

ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ БЮДЖЕТНОЕ УЧРЕЖДЕНИЕ
«НАЦИОНАЛЬНЫЙ МЕДИЦИНСКИЙ ИССЛЕДОВАТЕЛЬСКИЙ ЦЕНТР
СЕРДЕЧНО-СОСУДИСТОЙ ХИРУРГИИ ИМ. А. Н. БАКУЛЕВА»
МИНИСТЕРСТВА ЗДРАВООХРАНЕНИЯ РОССИЙСКОЙ ФЕДЕРАЦИИ

На правах рукописи

Тимофеева Ольга Юрьевна

Клинико-морфофункциональное обоснование поддержки принятия
решения при выборе хирургической тактики у детей с тетрадой Фалло.

3.1.15. Сердечно-сосудистая хирургия

Диссертация
на соискание ученой степени
кандидата медицинских наук

Научный руководитель:
Д.м.н., профессор А.И. Ким

Москва 2026

Оглавление

СПИСОК СОКРАЩЕНИЙ.....	4
ВВЕДЕНИЕ.....	5
Актуальность	5
Цель диссертационного исследования.....	6
Задачи исследования.....	6
Научная новизна исследования	7
Практическая ценность исследования	7
Реализация результатов исследования.....	7
Глава I. ОБЗОР ЛИТЕРАТУРЫ.....	8
1.1 Определение.....	8
1.2 Методы и процессы ИИ: от данных к интеллектуальным решениям	9
1.3 Основные направления применения ИИ в кардиохирургии	16
1.3.1. Предоперационное планирование и прогнозирование рисков.....	16
1.3.2 Прогнозирование послеоперационных осложнений.	20
1.3.3 Оптимизация хирургической тактики.....	21
1.3.4 Послеоперационный мониторинг и управление рисками	26
1.4 Использование ИИ для определения стратегии лечения ТФ.	29
Глава II. МАТЕРИАЛ И МЕТОДЫ ИССЛЕДОВАНИЯ.....	41
Глава III. МЕТОДИКА СОЗДАНИЯ МОДЕЛЕЙ МАШИННОГО ОБУЧЕНИЯ.....	56
3.1 Подготовка данных и разработка предиктивных моделей	56
3.1.1 Загрузка, первичный анализ и очистка данных	56

3.1.2 Формирование выборок и борьба с переобучением.....	57
3.1.3 Инженерия признаков (Feature Engineering)	57
3.1.4 Обработка текстовых и категориальных данных	57
3.1.5 Анализ распределений, аномалий и отбор признаков.....	58
3.1.6 Обучение и оптимизация гиперпараметров	60
3.2 Архитектура и алгоритм работы рекомендательной системы	60
3.3 Валидация и стабильность модели.....	62
Глава IV. РЕЗУЛЬТАТЫ	63
Глава V. ОБСУЖДЕНИЕ.....	76
ЗАКЛЮЧЕНИЕ	92
ВЫВОДЫ	94
ПРАКТИЧЕСКИЕ РЕКОМЕНДАЦИИ.....	95
СПИСОК ЛИТЕРАТУРЫ.....	97

СПИСОК СОКРАЩЕНИЙ

ВПС – врождённый порок сердца

ТФ – тетрада Фалло

ПЖ – правый желудочек

ВОПЖ – выводной отдел правого желудочка

ИИ – искусственный интеллект

МО – машинное обучение

РК – радикальная коррекция

РПОПЖ – реконструкция путей оттока из правого желудочка

ТЛБВП ЛА – транслюминальная баллонная вальвулопластика лёгочной артерии

CNN – свёрточные нейронные сети

ЭхоКГ – эхокардиография

MPT – магнитно-резонансная томография

КТ – компьютерная томография

GAN – генеративно-состязательные сети

ВВЕДЕНИЕ

Актуальность

Достижения медицины в области диагностики, хирургических методов, непрерывного ухода в до и послеоперационном периоде в детском возрасте изменили перспективы для пациентов с тетрадой Фалло (ТФ), увеличив выживаемость и продолжительность жизни. Однако с ростом когорты прооперированных больных обострились давние проблемы и возникли новые, что требует современных подходов к тактике лечения ТФ[1–5]. Актуальность применения искусственного интеллекта (ИИ) в кардиохирургии, особенно при лечении врождённых пороков сердца (ВПС), обусловлена необходимостью повышения точности диагностики, оптимизации хирургических вмешательств и улучшения послеоперационного ведения пациентов. ВПС представляют собой сложную и разнообразную группу заболеваний, требующих индивидуального подхода, и здесь ИИ становится незаменимым инструментом. Одним из ключевых направлений является автоматизированная обработка медицинских изображений. Алгоритмы глубокого обучения, такие как сверточные нейронные сети (CNN), способны анализировать данные эхокардиографии (ЭхоКГ), магнитно-резонансной томографии (МРТ) и компьютерной томографии (КТ), выявляя даже малозаметные аномалии строения сердца. Это значительно ускоряет постановку диагноза и снижает риск человеческой ошибки. Кроме того, ИИ применяется для прогнозирования течения заболевания и рисков послеоперационных осложнений. Машинное обучение анализирует огромные массивы данных, включая историю болезни, генетические маркеры, показатели гемодинамики и другие параметры, что позволяет разрабатывать персонализированные схемы лечения[6,7].

Важным аспектом является использование ИИ в предоперационном планировании. Современные технологии позволяют создавать 3D-модели сердца пациента на основе медицинских изображений, что дает хирургам возможность

детально изучить анатомические особенности и заранее проработать стратегию операции. Дополненная и виртуальная реальность (AR/VR) в сочетании с ИИ используются для симуляции хирургических вмешательств, что особенно важно при сложных случаях ВПС. Во время самой операции ИИ может оказывать поддержку в режиме реального времени, например, анализируя данные мониторинга и предупреждая о возможных рисках. Роботизированные системы, такие как da Vinci, уже активно применяются в кардиохирургии, повышая точность манипуляций и уменьшая инвазивность процедур [8,9].

После операции ИИ продолжает играть важную роль в мониторинге состояния пациента. Алгоритмы способны анализировать данные с датчиков, предсказывать возможные осложнения (например, аритмии или инфекции) и корректировать терапию. Телемедицинские платформы с ИИ позволяют удаленно наблюдать за пациентами, что особенно актуально для детей с ВПС, нуждающихся в длительном наблюдении. Таким образом, применение ИИ в кардиохирургии ВПС не только улучшает результаты лечения, но и способствует развитию персонализированной медицины, сокращает сроки госпитализации и снижает нагрузку на медицинский персонал. В будущем интеграция ИИ с новейшими технологиями, такими как биопечать тканей и генная терапия, может открыть еще более широкие возможности для лечения сложных врожденных пороков сердца[10–12].

Цель диссертационного исследования

Разработка и клиническая валидация интеллектуальной системы поддержки принятия решений на основе искусственного интеллекта для персонализированного выбора хирургической тактики у детей с тетрадой Фалло.

Задачи исследования

1. Провести систематический анализ современных хирургических стратегий при тетраде Фалло (РК, паллиативные вмешательства, гибридные методы)
2. Определить набор значимых прогностических параметров, включая: Анатомические особенности (размер ЛЖ, ПЖ, ДМЖП, степень гипоплазии ЛА,

выраженность инфундибулярного стеноза); гемодинамические показатели (градиенты давления, сатурация, давление в ПЖ); клинико-демографические данные (возраст, вес, сопутствующие патологии).

3. Определить оптимальную модель (LGBMClassifier, CatBoostClassifier, XGBClassifier, RandomForestClassifier, LogisticRegression) для клинического применения, учитывая баланс между точностью, обобщающей способностью и интерпретируемостью.

4. Разработать электронную платформу на основе обученной модели для персонализированной рекомендации хирургической тактики у детей с тетрадой Фалло и внедрить в клиническую работу кардиохирургических отделений врождённых пороков сердца.

Научная новизна исследования

Впервые в нашей практике единовременно проведён анализ группы пациентов с диагнозом ТФ в возрасте до 5 лет, всех имеющихся тактик лечения и факторов, влияющих на выбор оперативного вмешательства. Исследование впервые демонстрирует эффективность применения моделей машинного обучения для анализа мультимодальных данных при ТФ с интеграцией в хирургическую практику.

Практическая ценность исследования

Исследование имеет прикладное значение как основа для дальнейшей разработки систем поддержки принятия решений в кардиохирургии врождённых пороков, которые могут использоваться как вспомогательный инструмент при выборе хирургической тактики у детей с тетрадой Фалло.

Реализация результатов исследования

Полученные результаты исследования, научные выводы и практические рекомендации внедряются в клиническую практику НМИЦ ССХ им. А.Н. Бакулева. Данная работа может представлять практический интерес для детских кардиологов, кардиохирургов, неонатологов.

Глава I. ОБЗОР ЛИТЕРАТУРЫ

1.1 Определение

ИИ представляет собой междисциплинарную научную область, объединяющую методы компьютерных наук, математической статистики, когнитивной психологии и нейробиологии, направленную на разработку алгоритмических систем, демонстрирующих когнитивные функции, ассоциируемые с человеческим интеллектом [2–5,13]. В методологическом плане современные системы ИИ реализуют парадигму МО, основанную на статистическом выводе и оптимизационных процедурах, позволяющих автоматически выявлять сложные нелинейные зависимости в многомерных пространствах признаков. Архитектурно такие системы чаще всего реализуются в виде глубоких нейронных сетей, представляющих собой композиции дифференцируемых преобразований, параметры которых оптимизируются методами стохастической градиентной оптимизации на специализированных вычислительных устройствах (GPU, TPU).

С теоретической точки зрения, современные достижения в области ИИ базируются на фундаментальных результатах теории вероятностей (байесовский вывод), теории оптимизации (выпуклые и невыпуклые задачи), теории информации (минимизация энтропии) и вычислительной сложности. Практические реализации включают сверточные нейронные сети для обработки изображений, рекуррентные архитектуры для временных рядов, трансформеры для обработки последовательностей и графовые нейронные сети для работы со структурированными данными. Важнейшим аспектом современных ИИ-систем является их способность к обобщению – переносу выученных закономерностей на новые данные, что формально описывается в рамках статистической теории обучения Вапника-Червоненкиса.

С методологической точки зрения можно выделить три ключевых направления исследований: supervised learning (обучение с учителем на размеченных данных), unsupervised learning (выявление скрытых структур) и reinforcement learning (оптимизация стратегий через взаимодействие со средой). Каждое из этих направлений имеет строгое математическое обоснование в рамках теории вероятностей и статистики, а их практическая реализация требует решения сложных задач регуляризации, борьбы с переобучением и обеспечения вычислительной эффективности. Современные исследования в области ИИ фокусируются на таких фундаментальных проблемах, как интерпретируемость моделей, устойчивость к adversarial-возмущениям, эффективное обучение с небольшим количеством данных (few-shot learning) и разработка нейросетевых архитектур, способных к многоуровневой абстракции и символическим вычислениям [14,15].

1.2 Методы и процессы ИИ: от данных к интеллектуальным решениям

Современный ИИ представляет собой комплекс методов и технологических процессов, направленных на создание систем, способных выполнять задачи, традиционно требующие человеческого интеллекта. В основе ИИ лежат несколько ключевых направлений, каждое из которых включает уникальные алгоритмы и подходы к обработке данных, обучению и принятию решений.

В таблице 1 приведены часто используемые алгоритмы в области ИИ, а также их преимущества и ограничения [16]. Все алгоритмы ИИ, используемые в медицине, можно разделить на семь основных категорий, каждая из которых решает конкретные задачи и использует свои методы МО.

Таблица 1. Распространенные алгоритмы искусственного интеллекта [16].

Алгоритм	Собственность	Описание	Преимущество	Ограничение
Линейная регрессия	Контролируемое обучение	Моделирует взаимосвязь между независимыми и зависимыми переменными.	1. Простота реализации. 2. Хорошая интерпретируемость, способствует анализу решений.	Не удается обрабатывать очень сложные / нелинейные данные.
Наивный байес	Контролируемое обучение	Основываясь на теореме Байеса и независимости признаков, он использует знания в области вероятности и статистики для классификации.	1. Прочность, простота реализации и интерпретируемость. 2. Возможность постепенного обучения.	Независимость от данных слишком строга.
К-ближайший сосед (KNN)	Обучение без учителя	Найдите К ближайших узлов в многомерном пространстве объектов.	1. Простота реализации, возможность поэтапного обучения. 2. Может использоваться для задач классификации или регрессии; 3. Не чувствителен к выбросам.	1. Высокая вычислительная сложность. 2. не подходит для задач с неравномерным распределением данных. 3. Требуется достаточное количество узлов.
Дерево Принятия решений	Контролируемое обучение	Стройте вероятностные функции и древовидные структуры для достижения прогнозирования.	1. Высокая интерпретируемость 2. Можно обрабатывать числовые и логические данные.	1. Легко переобучить. 2. Игнорировать взаимосвязи между данными.
Кластеризация	Обучение без учителя	Увеличьте расстояние между кластерами и уменьшите расстояние внутри кластеров.	Может обрабатывать сложные многомерные данные.	1. Невозможно выполнять поэтапное обучение. 2. Влияющие гиперпараметры, это плохо для обучения.

Продолжение таблицы 1.

Алгоритм	Собственность	Описание	Преимущество	Ограничение
Машины опорных векторов	Контролируемое обучение	Установите гиперплоскость максимального отклонения в качестве границы принятия решения (нелинейные данные можно обрабатывать с помощью методов ядра).	1. Может работать с многомерными данными. 2. Хорошее обобщение. 3. Может решать проблему малых выборок.	1. Трудно найти подходящую функцию ядра. 2. Чувствителен к отсутствующим данным. 3. Слабая интерпретируемость
Анализ основных компонентов	Обучение без учителя	Используйте меньше объектов, отражающих исходное пространство объектов, чтобы добиться уменьшения размерности.	1. Снижает сложность данных. 2. В определённой степени может устранять помехи. 3. Не имеет ограничений по гиперпараметрам.	1. В случае негауссовского распределения результаты могут быть неоптимальными. 2. Не может обрабатывать нерегулярные данные.
Искусственные нейронные сети	Все семь категорий	Соедините большое количество узлов друг с другом в соответствии с различными способами подключения.	1. Может обучаться самостоятельно и обобщать. 2. Высокая точность.	1. Не поддаётся интерпретации. 2. Огромная вычислительная сложность, требуется достаточная аппаратная поддержка.
Многослойный персептрон (MLP)	Контролируемое обучение	Разновидность модели искусственной нейронной сети.	1. Универсальное приближение. 2. Высокая отказоустойчивость. 3. Способность изучать сложные взаимосвязи; 4. возможность быстро обрабатывать большие объёмы данных.	1. Легко переобучается. 2. Требуется большое количество обучающих данных. 3. Низкая интерпретируемость.

Продолжение таблицы 1.

Алгоритм	Собственность	Описание	Преимущество	Ограничение
Условное случайное поле (CRF)	Контролируемое обучение	Вероятностные графические модели используются для моделирования и прогнозирования последовательных данных.	1. Работа с данными последовательностей. 2. Возможность выявления долгосрочных зависимостей в данных последовательностей 3. Гибкая структура модели.	1. Высокая вычислительная сложность при работе с длинными последовательным и данными. 2. Высокая сложность настройки параметров. 3. Плохая интерпретируемость.
Сверточная нейронная сеть (CNN)	Контролируемое обучение	Нейронная сеть, состоящая из нескольких свёрточных, объединяющих и полносвязных слоёв.	1. Не нужно вручную создавать функции. 2. Можно использовать общие веса.	1. Более высокая вычислительная сложность. 2. Легко переобучается. 3. Плохо интерпретируется; 4. Склонен к переобучению
Генеративная состязательная сеть (GAN)	Обучение без учителя	Модель, состоящая из генератора и дискриминатора.	Легко читается и воспринимается. 2. Не требует помеченных данных. 3. Очень гибкий: может использоваться для различных типов данных и задач.	1. Процесс обучения более сложный и требует настройки множества гиперпараметров. 2. Нестабильность. 3. Оценка более сложная. 4. Плохая интерпретируемость.
Сеть глубоких убеждений (DBN)	Обучение без учителя	Модели, состоящие из нескольких ограниченных машин Больцмана.	1. Может изучать распределение сложных данных и многоуровневое представление признаков. 2. Может генерировать новые образцы данных. 3. Высокая гибкость.	1. Более высокая вычислительная сложность. 2. Сложный процесс обучения. 3. Плохая интерпретируемость модели. 4. Легко переобучиться.

Продолжение таблицы 1

Алгоритм	Собственность	Описание	Преимущество	Ограничение
Повышение Градиента	Контролируемое обучение	Алгоритм коллективного обучения, который повышает точность прогнозирования за счет объединения нескольких слабых учащихся.	1. Высокая точность. 2. Более высокая гибкость. 3. Более высокая надёжность. 4. Процесс принятия решений относительно прост для объяснения и понимания.	1. Процесс настройки параметров более сложный. 2. Более высокая вычислительная сложность. 3. Легко переобучиться. 4. Необходимо выбрать подходящий слабый алгоритм.
Повышение	Контролируемое обучение	Метод комплексного обучения для объединения слабых классификаций в один сильный классификатор с помощью обучения.	1. Снижает риск переобучения. 2. Подходит для различных типов данных.	1. Легко подвержен влиянию выбросов; 2. Сложная настройка. 3. Высокая вычислительная сложность.
Random Trees (Случайные деревья)	Контролируемое обучение	Интегрированный подход к обучению, состоящий из нескольких деревьев принятия решений.	1. Применим к многомерным данным; 2. Нечувствителен к выбросам. 3. Может рассчитываться параллельно.	1. Плохая интерпретация модели. 2. Высокое потребление ресурсов.

- **Диагностические системы**

Одним из наиболее актуальных направлений развития ИИ является автоматизация и объективизация диагностики заболеваний. ИИ анализирует медицинские изображения, такие как рентгеновские снимки, МРТ и КТ, выявляя патологии с точностью, сопоставимой с квалифицированными врачами. Например, CNN успешно применяются для обнаружения опухолей, диабетической ретинопатии и других заболеваний. Кроме того, алгоритмы обрабатывают сигналы ЭКГ и ЭЭГ, помогая диагностировать аритмии и неврологические расстройства. Такие системы, как IBM Watson и Ada Health,

также анализируют симптомы пациентов, предлагая возможные диагнозы на основе больших массивов медицинских данных[17–19].

- Прогностическая аналитика

Прогностические модели ИИ позволяют оценивать риски развития осложнений, рецидивов заболеваний или необходимости госпитализации[20]. Например, алгоритмы DeepMind Health, разработанные совместно с британской NHS, предсказывают вероятность сепсиса у пациентов в реанимации [21]. Другие системы анализируют историю болезни и генетические данные, прогнозируя течение онкологических заболеваний. Во время пандемии COVID-19 инструменты вроде BlueDot использовали машинное обучение для раннего предупреждения о вспышках инфекций, что помогло властям оперативно реагировать на угрозы [22].

- Персонализированное лечение

ИИ играет ключевую роль в персонализированном подходе, помогая подбирать индивидуальные схемы терапии [23,24]. Например, IBM Watson for Oncology анализирует медицинские записи и научные публикации, предлагая онкологам персонализированные рекомендации по лечению рака[25]. Алгоритмы также используются для расчета оптимальных доз лекарств, таких как варфарин, что снижает риск побочных эффектов [6]. В геномике ИИ ускоряет анализ ДНК, помогая выявлять мутации и подбирать целевые терапии для редких заболеваний [26].

- Роботизированная хирургия

Хирургические роботы, такие как Da Vinci, уже несколько лет используются в операционных, обеспечивая высокую точность и минимальную инвазивность. ИИ в этой области не только управляет инструментами, но и помогает хирургам в реальном времени – например, выделяя критически важные анатомические структуры на изображениях или предупреждая о возможных осложнениях. Некоторые системы, такие как Activ Surgical, используют компьютерное зрение и обучение с подкреплением для навигации во время операций [27].

- Обработка медицинских текстов

Естественно-языковые алгоритмы (NLP) применяются для анализа электронных медицинских карт, научных статей и клинических рекомендаций. Например, Amazon Comprehend Medical автоматически извлекает ключевую информацию из записей врачей, упрощая документирование [28]. Другие системы автоматизируют кодирование диагнозов по стандартам ICD-10, сокращая время на административную работу. В последние годы языковые модели, такие как ChatGPT, тестируются для генерации выписок и ответов на вопросы врачей [29].

- Мониторинг пациентов

ИИ позволяет непрерывно отслеживать состояние пациентов как в больницах, так и дома. Носимые устройства, такие как Apple Watch, обнаруживают аритмии и другие отклонения, отправляя предупреждения врачам [30]. Алгоритмы анализируют голос и речь для ранней диагностики нейродегенеративных заболеваний, таких как болезнь Паркинсона [31]. В отделениях интенсивной терапии системы на основе МО, например Epic Deterioration Index, предупреждают о резком ухудшении состояния пациентов, позволяя медикам действовать на опережение [32–34].

- Оптимизация работы медучреждений

ИИ помогает больницам и клиникам работать эффективнее, снижая затраты и улучшая качество обслуживания. Алгоритмы прогнозируют нагрузку на отделения, позволяя оптимально распределять ресурсы. Системы вроде LeanTaaS оптимизируют расписания операций и приемов, сокращая время ожидания для пациентов. Кроме того, ИИ применяется для выявления мошенничества в страховых выплатах, анализируя закономерности в больших массивах данных [35,36].

1.3 Основные направления применения ИИ в кардиохирургии

Современная кардиохирургия сталкивается с необходимостью персонализации лечения, минимизации инвазивности вмешательств и снижения риска осложнений. ИИ и МО предлагают новые возможности для решения этих задач, позволяя анализировать большие объемы клинических данных, прогнозировать исходы операций и оптимизировать хирургическую тактику. В данной главе рассматриваются ключевые направления внедрения ИИ в кардиохирургию, включая предоперационное планирование, интраоперационную навигацию и послеоперационный мониторинг.

1.3.1. Предоперационное планирование и прогнозирование рисков

ИИ активно используется для анализа данных визуализации (КТ, МРТ, ЭхоКГ) и создания цифровых моделей сердца, что особенно важно при сложных врожденных пороках и реконструктивных операциях.

Автоматическая сегментация анатомических структур Алгоритмы на основе CNN обеспечивают точность до 95% при выделении структур сердца из 3D-изображений.

Автоматическая сегментация и количественный анализ структур сердца на эхокардиографии крайне важны для диагностики и мониторинга сердечных патологий (дилатации, гипертрофии, нарушений сократимости), но остаются сложной задачей из-за анатомических вариаций. В исследовании L. Yu и коллег [37] предложен двухэтапный метод на основе CNN для сегментации левого желудочка плода. Модель сначала предобучалась на бинарной классификации пикселей (область интереса/фон), затем дообучалась на 200 тыс. размеченных образцов из 10 наборов данных. Особенность подхода – использование полной разметки только для первого кадра в последовательности ЭхоКГ, что упростило работу экспертов. Последующие кадры адаптировались автоматически с учетом

индивидуальных особенностей. Этот метод достиг точности сегментации 94.5%, что подтверждает потенциал глубокого обучения для автоматизации анализа фетальной эхокардиографии – безопасного и доступного метода пренатальной диагностики.

Китайские исследователи провели сравнительное исследование четырех современных архитектур глубоких нейронных сетей - U-Net, Attention U-Net, UNet++ и UNeXt - для решения задачи сегментации левого желудочка на трансторакальных эхокардиографических изображениях (TEE). В исследовании использовался значительный объем данных: обучающая выборка содержала 3336 изображений, валидационная и тестовая - по 138 изображений каждая. Для объективной оценки моделей применялись несколько ключевых метрик: коэффициент сходства Жаккара (JSC), коэффициент сходства Диза (DSC), количество обучаемых параметров сети, время обучения и скорость обработки одного изображения. Результаты показали, что модели Attention U-Net и UNet++ достигли наивысшей точности сегментации, продемонстрировав средние показатели JSC 86,02% и DSC 92,00%. При этом модель UNeXt выделялась своей компактностью, имея всего 1,47 миллиона параметров, что делает ее потенциально более удобной для практического внедрения. В аспекте производительности традиционная U-Net показала наилучшие результаты по скорости как в обучении (6428,65 секунд), так и в обработке одного изображения (101,75 миллисекунд). Особого внимания заслуживает способность Attention U-Net эффективно работать со сложными случаями, такими как нечеткие границы левого желудочка или наличие артефактов от сосочковых мышц. Это исследование имеет важное практическое значение, наглядно демонстрируя возможности использования методов глубокого обучения для автоматизированной и объективной оценки функционального статуса сердца, что может значительно улучшить качество периоперационного мониторинга пациентов в кардиологической и кардиохирургической практике [38].

При КТ ограниченное поле обзора (FOV) приводит к появлению артефактов усечения при реконструкции стандартными методами, такими как обратная фильтрация (FBP). Для решения этой проблемы Juuso Ketola и соавт. [39] предложили двухэтапный метод на основе генеративно-состязательных сетей (GAN). Сначала первая GAN-модель (Pix2Pix) восстанавливает усечённую синограмму, расширяя её, а затем вторая GAN обрабатывает реконструированное FBP-изображение, улучшая его качество. Модель Double GAN (DGAN) обучалась на 10 000 синограммах, смоделированных на основе реальных КТ-срезов, и сравнивалась с адаптивными методами восстановления, регуляризацией по полной вариации, FBPConvNet и U-Net-расширением синограммы (ES-UNet). DGAN и ES-UNet показали наилучшие результаты по среднеквадратичной ошибке ($RMSE\ 0,03 \pm 0,01$) и индексу структурного сходства ($SSIM\ 0,92 \pm 0,02$). Кроме устранения артефактов, метод позволил увеличить реконструируемую область на 20%, что улучшает диагностические возможности КТ-ангиографии.

Гемодинамические показатели играют ключевую роль в диагностике и лечении сердечно-сосудистых заболеваний, однако их неинвазивный мониторинг с высокой точностью остается сложной задачей. Китайские исследователи предложили решение на основе физик-информированных нейронных сетей (PINN), разработав 4D-модель для анализа кровотока в морфологически измененных сосудах, таких как после операций по коррекции ТФ или Фонтена [40]. Модель объединяет методы вычислительной гидродинамики с глубоким обучением, позволяя в реальном времени получать точные данные о структуре сосудов, полях скорости и давления крови, а также визуализировать 4D-гемодинамику. Система была протестирована на 88 000 случаях, включая два типа персонализированных моделей сосудов, и продемонстрировала высокую эффективность в прогнозировании пространственно-временных характеристик кровотока [41]. PINN-подход обеспечивает оптимальный баланс между точностью и вычислительными

затратами, что особенно важно для сложных клинических случаев. Разработка открывает новые возможности для неинвазивного мониторинга гемодинамики и планирования кардиохирургических вмешательств [42].

Трехмерная печать позволяет достичь уникального тактильного восприятия и точной объемной визуализации сложных патологий сердечно-сосудистой системы, обеспечивая детальную пространственную оценку структур, что значительно сокращает время планирования операции на 30–40%.

В систематическом обзоре Р. Таск и соавт. [43] отмечается широкое применение 3D-моделей во всех областях медицины, включая сердечно-сосудистую хирургию. Исследования, включенные автором в обзор, подтверждают, что использование подобных моделей достоверно сокращает время операций и улучшает ряд клинических результатов. В ВПС данная технология наиболее актуальна из-за разнообразия анатомических форм пороков и активно применяется для планирования как эндоваскулярных, так и открытых вмешательств [44,45]. Некоторые исследователи специально изучали преимущества 3D-моделей при подготовке к операциям. Например, Х.Л. Ма и коллеги провели проспективный анализ 35 случаев ТФ с использованием 3D-печатных моделей. Их целью было сопоставить данные моделей с интраоперационными находками. Результаты показали, что 3D-модели точно соответствуют реальной анатомии, наблюдаемой во время операции [46]. Наши коллеги Свободов А.А. и соавт., [47] описывают случай о применении данной технологии в предоперационном периоде у ребёнка со сложной анатомией ДОО от ПЖ, ТМА и комбинированным стенозом ЛА и сообщают, что 3Д-принтинг, помог им на предоперационном этапе в принятии решения об оптимальной хирургической тактике и интраоперационно никаких «находок» обнаружено не было, операция прошла по намеченному плану.

1.3.2 Прогнозирование послеоперационных осложнений

Острое повреждение почек остается одним из самых серьезных осложнений после кардиохирургических операций, значительно ухудшая прогноз пациентов и повышая риск летального исхода. Несмотря на существование различных методов оценки риска, их прогностическая способность оставляет желать лучшего. В поисках более точного инструмента прогнозирования группа исследователей под руководством Chen, J. [48] провела сравнительный анализ эффективности современных алгоритмов МО. Для этого были применены четыре различных метода: случайный лес (Random Forest), логистическая регрессия с LASSO-регуляризацией, экстремальный градиентный бустинг (XGBoost) и метод опорных векторов (SVM). В исследовании приняли участие пациенты, у которых после кардиохирургического вмешательства развилось ОПП (44 случая). Особое внимание уделялось выявлению наиболее значимых биомаркеров и клинических показателей. Анализ выявил четкую взаимосвязь между развитием ОПП и такими параметрами, как уровень белка FABP, геможувелина (HJV), нейтрофильного липокалина (NGAL), продолжительность искусственной вентиляции легких и концентрация тропонина I. При сравнении прогностической ценности различных алгоритмов наилучшие результаты показал метод случайного леса. Эта модель продемонстрировала исключительную точность с площадью под ROC-кривой (AUC) 0,858, что свидетельствует о ее высокой discriminative способности. Дополнительные метрики, включая показатель Бриера (0,137) и индекс чистой переклассификации (NRI = 0,221), подтвердили клиническую значимость данной модели. Полученные результаты убедительно доказывают, что современные методы МО, и в частности алгоритм Random Forest, существенно превосходят традиционные статистические подходы в прогнозировании послеоперационного ОПП. Внедрение таких моделей в клиническую практику может стать важным шагом на пути к ранней диагностике и своевременной профилактике этого

грозного осложнения, что в конечном итоге позволит улучшить исходы лечения кардиохирургических пациентов.

Раннее обнаружение сепсиса крайне важно, так как задержка в лечении значительно повышает смертность из-за необратимых повреждений органов. Smith и соавт. [49] разработали модель ИИ, используя данные пациентов из ОРИТ, и протестировали ее на скрытых наборах данных. Модель анализировала 168 почасовых признаков, предсказывая риск сепсиса в реальном времени с высокой точностью. Алгоритм показал общий показатель клинической полезности 0,364, а на отдельных тестовых наборах – 0,430, 0,422 и -0,048. Модель не только обеспечивает эффективное прогнозирование, но и позволяет интерпретировать влияние ключевых факторов на риск сепсиса, что важно для клинической практики в реанимации.

1.3.3 Оптимизация хирургической тактики

Алгоритмы поддержки принятия решений

В работе Smith и соавт. была разработана и проанализирована серия адаптивных моделей машинного обучения с целью определения возможностей прогнозирования 5-летней выживаемости без использования трансплантации сердца у младенцев с синдромом гипоплазии левых отделов сердца (СГЛС) [50]. Для обучения использовались показатели когорты, включённой в мультицентровое исследование Pediatric Heart Network Single Ventricle Reconstruction (SVR) trial и продолженного наблюдения SVR II, охватывающего этапные паллиативные операции и последующее 5-летнее наблюдение. Модели МО поэтапно включали клинические признаки, соответствующие различным фазам ведения: до первой паллиации (Pre-S1P), операционный этап первой паллиации и период госпитализации после первой паллиации, а также последующие периоды ухода до госпитализации после второй паллиации. Модели, обученные на данных от фазы Pre-S1P до периода после госпитализации

первой паллиации, продемонстрировали устойчивую производительность в прогнозировании выживаемости без трансплантации сердца на протяжении пяти лет после первой операции. Все эти модели показали времязависимую площадь под ROC-кривой в модели выживаемости выше 0,70, что указывает на хорошую прогностическую способность, а лучшая модель, включающая данные до конца госпитализации после первой паллиации, достигла 0,838 (95% доверительный интервал (ДИ) 0,836-0,840), что отражает высокую способность отличать исходы выживания от неблагоприятных исходов в течение длительного периода. Подобный подход обеспечивает клинически полезные индивидуальные прогнозы вероятности выживания без трансплантации на годы вперёд после этапной хирургической паллиации СГЛС, учитывая нелинейные эффекты и взаимодействия множества факторов риска на различных этапах ведения пациентов. Предложенные модели могут служить инструментом для стратификации риска и поддержки принятия решений как для клиницистов, так и для семей, поскольку они включают информацию, доступную уже на ранних этапах лечения, и уточняют прогноз по мере накопления клинических данных на каждом этапе терапии. Полученные Smith и соавт. результаты демонстрируют, что МО может предложить точный и адаптивный метод прогнозирования исходов у сложных пациентов с СГЛС, превосходящий традиционные подходы и способствующий персонализированному ведению данной высокорисковой группы пациентов.

В работе Chang Junior и соавт. разработана модель индивидуального предоперационного прогнозирования госпитальной летальности у пациентов с ВПС на основе методов МО [51]. В анализ включены 2240 последовательных пациентов регистра ASSIST (региональный многоцентровой регистр ВПС, созданный в Бразилии в 2014 году), перенёсших кардиохирургическое вмешательство в одном из крупнейших кардиохирургических центров Латинской Америки InCor в 2014-2018 гг. Спектр пороков включал широкий диапазон врождённых аномалий различной сложности, в том числе синдром

гипоплазии левых отделов сердца, атрезию лёгочной артерии, транспозицию магистральных артерий, тетраду Фалло, сложные сочетанные патологии и прочие критические формы ВПС. В качестве конечной точки определена госпитальная летальность, включающая смерть в стационаре или в течение 30 дней после операции. Общая летальность в выборке составляла 10,8%. Для построения прогностической модели были использованы 83 предоперационные клинико-демографические и диагностические переменные. Протестированы шесть алгоритмов машинного обучения: Multilayer Perceptron, Random Forest, Extra Trees, Stochastic Gradient Boosting, AdaBoost и Bagged Decision Trees. Применялась 10-кратная перекрёстная валидация с учётом выраженного дисбаланса выборки, где соотношение летальность/выживаемость составило примерно 1:9. Наилучшие показатели продемонстрировал алгоритм Random Forest с AUROC 0,902, чувствительностью 92,2%, специфичностью 90,8% и средней точностью 80,8% в тестовой выборке. Average Precision составил 0,73. Для сравнения, нейросетевая модель Multilayer Perceptron достигла высокой общей точности 90,2% и специфичности 98,5%, однако её чувствительность была лишь 20,8%, что существенно ограничивает её пригодность для выявления пациентов высокого риска. Анализ важности признаков показал, что шесть переменных обеспечивали 67,8% совокупной значимости модели Random Forest. К ним относились: предшествующая госпитализация в отделение интенсивной терапии, диагноз по шкалам Aristotle и RACHS-1, рост пациента на момент операции, индекс массы тела и сатурация артериальной крови кислородом. Отмечено, что риск госпитальной летальности был существенно выше у пациентов с ростом до 66 см и индексом массы тела ниже 13,0. Вероятность летального исхода снижалась при увеличении уровня артериальной сатурации. Предоперационная госпитализация, особенно пребывание в ОРИТ, ассоциировалась с более высоким риском смерти. Тяжёлые анатомические формы, включая синдром гипоплазии левых отделов сердца, демонстрировали наибольшую вероятность неблагоприятного исхода. Данные свидетельствовали

о том, что алгоритмы машинного обучения обеспечивали более точную индивидуализированную стратификацию риска по сравнению с традиционными шкалами, такими как RACHS-1 и Aristotle, за счёт учёта нелинейных взаимодействий множества клинических параметров. На основе модели был разработан веб-калькулятор (CgntSCORE), позволяющий рассчитывать уникальный риск операционной летальности с применением его в алгоритмах поддержки клинического принятия решений при кардиохирургическом лечении пациентов с ВПС.

В обзоре Duci и соавторов подчёркивается, что в педиатрической хирургии наиболее зрелым направлением применения ИИ является разработка алгоритмов поддержки принятия решений на основе машинного обучения для предоперационной стратификации риска и прогнозирования послеоперационных исходов [52]. В разделе, посвящённом прогнозированию послеоперационной летальности у новорождённых, приведены данные исследования Cooper и соавторов, где ансамблевая модель Super Learner, объединяющая несколько алгоритмов машинного обучения, продемонстрировала AUROC 0,91 в обучающей выборке и 0,87 во внешней валидации при прогнозировании 30-дневной смертности после хирургических вмешательств [53]. Указанные модели строились на основе комплексных предоперационных данных, включая демографические характеристики, клиническое состояние и тип выполняемой операции. В контексте кардиохирургии это особенно актуально для критических форм ВПС, таких как СГЛС, ТМА, ТФ, а также сложные одножелудочковые аномалии, где ранняя послеоперационная летальность остаётся значимой проблемой. При этом отдельные гибридные модели, объединяющие нейросетевые архитектуры для анализа изображений и лабораторных показателей, достигали точности до 94% и AUROC 0,91 при прогнозировании тяжёлых осложнений. В совокупности обзор демонстрирует, что модели машинного обучения уже достигают AUROC 0,87-0,91 в прогнозировании послеоперационной летальности и более 0,9 в

отдельных диагностических задачах, что превосходит традиционные клинические шкалы риска. Однако подчёркиваются и ограничения: большинство исследований выполнены на одноцентровых выборках, внешняя валидация была ограничена, а специфические когорты пациентов с отдельными формами ВПС остаются недостаточно представленными.

Интраоперационная навигация

В исследовании Lal Vallath и соавт. [54] была разработана и протестирована инновационная система компьютерного зрения для интраоперационной навигации во время коррекции дефектов межжелудочковой перегородки (ДМЖП). Система основана на глубоком обучении с использованием 3D U-Net архитектуры и обеспечивает в реальном времени анализ видео с хирургического микроскопа в сочетании с эхокардиографическими данными. Алгоритм демонстрирует исключительную точность в идентификации критических анатомических структур: 98.2% для границ ДМЖП, 96.7% для трабекул правого желудочка и 93.5% для проводящей системы сердца. Многоцентровое исследование, проведенное в восьми ведущих кардиохирургических центрах на выборке из 240 пациентов, показало значительные клинические преимущества системы. Внедрение технологии позволило сократить время поиска анатомических ориентиров на 42%, снизить частоту остаточных шунтов до 1.7% (по сравнению с 6.3% в контрольной группе) и уменьшить длительность пережатия аорты в среднем на 15 минут. Ключевой инновацией системы является ее интеграция с дополненной реальностью - хирург получает цветовую маркировку критических структур непосредственно в поле зрения операционного микроскопа, что существенно повышает точность и безопасность вмешательства [55].

В статье Arghami и соавторов [56] представлен десятилетний опыт выполнения робот-ассистированных операций на митральном клапане с послеоперационным эхокардиографическим контролем. Исследование охватывает 512 пациентов, прооперированных в период с 2010 по 2020 год с

использованием системы da Vinci. Основные результаты показали, что роботизированный доступ обеспечил успешную реконструкцию клапана в 98.2% случаев с низкой частотой конверсии на стернотомию (1.6%). Эхокардиографическое наблюдение в течение 5 лет продемонстрировало устойчивые результаты: степень регургитации $\leq 1+$ сохранялась у 92% пациентов, частота повторных вмешательств составила всего 1.9%. Авторы отмечают значительное сокращение времени пребывания в стационаре (в среднем 3.2 дня) по сравнению с традиционными методами, а также уменьшение частоты послеоперационных осложнений, включая кровопотерю и инфекции. Исследование подтвердило безопасность и эффективность роботизированной техники в долгосрочной перспективе, особенно для пациентов с пролапсом задней створки митрального клапана (85% случаев в исследовании).

1.3.4 Послеоперационный мониторинг и управление рисками

Раннее выявление осложнений

В статье Choi и соавторов [57] представлена одна из первых работ по применению рекуррентных нейронных сетей (RNN) для раннего прогнозирования сердечной недостаточности на основе электронных медицинских записей. Исследование охватывает данные 3884 пациентов из системы здравоохранения Geisinger за 10-летний период. Авторы разработали LSTM-модель (разновидность RNN), которая анализирует временные ряды 87 клинических параметров, включая жизненно важные показатели, лабораторные тесты, медикаменты и диагнозы, с возможностью прогнозирования госпитализации по поводу сердечной недостаточности за 6-18 месяцев до события. Модель продемонстрировала AUC 0.83 (95% ДИ: 0.81-0.85), что значительно превосходит традиционные логистические регрессионные модели (AUC 0.76). Ключевыми предикторами оказались динамика уровня натрия, креатинина и изменения массы тела. Особенность подхода - способность

учитывать нерегулярные временные интервалы между наблюдениями, характерные для реальной клинической практики. Исследование также включает интерпретируемый анализ важности признаков, что повышает доверие клиницистов к модели.

В статье Gorecki и соавторов [58] проведен критический анализ возможностей и ограничений ИИ в диагностике сепсиса и септического шока. Исследование охватывает 18 современных ИИ-алгоритмов (включая системы на основе МО и глубоких нейронных сетей), применяемых для раннего выявления сепсиса по комбинации клинических, лабораторных и гемодинамических параметров. Авторы выделяют, что наиболее эффективные модели (AUC 0.88-0.92) используют временные ряды данных - динамику лактата, тромбоцитов, СРБ и показателей органной дисфункции, при этом подчеркивают проблему "черного ящика" в интерпретации решений ИИ. Особое внимание уделено сравнению с традиционными критериями SOFA и qSOFA: ИИ-системы демонстрируют преимущество в прогнозировании сепсиса за 4-6 часов до клинической манифестации, но требуют строгой валидации в различных популяциях пациентов. Ключевые барьеры внедрения включают неоднородность электронных медицинских карт между учреждениями и необходимость обучения медицинского персонала. Авторы предлагают дорожную карту для интеграции ИИ в клиническую практику, акцентируя важность мультидисциплинарного подхода и разработки стандартов отчетности для ИИ-моделей в интенсивной терапии.

Персонализированная терапия

В статье Zhu и соавторов [59] представлены результаты многоцентрового рандомизированного контролируемого исследования, посвященного оценке эффективности нового интернет-подхода к управлению антикоагулянтной терапией варфарином у пациентов после механического протезирования клапанов сердца. В исследовании участвовали 1024 пациента из 12 медицинских центров Китая, которых случайным образом распределили на две группы: в

первой (n=512) использовался традиционный подход к подбору дозы варфарина, во второй (n=512) - новая интернет-платформа с алгоритмами ИИ. Платформа анализировала комплекс параметров, включая МНО, демографические данные, сопутствующую терапию и клинические показатели, предоставляя персонализированные рекомендации по дозировке. Основные результаты показали, что интернет-подход достоверно увеличил время в терапевтическом диапазоне МНО (TTR) с 55,3% до 64,7% ($p<0,001$), снизил частоту тромбоэмболических осложнений с 3,5% до 1,4% ($p=0,02$) и уменьшил частоту кровотечений с 4,3% до 2,1% ($p=0,04$) в течение 6 месяцев наблюдения. Авторы подчеркивают, что предложенный подход улучшает безопасность и эффективность антикоагулянтной терапии, обеспечивая более стабильный антикоагулянтный эффект, и может быть рекомендован для широкого внедрения в клиническую практику. Важным преимуществом системы является ее доступность для пациентов в отдаленных районах через мобильные приложения, что особенно актуально для стран с большой территорией.

В статье Liu и соавт. [60] представлено ретроспективное исследование, в котором разработан и протестирован алгоритм обучения с подкреплением (Reinforcement Learning, RL) для оптимизации параметров искусственной вентиляции легких (ИВЛ) у пациентов в условиях интенсивной терапии. Исследование основано на анализе данных 1 850 пациентов, находящихся на инвазивной ИВЛ, из электронных медицинских карт трёх медицинских центров. Алгоритм RL анализировал динамику клинических показателей (газы крови, параметры вентиляции, витальные функции) и предлагал персонализированные настройки респиратора (FiO_2 , РЕЕР, дыхательный объём) с целью минимизации риска баротравмы и гипоксии. Результаты показали, что предложенный алгоритм мог бы сократить среднее время оптимальной вентиляции на 18% по сравнению с ручными настройками, а также снизить частоту осложнений, связанных с ИВЛ, на 22%.

1.4 Использование ИИ для определения стратегии лечения ТФ

ТФ, как один из наиболее сложных цианотических пороков, представляет особый интерес для внедрения интеллектуальных систем поддержки врачебных решений. В последнем обзоре Европейской ассоциации кардиоторакальной хирургии (EACTS, 2023) подчеркивается, что ИИ-технологии позволяют преодолеть ключевые ограничения традиционных подходов, связанные с субъективностью интерпретации диагностических данных и вариабельностью хирургических результатов. Несмотря на значительный прогресс в кардиохирургии, отдаленные результаты лечения варьируют, а пациенты сталкиваются с риском развития жизнеугрожающих осложнений, включая аритмии, сердечную недостаточность и внезапную смерть. В этой связи прогнозирование индивидуальных исходов приобретает особую значимость, и ИИ открывает новые возможности для персонализированной медицины.

В исследовании S.Tilborghs и соавт. [61] разработали инновационную трехмерную модель глубокого обучения на основе архитектуры U-Net, специально адаптированную для сегментации левого и правого желудочков. Методология исследования включала несколько ключевых этапов: подготовку данных (использовались как публичные, так и институциональные наборы данных МРТ-изображений), пятикратную перекрестную валидацию для обеспечения надежности результатов, а также применение специальных техник для работы с неполными или зашумленными данными. Особого внимания заслуживает использование маргинальной Dice loss функции, которая позволила эффективно обрабатывать отсутствующие сегменты в разметке данных. Для оптимизации процесса обучения применялся алгоритм Adam с тщательно подобранным графиком изменения learning rate и размером батча. Важной частью методологии стало использование методов аугментации данных, что значительно увеличило разнообразие обучающей выборки. Результаты показали исключительную точность модели: коэффициент Dice составил 0.91 для левого

желудочка и 0.88 для правого, что особенно важно учитывая известные сложности в оценке ПЖ. Модель продемонстрировала превосходство над коммерческим программным обеспечением, особенно в анализе правого желудочка, где средняя абсолютная ошибка объема составила всего 12 мл. Эти результаты имеют важное клиническое значение, так как позволяют значительно сократить время анализа (с нескольких часов ручной обработки до нескольких минут) и устранить проблему межоператорской вариабельности.

В исследовании «The Lifelong Impact of Artificial Intelligence and Clinical Prediction Models on Patients With Tetralogy of Fallot» [62] авторы систематизировали применение различных алгоритмов ИИ в нескольких ключевых областях: скрининг и диагностика, автоматизированная обработка и интерпретация медицинских изображений, стратификация риска, планирование хирургических вмешательств и прогнозирование их исходов. В работе подробно рассматриваются несколько алгоритмов, включая CNN, GAN, SVM, случайные леса и линейный дискриминантный анализ. Особое внимание уделяется потенциалу этих технологий в решении специфических задач, таких как оценка аритмического риска, прогнозирование когнитивных нарушений и вероятности летального исхода. Авторы приводят убедительные аргументы в пользу того, что интеграция ИИ в клиническую практику может революционизировать подходы к ведению пациентов с ТФ, обеспечивая более раннее выявление осложнений, персонализированный выбор тактики лечения и улучшение долгосрочных результатов. Однако в работе также подчеркиваются существующие ограничения, в частности необходимость дальнейших исследований для внешней валидации существующих моделей, решения проблем интерпретируемости решений ИИ и преодоления методологических сложностей, связанных с особенностями данных по врожденным порокам сердца.

Diller et al. и соавт. [63] провели проспективное исследование с участием 372 пациентов с корригированной ТФ было направлено на разработку и валидацию алгоритмов глубокого обучения для прогнозирования клинических

исходов на основе анализа данных магнитно-резонансной томографии сердца. Методологическая часть исследования включала несколько инновационных подходов: применение предобученных моделей глубокого обучения для распознавания МРТ-изображений камер сердца, использование техник аугментации данных с целью увеличения обучающей выборки, а также интеграцию методов сегментации (на основе U-Net) с алгоритмами прогностического моделирования. Особый интерес представляют выявленные исследователями значимые предикторы неблагоприятных исходов: медианная площадь правого предсердия и показатели продольной деформации правого желудочка. Авторы разработали составной прогностический балл, объединяющий параметры увеличения правого предсердия и нарушения функции ПЖ, который продемонстрировал высокую дискриминационную способность в выделении группы высокого риска. Важным достижением исследования стало значительное сокращение межоператорской вариабельности при оценке прогноза по сравнению с традиционными методами анализа. В работе подробно обсуждаются технические аспекты реализации алгоритмов, включая используемое аппаратное обеспечение (процессоры Intel и графические ускорители Nvidia), а также применяемые метрики качества (включая Dice score). Клиническая значимость исследования заключается в том, что предложенный подход позволяет не только прогнозировать риск серьезных осложнений (включая внезапную сердечную смерть и желудочковые аритмии), но и может служить инструментом для динамического наблюдения за пациентами в течение длительного времени.

В работе «Le Coeur en Sabot: shape associations with adverse events in repaired tetralogy of Fallot» [64] предлагается принципиально новый подход к прогнозированию осложнений через анализ геометрических изменений сердца у пациентов с корригированной ТФ. Авторы провели комплексный анализ морфологии желудочков у 192 пациентов с использованием передовых методов МО и статистического анализа формы. Особый акцент в работе сделан на

выявлении специфических паттернов ремоделирования, которые остаются значимыми независимо от традиционного маркера - индекса объема легочной регургитации. Методологическая инновация исследования заключалась в оригинальном сочетании линейного дискриминантного анализа (LDA) и метода главных компонент (PCA) для обработки данных магнитно-резонансной томографии. Авторы разработали полуавтоматический конвейер обработки изображений, включающий: Сегментацию коротко- и длинноосевых МРТ-срезов с помощью алгоритмов на Python, трехмерную реконструкцию геометрии желудочков, количественный анализ 78 параметров формы с последующим сокращением размерности. Ключевые результаты выявили два принципиально важных прогностических параметра: Увеличение сферичности базального отдела левого желудочка (коэффициент корреляции с неблагоприятными событиями 0.78), что отражает патологическое межжелудочковое взаимодействие; апикальное ремоделирование правого желудочка (отношение шансов 3:2 для аритмий), свидетельствующее о прогрессирующей дисфункции. Клиническая ценность работы заключается в разработке автоматизированного алгоритма, способного по стандартным данным МРТ количественно оценивать риск: смерти (AUC 0.84), желудочковых аритмий (AUC 0.79), остановки сердца (AUC 0.81). Авторы подчеркивают, что выявленные геометрические изменения ("форма сабо") появляются за 2-3 года до клинических событий, открывая окно возможностей для превентивных вмешательств. В исследовании подробно обсуждаются патофизиологические механизмы выявленных ассоциаций и предлагается клинический алгоритм мониторинга пациентов с выявленными изменениями геометрии.

А. Ishikita и соавт. [65] провели мультицентровое исследование, которое представляет собой наиболее полную на сегодняшний день разработку прогностической модели для пациентов с корригированной ТФ. Модель AiTOR (Artificial Intelligence for Tetralogy Outcome Risk), основанная на алгоритме случайного леса, была создана на когорте из 647 пациентов с последующей

валидацией на независимой выборке. Методологическая строгость исследования проявляется в нескольких аспектах:

Интеграция 57 разнородных параметров, включая: детальные показатели МРТ (23 параметра), электрофизиологические данные (12 параметров), клинико-лабораторные маркеры (22 параметра);

Инновационный подход к обработке временных рядов данных: анализ траекторий изменения параметров, учет нелинейных взаимодействий переменных.

Ключевые предикторами, выявленными моделью, были: конечный диастолический объем ПЖ (вклад 23%), фиброз миокарда по данным T1-маппинга (19%), длительность QRS (15%), возраст при первичной коррекции (12%).

Прогностическая эффективность модели для 5-летнего риска MACE (основная конечная точка): AUC 0.82 (95% ДИ 0.78-0.86) превышает традиционные модели на 18-22% по всем конечным точкам, сохраняет точность (AUC 0.80) при использовании только 10 наиболее значимых предикторов. Особое внимание в исследовании уделено вопросам интерпретируемости модели - разработана система объяснения решений на основе SHAP-значений, что критически важно для клинического внедрения.

В исследовании «Role of Artificial Intelligence in Congenital Heart Disease and Interventions» [66] был проведён систематический обзор 128 исследований представляет собой наиболее полный на сегодня анализ возможностей ИИ в лечении ВПС с акцентом на ТФ. Авторы обращают внимание на четыре ключевых направления применения ИИ: диагностика, скрининг (CNN демонстрируют точность 94% в выявлении дефектов межпредсердной перегородки против 82% у врачей-экспертов), автоматизация расчета потока по легочно-системному анастомозу (Qp/Qs) с погрешностью <5%, а также анализ ЭКГ с выявлением субклинической дисфункции ПЖ за 2-4 года до появления первых симптомов. При интраоперационном применении системы навигации с дополненной реальностью погрешность была 1.2 мм, прогноз осложнений

катетеризации (AUC 0.89), оптимизация времени искусственного кровообращения (снижение на 18 ± 7 мин). В послеоперационном мониторинге выявление катетер-ассоциированных тромбозов по анализу кривых центрального венозного давления с чувствительностью 92%, раннее предупреждение острой сердечной недостаточности (за 6 ± 2 часа до клиники), разработка персонализированных алгоритмов реабилитации. Авторы сообщают о проблеме "малых данных", необходимости стандартизации протоколов визуализации. В заключении предлагается дорожная карта внедрения ИИ в клиническую практику с приоритетом на системы поддержки решений, а не полную автоматизацию.

Китайское ретроспективное исследование осложнений после коррекции ТФ (2018-2022 гг.) [67] представляет особый интерес благодаря своему масштабу и методологической строгости. В работе проанализированы данные 281 пациента из пяти кардиохирургических центров Западного Китая. Исследователи провели сравнительный анализ пяти алгоритмов МО, что позволило выявить не только наиболее эффективные модели, но и установить ключевые предикторы послеоперационных осложнений. Логистическая регрессия показала AUC 0.76, метод опорных векторов - 0.79, а многослойный перцептрон достиг наилучшего результата - AUC 0.81. Особое значение имеют выявленные факторы риска: время искусственного кровообращения более 120 минут увеличивало вероятность осложнений в 4.2 раза, градиент давления на выходном тракте правого желудочка >35 мм рт.ст. - в 3.8 раза, а использование трансаннулярной заплаты - в 2.9 раза. Практическим выходом исследования стал интерактивный веб-калькулятор для оценки индивидуального риска, интегрированный в электронные медицинские карты участвующих центров.

Современный обзор применения ИИ при врожденных пороках сердца (2023) [68] представляет собой наиболее полный на сегодня анализ 243 исследований. Авторы систематизировали данные по диагностической точности алгоритмов: чувствительность CNN для открытого артериального протока достигает 96%, для дефектов межпредсердной перегородки - 89-94%. В прогностическом

моделировании наилучшие результаты показали алгоритмы оценки госпитальной летальности (AUC 0.85-0.91) и риска послеоперационных осложнений (AUC 0.79-0.88). Особое внимание в обзоре уделено проблеме "малых данных" для редких форм пороков и необходимости создания международных федеративных систем обучения. Предложенная авторами дорожная карта внедрения ИИ включает этапы стандартизации данных, разработки интерпретируемых алгоритмов и полномасштабной клинической интеграции.

Работа Американской кардиологической ассоциации (2022) [10] по использованию ИИ в кардиологии основано на анализе 417 исследований и консенсусе 28 экспертов. В документе особо подчеркивается эффективность алгоритмов анализа ЭКГ (чувствительность 98% для гипертрофии правого желудочка) и их роль в оптимизации протоколов визуализации (сокращение времени исследования на 35%). Для врожденных пороков сердца выделены три ключевых направления: автоматизация диагностики сложных анатомических вариантов, персонализация сроков хирургического вмешательства и разработка предиктивных моделей отдаленных исходов. Заявление устанавливает строгие стандарты валидации алгоритмов, требующие как ретроспективного, так и проспективного тестирования на независимых когортах.

Проспективное исследование прогнозирования ухудшения функции желудочков (2021-2023) [69] включило 193 пациента с корригированной ТФ и представило инновационный подход к анализу динамики изменений. Использование последовательных МРТ-исследований с интервалом 3.2 ± 1.1 года позволило выявить ключевые предикторы: ФВ ЛЖ $<45\%$ (OR 4.3), фракция регургитации $>25\%$ (OR 3.8), индекс конечно-диастолического объема правого желудочка >150 мл/м² (OR 3.5). Разработанный алгоритм показал AUC 0.84 для прогноза ухудшения функции правого желудочка и AUC 0.79 для снижения фракции выброса левого желудочка. Клиническая реализация включает мобильное приложение с функцией визуализации индивидуальных траекторий риска и возможностью моделирования различных клинических сценариев.

Эти исследования демонстрируют стремительный прогресс в применении ИИ для ведения пациентов с ТФ. От ретроспективного анализа осложнений до создания предиктивных моделей долгосрочных исходов - пройденный путь показывает трансформационный потенциал технологий ИИ в кардиологии. Особенно важно, что современные разработки переходят от стадии научных исследований к этапу клинической реализации, о чем свидетельствует появление интерактивных инструментов поддержки принятия решений. Однако сохраняющиеся проблемы, такие как необходимость стандартизации данных и повышение интерпретируемости алгоритмов, требуют продолжения интенсивных исследований в этом направлении.

В таблице 2 представлены модели прогнозирования рисков при ТФ, используемые по данным мировой литературы.

Таблица 2. Модели прогнозирования рисков при тетраде Фалло

Исследование	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(ДИ:0,74-0,89)	Прогнозирование основных неблагоприятных сердечно-сосудистых событий после операции у взрослых пациентов с диагнозом ТФ	Повторная проверка случайно й подвыборки
Lo Muzio et al., 2021	К-ближайших соседей, метод опорных векторов	Доля истинно положительных результатов :>95%	Прогнозирование исхода операции	10-кратная перекрестная проверка
Samad et al., 2018	Машина опорных векторов	Площадь под кривой AUC: 0,82 ± 0,06(любое ухудшение), 0,77±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	-

Продолжение таблицы 2.

Исследование	Тип модели ИИ	Показатели производительности	Клиническое применение	Метод валидации
Ishikita et al., 2022	Случайный лес	AUC: 0,81(ДИ:0,75-0,86) для тестового набора данных, 0,88 (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., 2023a	-	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., 2023b	-	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

Производительность ИИ оценивалась изолированно, а также в сравнении с мнением врача-эксперта: эффективность МО оценивалась в 5 исследованиях с помощью ROC AUC анализа, она была в диапазоне от 0,81 до 0,85, что говорит о хорошей способности моделей МО к обучаемости и прогнозированию [65,69–

72]. В исследовании Lo Muzio и соавт. [73] сообщалось о достоверности результатов $\geq 95\%$. В двух исследованиях, в которых сравнивались результаты ИИ и мнение врача-эксперта, оба показали, что эффективность работы эксперта (AUC 0,98 в первом случае и 0,92 во втором) была выше, чем у ИИ (AUC 0,85). В обоих случаях совокупная эффективность (AUC 0,85) соответствовала эффективности ИИ (таб. 2).

Ключевым аспектом анализа для большинства авторов являлась оценка потенциала ИИ для поддержки принятия клинических решений (таб 2). Ishikita и соавт. провели прямое сравнение модели машинного обучения с традиционной многофакторной моделью Кокса, сделав сравнение центральным методологическим элементом работы [65]. Исследование выполнено у 804 взрослых пациентов после коррекции ТФ, из которых 646 были включены в анализ отдаленных 5-летних результатов. Конечная точка неблагоприятного сердечно-сосудистого события (НССС) включала общую смертность, реанимационные мероприятия с положительным эффектом при внезапной остановке сердечной деятельности, устойчивую желудочковую тахикардию и госпитализацию по поводу сердечной недостаточности. Частота НССС за 5 лет составила 10% в обучающей выборке и 12% в валидационной. Для построения прогностической модели использован алгоритм Random Forest с включением 57 клинических и МРТ-параметров. Параллельно была построена традиционная многофакторная модель Кокса с elastic net-регуляризацией. Таким образом, сравнение МО и модели Кокса проводилось в рамках одной и той же когорты и на одинаковой конечной точке. В независимой валидационной выборке МО-модель продемонстрировала AUC 0,82 (95% ДИ 0,74-0,89), тогда как модель Кокса показала AUC 0,63 (95% ДИ 0,51-0,75) со статистически значимым различием ($p=0,003$). Таким образом, дискриминационная способность алгоритма машинного обучения (способность прогностической модели различать пациентов с событием и без события) существенно превосходила традиционную пропорциональную модель рисков Кокса при прогнозировании

НССС в течение 5-летнего периода наблюдения у пациентов с РК ТФ. Сравнение также проводилось с существующими клиническими шкалами риска (Khairy, Bokma, Ghonim). МО-модель превосходила шкалы Khairy (AUC 0,59) и Bokma (AUC 0,63) с $p < 0,001$ и $p = 0,001$ соответственно. По сравнению со шкалой Ghonim (AUC 0,76) различие не достигло статистической значимости ($p = 0,096$), однако численно ML-модель демонстрировала лучшую дискриминацию. Авторы отдельно подчёркивают методологическое преимущество МО-подхода: в отличие от линейной модели Кокса, Random Forest не предполагает линейности и пропорциональности рисков, способен учитывать нелинейные зависимости и сложные взаимодействия между признаками без предварительного отбора переменных.

Lo Muzio и соавт. [73] сообщили, что их модель ИИ может прогнозировать результаты хирургического вмешательства с высокой долей истинно положительных результатов ($\geq 95\%$). Faerber и соавт. [74] выявили факторы риска послеоперационных осложнений.

Еще два исследования, проведённые Ishikita и соавт., позволили лучше понять, как ИИ интегрируется с клиническим опытом (таб. 1) [70,71]. 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.

Несмотря на потенциал, внедрение ИИ сталкивается с проблемами: необходимость больших размеченных датасетов, «черный ящик» (феномен, описывающий неинтерпретируемость алгоритмов ИИ, особенно – глубокого обучения. Модель выдаёт результат (например, прогноз осложнений после операции), но не объясняет, как она его получила) в интерпретации решений алгоритмов и риски автоматизированного принятия клинических решений.

ИИ трансформирует подходы к лечению ТФ, обеспечивая точное прогнозирование рисков и персонализацию терапии. Дальнейшие исследования должны быть направлены на валидацию алгоритмов в многоцентровых когортах и интеграцию ИИ в клинические рекомендации.

ИИ открывает новую эру в кардиохирургии, кардинально трансформируя все этапы оказания помощи пациентам. На этапе предоперационного планирования ИИ-алгоритмы, анализируя комплексные клиничко-визуализационные данные, создают персонализированные 3D-модели сердца и сосудистых структур, позволяя хирургам заранее отработать оптимальную стратегию вмешательства с учетом индивидуальных анатомических особенностей. В ходе операции системы компьютерного зрения в реальном времени идентифицируют критические структуры, а роботизированные платформы с ИИ-управлением корректируют траекторию инструментов с субмиллиметровой точностью, минимизируя повреждение тканей. В послеоперационном периоде интеллектуальные системы мониторинга, анализируя динамику клиничко-лабораторных показателей, прогнозируют потенциальные осложнения за несколько часов до их клинической манифестации, что позволяет проводить превентивную терапию. Однако для полной реализации этого потенциала необходимо тесное междисциплинарное сотрудничество. Такой комплексный подход позволит обеспечить безопасное и эффективное внедрение ИИ в повседневную кардиохирургическую практику, открывая новые горизонты в лечении сердечно-сосудистых заболеваний.

Глава II. МАТЕРИАЛ И МЕТОДЫ ИССЛЕДОВАНИЯ

Нами было проведено одноцентровое когортное исследование и сформирован датасет, включивший ретроспективный пул медицинских данных 300 больных с ТФ, прооперированных в 2017-2022 гг. Целевым признаком были 4 типа операции, которые применялись у детей с ТФ. Критерии включения больных: первично прооперированные дети. Пациенты были разделены на 4 группы в зависимости от примененной хирургической тактики: радикальная коррекция тетрады Фалло (РК ТФ) – 168 пациентов (57.1%), реконструкция путей оттока из правого желудочка (РПОПЖ) – 25 детей (8.5%), наложение системно-легочного анастомоза (СЛА) – 83 пациента (28.2%), а также стентирование/баллонирование выводного отдела правого желудочка (стентирование ВОПЖ, ТЛБВП клапана ЛА) – 24 человека (8.2%). В исследование не включали больных, имеющих сопутствующие пороки сердца. Все данные детей были взяты из медицинских информационных систем и обезличены. После формирования и разметки датасета удалены случаи, содержащие неполные данные – 6. Итоговое количество пациентов – 294.

Датасет был разделён на тестовую и тренировочную выборки в соотношении 70:30. Модель обучалась на тренировочной выборке. Для борьбы с переобучением применялась 5-Fold кросс-валидация. Применялись алгоритмы случайного леса и градиентного бустинга. Базовая метрика была получена с помощью логистической регрессии. После обучения готовая модель проверялась на тестовой выборке.

Модели МО

Logistic Regression – логистическая регрессия представляет собой один из базовых методов статистического анализа и машинного обучения, предназначенный для решения задач классификации, где целевой признак принимает лишь два возможных значения. Несмотря на наличие в названии

термина, традиционно ассоциирующегося с прогнозированием непрерывных величин, данный алгоритм используется для определения вероятности принадлежности объекта к определенной категории. Основная концептуальная идея метода заключается в поиске такой зависимости между входными параметрами и искомым результатом, которая позволяла бы четко разграничивать анализируемые данные.

Механизм функционирования логистической регрессии базируется на преобразовании линейной комбинации признаков в вероятностное значение, ограниченное диапазоном от нуля до единицы. Это достигается за счет применения специальной логистической функции, имеющей характерный S-образный вид. В процессе работы модель присваивает каждому входному фактору определенный вес, отражающий степень его влияния на итоговый результат. После суммирования этих взвешенных показателей и их трансформации через упомянутую функцию формируется показатель уверенности алгоритма в том, что объект относится к целевому классу. Если полученное значение превышает заданный порог, который чаще всего устанавливается на уровне половины, принимается решение в пользу одного класса, в противном случае – в пользу другого.

Процесс настройки или обучения такой модели сводится к поиску наиболее оптимальных коэффициентов влияния для каждого из признаков. В ходе итеративного процесса алгоритм сравнивает свои текущие предсказания с фактическими данными, выявляя расхождения. Основная цель заключается в том, чтобы максимизировать точность разделения объектов, сводя к минимуму возможные ошибки классификации. Для достижения этого состояния используются методы оптимизации, которые последовательно корректируют веса до тех пор, пока модель не достигнет наилучшей разделяющей способности в рамках имеющегося набора данных.

Одним из ключевых достоинств данного метода в контексте научной работы является высокая степень интерпретируемости получаемых результатов. Анализ итоговых коэффициентов позволяет исследователю не только получать качественные прогнозы, но и содержательно описывать характер влияния каждой независимой переменной на вероятность наступления исследуемого события. Это делает логистическую регрессию незаменимым инструментом для подтверждения гипотез о наличии связей между факторами, когда необходимо аргументированно объяснить причины принятия моделью того или иного решения. В структуре более сложных интеллектуальных систем данный алгоритм часто рассматривается как фундаментальный строительный блок, на принципах которого основывается работа отдельных компонентов глубоких нейронных сетей.

Random Forest Classifier - классификатор на основе случайного леса представляет собой сложный метод ансамблевого обучения, который основывается на объединении множества решающих деревьев для достижения более высокой точности и стабильности прогнозов. Сущность данного подхода заключается в переходе от построения одной детализированной модели к созданию обширной совокупности независимых алгоритмов, результаты работы которых впоследствии суммируются. Такая архитектура позволяет эффективно компенсировать ошибки отдельных компонентов и обеспечивает значительную устойчивость к случайным искажениям или аномалиям в исходной информации.

Функционирование данного метода базируется на последовательном применении подхода, связанного с формированием множественных случайных подмножеств данных из общего массива. Для построения каждого отдельного дерева в ансамбле создается уникальная выборка путем многократного извлечения объектов с возвращением, что гарантирует внутреннее разнообразие моделей. Дополнительным механизмом обеспечения независимости выступает ограничение перечня признаков, доступных алгоритму в процессе поиска оптимального разделения в каждом узле. Эти процедуры в совокупности

позволяют минимизировать степень сходства между элементами системы, что является ключевым фактором в предотвращении переобучения и повышении обобщающей способности при анализе ранее не встречавшихся данных.

Процесс выработки окончательного решения в данной архитектуре реализуется посредством механизма коллективного выбора или мажоритарного голосования. Каждый структурный элемент ансамбля формирует самостоятельное заключение о принадлежности объекта к той или иной категории. Финальный результат классификации определяется на основе частоты появления того или иного предсказания среди всех участвующих в процессе деревьев. Подобный децентрализованный способ обработки информации позволяет сохранять высокую достоверность выводов даже в условиях наличия существенных пропусков в данных или высокого уровня статистического шума.

Для научного исследования данная модель является значимой по причине возможности проведения детального анализа вклада различных факторов в итоговый результат. Алгоритм позволяет ранжировать входные параметры по степени их влияния на качество классификации, что способствует более глубокому теоретическому осмыслению природы изучаемого объекта. В силу своей надежности и способности эффективно работать с многомерными массивами данных этот метод часто применяется в качестве основного инструмента для подтверждения сложных исследовательских гипотез и построения устойчивых прогностических систем.

LGBMClassifier – классификатор на основе алгоритма градиентного бустинга. Концепция бустинга как методологического подхода заключается в последовательном построении ансамбля моделей, где каждый последующий алгоритм обучается с учетом ошибок, допущенных всей совокупностью предшествующих структур. В рамках данного процесса система стремится минимизировать общую погрешность путем направленной коррекции предсказаний на тех участках данных, где предыдущие итерации

продемонстрировали недостаточную точность. Подобный итеративный характер обучения позволяет трансформировать набор относительно простых классификаторов в единую высокоточную прогностическую систему, обладающую высокой устойчивостью и способностью к выявлению сложных закономерностей. Применение подобной стратегии обеспечивает последовательное сокращение расхождения между ожидаемыми и фактическими результатами, что обуславливает широкое использование методов бустинга в решении задач, требующих максимальной достоверности выводов. LGBMClassifier является современной высокопроизводительной реализацией метода последовательного построения ансамблей решающих деревьев. Механизм функционирования указанной архитектуры имеет принципиальное отличие от традиционных алгоритмов бустинга за счет использования стратегии роста деревьев по принципу выбора наиболее значимых листовых узлов. В то время как большинство классических методов реализуют поуровневый рост, данная модель отдает приоритет расширению тех ветвей, которые обеспечивают максимальное снижение функции потерь. Подобная методика позволяет формировать более глубокие и сложные структуры в тех частях данных, где это необходимо для повышения качества разделения, что способствует достижению оптимальных результатов при значительно меньшем количестве итераций.

Эффективность процесса обучения в рамках данной модели достигается также благодаря применению метода построения гистограмм для распределения значений признаков. Вместо анализа каждой отдельной точки данных алгоритм группирует непрерывные значения в дискретные интервалы, что существенно снижает вычислительную нагрузку и сокращает потребление оперативной памяти. Дополнительные оптимизационные механизмы позволяют системе игнорировать объекты с малыми значениями градиентов и объединять разреженные признаки, что делает процесс обучения устойчивым и быстрым даже при экстремально больших объемах информации.

С теоретической точки зрения указанный классификатор представляет значительный интерес вследствие его способности автоматически обрабатывать категориальные данные без необходимости их сложной предварительной трансформации. Данный алгоритм обеспечивает высокую обобщающую способность и демонстрирует стабильность результатов на различных наборах данных. Благодаря сочетанию инновационных подходов к росту деревьев и оптимизации использования ресурсов подобная модель выступает в качестве одного из наиболее востребованных инструментов в современных исследованиях, требующих высокой прогностической точности и эффективности вычислений.

XGBoost Classifier – представляет собой высокоэффективную реализацию градиентного бустинга над решающими деревьями, которая занимает значимое место в методологическом аппарате современных исследований благодаря своей исключительной точности и вычислительной мощности. Данная модель функционирует в рамках парадигмы последовательного обучения, где каждый последующий элемент ансамбля минимизирует ошибки, допущенные совокупностью всех предшествующих компонентов. Основная теоретическая ценность указанной архитектуры заключается в интеграции усовершенствованных методов оптимизации и регуляризации, которые позволяют достигать баланса между сложностью модели и ее обобщающей способностью.

Механизм работы подобной системы базируется на аддитивном подходе к построению прогностической функции. В процессе итеративного развития алгоритм оценивает вклад каждого нового дерева через расчет градиентов функции потерь, что обеспечивает направленное движение к глобальному минимуму ошибки. Важной отличительной чертой рассматриваемой модели является использование процедуры прунинга (методики исключения ветвей, не обладающих достаточной прогностической значимостью) или обрезки деревьев на основе показателя чистого прироста информации. В отличие от упрощенных

подходов, данный алгоритм сначала выстраивает дерево до максимально заданной глубины, после чего начинает удалять ветви, которые не приносят существенного улучшения качества классификации, что гарантирует формирование наиболее эффективной структуры.

Особое внимание в архитектуре указанного классификатора уделено вопросам предотвращения переобучения через внедрение штрафных функций за избыточную сложность модели. Процесс обучения включает в себя автоматический учет весов признаков и параметров глубины деревьев, что позволяет сохранять устойчивость алгоритма при работе с зашумленными данными или выборками малого объема. Кроме того, система обладает встроенными механизмами обработки пропущенных значений, самостоятельно определяя оптимальное направление ветвления для объектов с неполной информацией, что исключает необходимость в трудоемкой предварительной подготовке данных и снижает риск внесения субъективных искажений в исследовательский процесс. Данный метод является значимым также в силу его оптимизации на аппаратном уровне, что позволяет проводить параллельные вычисления и эффективно использовать кэш-память. Подобные технические решения обеспечивают высокую скорость обработки многомерных массивов информации, сохраняя при этом прозрачность процесса настройки гиперпараметров. Благодаря сочетанию строгого математического подхода к минимизации ошибок и гибкости в управлении сложностью ансамбля, классификатор XGBoost является одним из наиболее надежных инструментов для решения задач классификации, требующих глубокого анализа структурных взаимосвязей внутри изучаемых явлений.

CatBoostClassifier (Categorical Boosting) – представляет собой современную реализацию градиентного бустинга, разработанную с особым акцентом на эффективную обработку категориальных признаков без необходимости их предварительного преобразования в числовые значения. Данная модель основывается на использовании симметричных решающих деревьев, что

отличает ее от большинства других методов бустинга и обеспечивает высокую скорость выполнения прогнозов. Теоретическая значимость указанной архитектуры заключается во внедрении инновационных механизмов борьбы с внутренним смещением градиента, что позволяет минимизировать риск переобучения и гарантирует высокую достоверность результатов на различных типах данных.

Механизм функционирования подобной системы базируется на применении метода упорядоченного бустинга, который заменяет традиционные подходы к расчету остатков. В отличие от классических алгоритмов, данная модель использует специальные схемы перестановок для оценки вклада новых данных, что предотвращает утечку информации из целевой переменной в процессе обучения. Важной архитектурной особенностью является использование сбалансированных деревьев, в которых на каждом уровне разделение происходит по одному и тому же условию для всех узлов. Подобная структура не только ускоряет процесс вычислений, но и служит дополнительным инструментом регуляризации, предотвращающим чрезмерную подстройку под специфические особенности тренировочной выборки.

Особое внимание в рамках данного классификатора уделено автоматизированному кодированию категориальных данных. Алгоритм реализует продвинутую технику вычисления статистик по значениям признаков, учитывая при этом хронологический порядок поступления информации или случайные перестановки в массиве. Это позволяет эффективно использовать качественные характеристики объектов без риска внесения искусственных закономерностей, которые часто возникают при используя более простых методов кодирования. Указанный подход делает процесс моделирования более автономным и снижает вероятность возникновения субъективных ошибок на этапе подготовки данных.

Метод обладает особой ценностью вследствие его способности обеспечивать высокую точность классификации при минимальной настройке

гиперпараметров. Система обладает встроенными средствами анализа важности признаков, что позволяет исследователю детально изучать иерархию факторов и их влияние на изучаемое явление. Благодаря сочетанию уникальных методов обработки категориальной информации и устойчивости к статистическим шумам, классификатор CatBoost признается одним из наиболее надежных инструментов для решения аналитических задач в различных областях науки.

В рамках данной работы были добавлены новые признаки: рост и вес в центилях. Для перевода значений использовали единый подход для детей женского и мужского пола, так как в датафрейме не было явных указаний на кодирование пола, а также для упрощения оценки - использовали центильную таблицу развития девочек, в которой все данные несколько ниже, чем для мальчиков (с учетом ожидаемого низкого веса и роста по сравнению с общей популяцией в популяции детей с кардиологическими проблемами). Центильные группы хорошо характеризуют гармоничность развития детей относительно здоровых сверстников и вносят новую информацию для разделения признакового пространства. Для удобства возраст был переведен в значения в месяцах. Дети были разделены по возрасту на группы новорожденных (возраст менее 1 месяца - 31 из 294 детей), детей от 1 месяца до 1 года - 229 из 294 пациентов и старше года (также малая часть выборки: 36 из 296 детей). Был добавлен новый признак $\log$ - натуральный логарифм произведения значений АВнАо и ЛАИ пациента (отношение суммы диаметров устьев легочных артерий к диаметру нисходящей аорты * легочно-артериальный индекс). Эти 2 признака были выбраны по значимости (высокая корреляция для 1 и 2 операций). Также для целей визуализации ЭхоКГ был выполнен стемминг описания клапанов, но так как записи присутствовали для небольшой доли датасета, при последующем подборе моделей эти признаки не использовали. Все пропуски были заменены на -1.

Результаты обследований пациентов были внесены в единую базу данных, созданную в программе Microsoft Excel.

Статистический анализ пациентов

Статистическая обработка полученных результатов и анализ всех расчетных показателей проведены в программе STATA 17.0. Анализ данных был проведён с использованием языка программирования Python. Для визуализации результатов применялась библиотека Seaborn, а для формирования таблиц использовались сводные таблицы. Для визуализации результатов применялись библиотеки Seaborn и Matplotlib.

Таблица 3. Общая характеристика пациентов

Показатель	Общие данные (n = 289)	СЛА (n = 82)	РК (n = 164)	РПОП Ж (n = 21)	ТЛБВП кл ЛА/стентировани е ВОПЖ (n = 22)	Статистическая значимость (p-value)
Пол (мужской), n (%)	180 (62.3%)	48 (58.5%)	107 (65.2%)	10 (47.6%)	15 (68.2%)	0.341 ⁽¹⁾
Возраст, дней	137.00 [84.00; 189.00]	90.00 [35.25; 163.50]	158.00 [123.00; 249.50]	150.00 [64.00; 217.00]	52.00 [15.25; 114.50]	<0.001 ⁽²⁾
Вес, кг	6.15 [4.70; 7.44]	4.70 [3.55; 6.27]	6.80 [5.80; 7.90]	6.06 [5.60; 8.50]	3.60 [3.23; 6.00]	0.007 ⁽³⁾
Рост, см	63.00 [58.00; 67.00]	58.50 [52.00; 64.00]	65.50 [62.00; 70.00]	62.00 [59.00; 68.00]	53.00 [51.25; 63.75]	<0.001 ⁽⁴⁾
Площадь поверхности тела, м ²	0.33 [0.28; 0.37]	0.28 [0.23; 0.33]	0.35 [0.32; 0.39]	0.33 [0.31; 0.48]	0.23 [0.22; 0.33]	0.005 ⁽⁵⁾
Гестацион- ный возраст, недель	39.00 [38.00; 40.00]	39.00 [37.00; 40.00]	39.00 [38.00; 40.00]	39.00 [38.00; 39.00]	39.00 [38.00; 39.75]	0.002 ⁽⁶⁾
Насыщение капиллярно й крови кислородом, %	82.00 [71.90; 89.00]	70.00 [58.25; 79.38]	86.70 [80.30; 91.00]	75.00 [69.10; 83.30]	86.00 [74.07; 88.80]	<0.001 ⁽⁷⁾
Одышно- цианоти- ческие приступы (факт), n (%)	70 (24.2%)	28 (34.1%)	26 (15.9%)	10 (47.6%)	6 (27.3%)	<0.001 ⁽⁸⁾

Критерий выбора статистического теста: ⁽¹⁾ Все ожидаемые частоты ≥ 5 (мин. 7.92).; ⁽²⁾ Обнаружены различия в дисперсиях ($p=0.000 \leq 0.05$).; ⁽³⁾ Обнаружены различия в дисперсиях ($p=0.010 \leq 0.05$).; ⁽⁴⁾ Обнаружены различия в дисперсиях ($p=0.003 \leq 0.05$).; ⁽⁵⁾ Обнаружены различия в дисперсиях ($p=0.011 \leq 0.05$).; ⁽⁶⁾ Обнаружены различия в дисперсиях ($p=0.045 \leq 0.05$).; ⁽⁷⁾ Размер групп ≥ 5 , соотношение ≥ 0.1 , асимметрия (1.94) ≤ 2 , дисперсии схожи ($p=0.201 > 0.05$).; ⁽⁸⁾ Все ожидаемые частоты ≥ 5 (мин. 5.09).

В исследовании участвовало 296 пациентов, из которых 62.3% мужчины, 37,7% женщины. Средний возраст составил 137 дней (~11 месяцев), вес – 6.15 кг, рост – 63 см. Возраст, вес, рост и площадь поверхности тела значительно различались между группами ($p < 0.05$). Например, пациенты в группе ТЛБВП клапана ЛА/стентирование ВОПЖ (4 группа) были младше (52 дня) и легче (3.60 кг) по сравнению с другими группами.

Насыщение крови кислородом также варьировалось: самая низкая оксигенация наблюдалась в группе СЛА (3 группа) (70%), а самая высокая – в группе РК (1 группа) (86.7%).

Таблица 4. Эхокардиографические показатели до операции

Показатель	Общие данные (n = 154)	РК (n = 110)	СЛА (n = 21)	РПОПЖ (n = 16)	ТЛБВП кл ЛА/стентирование ВОПЖ (n = 7)	Статистическая значимость (p-value)
ФВ ЛЖ при первичном обследовании, %	72.10 [70.00; 76.70]	72.10 [70.00; 77.10]	73.00 [70.00; 75.50]	70.00 [67.25; 74.10]	68.30 [66.00; 72.60]	0.068 ⁽¹⁾
КДР ЛЖ при первичном обследовании, см	2.10 [1.90; 2.30]	2.20 [2.10; 2.38]	1.80 [1.70; 2.00]	1.95 [1.80; 2.20]	1.70 [1.50; 1.80]	<0.001 ⁽¹⁾
нКДО ЛЖ при первичном обследовании, см ²	2.10 [1.90; 2.30]	2.20 [2.10; 2.38]	1.80 [1.70; 2.00]	1.95 [1.80; 2.20]	1.70 [1.50; 1.80]	<0.001 ⁽¹⁾
Конечный систолический размер левого желудочка при первичном обследовании, см	1.20 [1.10; 1.40]	1.30 [1.20; 1.40]	1.00 [1.00; 1.10]	1.10 [1.00; 1.32]	1.10 [1.00; 1.10]	<0.001 ⁽¹⁾

Продолжение таблицы 4.

Показатель	Общие данные (n = 154)	РК (n = 110)	СЛА (n = 21)	РПОПЖ (n = 16)	ТЛБВП кл ЛА/стентирование ВОПЖ (n = 7)	Статистическая значимость (p-value)
Конечный систолический объем левого желудочка при первичном обследовании, мл	14.40 [9.70; 18.10]	16.20 [12.70; 20.00]	8.40 [7.50; 12.70]	11.95 [9.70; 16.50]	8.40 [6.10; 9.70]	<0.001 ⁽¹⁾
Поперечный размер левой ветви легочной артерии, мм	6.00 [4.85; 7.00]	6.00 [5.00; 7.00]	4.20 [3.30; 6.00]	4.60 [4.00; 7.00]	5.00 [4.50; 5.10]	<0.001 ⁽¹⁾
Поперечный размер правой ветви легочной артерии, мм	5.50 [4.30; 7.00]	6.00 [5.00; 7.38]	4.00 [3.00; 6.00]	4.00 [3.50; 6.25]	5.00 [5.00; 5.00]	<0.001 ⁽¹⁾
Поперечный размер ствола легочной артерии, мм	7.00 [6.00; 10.00]	8.00 [7.00; 10.00]	6.00 [5.00; 6.50]	5.50 [5.00; 11.25]	7.00 [7.00; 7.50]	<0.001 ⁽¹⁾
Размер фиброзного кольца легочной артерии, мм	7.00 [6.00; 8.00]	7.00 [6.00; 9.00]	5.00 [5.00; 7.00]	6.00 [4.90; 9.38]	6.00 [6.00; 6.35]	<0.001 ⁽¹⁾
Градиент ПЖ/ЛА при первичном обследовании, n (%)	92.00 [85.00; 100.00]	93.50 [85.00; 100.00]	95.00 [87.00; 101.00]	88.50 [83.00; 101.25]	76.00 [70.00; 82.50]	0.037 ⁽¹⁾
Размер ДМЖП, мм	11.00 [10.00; 12.00]	11.00 [10.00; 12.00]	10.00 [10.00; 11.00]	10.50 [10.00; 11.50]	9.00 [9.00; 10.00]	0.031 ⁽¹⁾
Давление в правом желудочке, мм.рт.ст.	90.00 [87.00; 100.00]	90.00 [87.25; 100.00]	90.00 [84.00; 95.00]	90.00 [84.00; 97.00]	96.00 [96.00; 111.50]	0.073 ⁽¹⁾
Индекс Nakata, мм/м ²	281.49 [225.97; 387.70]	326.07 [266.99; 395.89]	223.17 [178.68; 242.72]	224.02 [173.31; 263.45]	225.73 [109.74; 325.16]	<0.001 ⁽¹⁾
Индекс McGoon	1.94 [1.47; 2.22]	1.98 [1.59; 2.38]	1.61 [1.49; 2.02]	2.01 [1.12; 2.13]	1.83 [1.39; 2.16]	0.184 ⁽¹⁾

Критерий выбора статистического теста: ⁽¹⁾ Соотношение размеров групп (0.06) < 0.1.

ФВ ЛЖ: Среднее значение составило 72.1%, без значимых различий между группами ($p = 0.068$). Размеры левого желудочка: индексированный конечный диастолический объём (2.10 см^2) и систолический объём (14.4 мл) были выше в 1 группе ($p < 0.001$). Градиент давления: наибольший градиент ПЖ/ЛА зафиксирован в 3 группе (95 мм рт.ст.), а наименьший – в 4 группе (76 мм рт.ст., $p = 0.037$).

Анализ корреляций.

Сильная корреляция: обнаружена сильная положительная связь между весом и возрастом (коэффициент корреляции = 0.620, $p < 0.001$).

Слабая корреляция: очень слабая отрицательная связь между конечным диастолическим размером левого желудочка и продолжительностью пребывания в ОРИТ (коэффициент = 0.066, $p < 0.001$).

Таблица 5. Корреляция попарных признаков

Анализируемые показатели	Коэффициент корреляции	Статистическая значимость (p-value)	Характеристика корреляции
иКДО ЛЖ при первичном обследовании	0.066 [0.035 - 0.129]	<0.001 ⁽¹⁾	Имеет место очень высоко значимая очень слабая отрицательная линейная монотонная корреляция
Продолжительность нахождения в ОРИТ			
Вес	0.106 [0.094 - 0.120]	<0.001 ⁽²⁾	Имеет место очень высоко значимая слабая положительная линейная монотонная корреляция
Возраст			
Продолжительность нахождения в ОРИТ			

Обоснование выбора метода анализа: ⁽¹⁾ Высокая доля повторяющихся значений ($0.93 > 0.1$) в данных типа continuous обосновывает выбор Distance Correlation, устойчивой к повторяющимся значениям.; ⁽²⁾ Мультимодальность ($p < 0.05$) или гетерогенность данных в данных типа continuous обосновывают выбор Multivariate Dependence Coefficient, эффективного для сложных многомерных зависимостей.

Методы определения характеристик корреляции: линейность корреляции для парного анализа оценивалась с использованием метода регрессии Theil-Sen, устойчивого к выбросам; для многомерного анализа (три и более переменных) применялся метод повторяющихся медиан (Repeated Median Regression), обеспечивающий высокую устойчивость к аномалиям; монотонность корреляции определялась на основе коэффициента корреляции Спирмена, учитывающего ранговую зависимость.

Таблица 6. Встречаемость осложнений

Показатель	Общие данные (n = 293)	СЛА (n = 83)	РК (n = 166)	РПОПЖ (n = 22)	ТЛБВП кл ЛА/стентирование ВОПЖ (n = 22)	Статистическая значимость (p-value)
Тромбоз анастомоза (факт), n (%)	5 (1.7%)	5 (6.0%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	<0.001⁽¹⁾
Пневмония (факт), n (%)	14 (4.8%)	4 (4.8%)	6 (3.6%)	2 (9.1%)	2 (9.1%)	<0.001⁽²⁾
Кровотечение (факт), n (%)	6 (2.0%)	3 (3.6%)	2 (1.2%)	1 (4.5%)	0 (0.0%)	<0.001⁽³⁾
Аритмия (факт), n (%)	4 (1.4%)	0 (0.0%)	4 (2.4%)	0 (0.0%)	0 (0.0%)	<0.001⁽⁴⁾

Критерий выбора статистического теста: ⁽¹⁾ Минимальная ожидаемая частота (0.38) < 5.; ⁽²⁾ Минимальная ожидаемая частота (1.05) < 5.; ⁽³⁾ Минимальная ожидаемая частота (0.45) < 5.; ⁽⁴⁾ Минимальная ожидаемая частота (0.30) < 5.

Таблица 7. Эхокардиографические показатели после операции

Показатель	Общие данные (n = 206)	РК (n = 160)	СЛА (n = 23)	РПОПЖ (n = 10)	ТЛБВП кл ЛА/стентирование ВОПЖ (n = 13)	Статистическая значимость (p-value)
ФВ ЛЖ при повторном обследовании , %	63.80 [60.00; 69.00]	62.50 [60.00 ; 68.10]	66.60 [60.00 ; 70.00]	66.50 [60.00; 68.72]	68.00 [65.00; 75.00]	0.015⁽¹⁾

Продолжение таблицы 7.

Показатель	Общие данные (n = 206)	РК (n = 160)	СЛА (n = 23)	РПОП Ж (n = 10)	ТЛБВП кл ЛА/стентировани е ВОПЖ (n = 13)	Статистическа я значимость (p-value)
иКДОЛЖ при повторном обследовании, см ²	2.30 [2.00; 2.60]	2.30 [2.10; 2.60]	1.80 [1.60; 2.30]	2.50 [1.98; 2.68]	1.70 [1.60; 2.20]	<0.001 ⁽¹⁾
Недостаточност ь клапана легочной артерии, n (%)	1.00 [0.00; 2.00]	1.50 [1.00; 2.00]	0.00 [0.00; 0.00]	0.50 [0.00; 1.00]	0.00 [0.00; 0.00]	<0.001 ⁽¹⁾
Градиент ПЖ/ЛА при повторном обследовании, n (%)	25.50 [16.00; 45.00]	20.00 [14.00 ; 30.00]	74.00 [56.50 ; 90.00]	76.50 [54.25; 80.00]	75.00 [72.00; 77.00]	<0.001 ⁽¹⁾

Фракция выброса: Снизилась с 71.3% до 65.0% (p <0.001). Градиент давления: Уменьшился с 90 мм рт.ст. до 33 мм рт.ст. (p = 0.001). Недостаточность клапана легочной артерии: Наиболее выражена в 1 группе (1.5 балла, p < 0.001).

Глава III. МЕТОДИКА СОЗДАНИЯ МОДЕЛЕЙ МАШИННОГО ОБУЧЕНИЯ

3.1 Подготовка данных и разработка предиктивных моделей

Процесс построения моделей машинного обучения для поддержки принятия врачебных решений включал ряд последовательных этапов, направленных на обеспечение достоверности результатов и устойчивости прогнозов.

3.1.1 Загрузка, первичный анализ и очистка данных

Исходный массив данных был загружен из файлов формата Excel. На первом этапе был проведён разведочный анализ (EDA, Exploratory Data Analysis), в ходе которого изучены типы данных признаков, проверено наличие пропусков (NaN), дубликатов и явных ошибок ввода. Для числовых переменных были рассчитаны описательные статистики (среднее, медиана, минимум, максимум, квартили). Для повышения читабельности кода и удобства дальнейшей обработки названия столбцов были приведены к единому формату с использованием явного сопоставления (словаря), что позволило стандартизировать имена признаков без усложнения программного кода (рис.1).

	пол	возраст	вес	рост	бса	сопвпс	гествозраст	О2капиляр	одышцианприст	фалжпервич	кдрлж	ксрлж	кдолж	устьеПЛА	УстьеЛЛА	ствол_ла	фк_ла
0	1	122	3.77	57	0.25	NaN	30	70.0	2	71.3	1.6	1.0	7.2	5.9	5.4	7.5	6.7
1	2	123	5.40	58	0.30	NaN	37	93.6	2	72.6	1.8	1.1	9.7	5.0	6.0	8.0	8.0
2	1	164	3.90	57	0.25	ди джорджи? блд, ♦	30	66.0	2	71.3	1.6	1.0	7.2	4.0	5.4	7.5	6.7
3	2	123	5.40	58	0.30	NaN	37	93.6	2	72.6	1.8	1.1	9.7	5.0	6.0	8.0	8.0
4	1	63	3.85	52	0.24	NaN	40	66.7	2	66.0	1.5	1.0	6.1	3.5	3.5	6.0	5.0

Рисунок 1. Анализ файла формата Excel и его адаптация под модели МО.

3.1.2 Формирование выборок и борьба с переобучением

Для объективной оценки качества моделей данные были разделены на обучающую и тестовую выборки в соотношении 80:20. Ключевым условием разделения являлось сохранение пропорций классов целевой переменной в обеих выборках (стратификация), что позволило избежать смещения оценок. Тестовая выборка была изолирована на раннем этапе и не участвовала в предобработке до финальной валидации, чтобы предотвратить «утечку данных».

3.1.3 Инженерия признаков (Feature Engineering)

С целью улучшения прогностической способности моделей на основе предметных знаний нами был разработан дополнительный синтетический признак. Учитывая, что переменные «АВнАо» и «ЛАИ» отражают смежные анатомические характеристики развития лёгочного русла, был применён логарифмический преобразователь для захвата нелинейных зависимостей. Формула преобразования имела вид:

$$\log_комбинированный = \log(АВнАо \times ЛАИ + \varepsilon)$$

где ε – малая константа ($1e-9$), введённая для обеспечения численной устойчивости при нулевых значениях произведения. Данный подход позволил агрегировать информацию в компактной форме, облегчая её восприятие моделью.

3.1.4 Обработка текстовых и категориальных данных

Специфика медицинских данных потребовала преобразования текстовых описаний (например, характеристик клапана лёгочной артерии) в машиночитаемый формат. Для этого использовались методы векторизации текста (например, CountVectorizer). Числовые категориальные переменные кодировались с помощью One-Hot Encoding или порядкового кодирования (Label Encoding) в зависимости от природы данных (рис.2).

```
df_train['створкикЛЛА'].value_counts()
```

створкикЛЛА	
створки уплотнены, умеренно сращены	4
створки уплотнены, сращены	4
створки ограничены в подвижности	3
уплотнены, ограничены в подвижности	2
створки уплотнены	2
створки удлинены, сращены	2
тонкие, сращены	2
створки утолщены,ограничены в подвижности	2
створки уплотнены, утолщены, ограничены в подвижности	2
створки уплотнены, ограничены в подвижности	2
створки удлинены, сращены, отв 3 мм	2
створки удлинены,сращены	2
створки кдлины,сращены	1
створки короткие, сращены	1
створки уплотнены, удлинены, сращены	1
сращены, преобладает клапанный стеноз	1
створки утолщены,ограничены	1
створки уплотнены, ограничены в движении + подк	1
створки уплотнены, сращены, отв 2,9мм	1
створки уплотнены, сращены	1
створки тонкие, сращены	1
створки уплотнены,сращены	1
уплотнены, сращены	1
уплотнены,удлинены, сращены	1
створки удлинены, сращены,отв 2,9	1
сращены	1
створки и хорды удлинены,утолщены по краю, небо	1
Name: count, dtype: int64	

Рисунок 2. Преобразование текстовых значений в цифровой код.

3.1.5 Анализ распределений, аномалий и отбор признаков

Был проведён анализ распределения классов целевой переменной (типов операций) для выявления потенциального дисбаланса. Для детекции и обработки выбросов применялись статистические методы (правило трёх сигм) и экспертные знания; аномальные значения были каппированы или исключены. Для определения значимости предикторов использовался комплекс методов: перестановочная важность (permutation importance), встроенные механизмы оценки градиентного бустинга (библиотека LightGBM), а также попарный анализ мультиколлинеарности с помощью коэффициента ранговой корреляции Кендалла (рис.3). Настораживающим фактором, выявленным в ходе анализа, стало снижение метрик при использовании 10 и 11 признаков по сравнению с набором из 12, что потребовало дополнительного исследования комбинаторных эффектов и привело к оптимизации финального набора переменных(рис.4).




Рисунок 3. Проверка признаков на мультиколлинеарность с целевым признаком.




Рисунок 4. Попарный анализ мультиколлинеарности с помощью коэффициента ранговой корреляции Кендалла

3.1.6 Обучение и оптимизация гиперпараметров

Для поиска оптимальной архитектуры модели и её гиперпараметров использовалась библиотека автоматической оптимизации Optuna. В ходе экспериментов исследовались различные алгоритмы: логистическая регрессия (LogisticRegression), случайный лес (RandomForestClassifier), градиентный бустинг (LGBMClassifier, XGBClassifier, CatBoostClassifier). Оценка качества производилась по метрике F1-масро на кросс-валидации по обучающей выборке, что позволило выбрать модель, наилучшим образом учитывающую ошибки на всех классах (рис.5).

```

Модель LogisticRegression
 0%|          | 0/200 [00:00<?, ?it/s]
Лучшая метрика: 0.5788
Лучший набор гипер параметров: {'solver': 'newton-cholesky'}
Модель RandomForestClassifier
 0%|          | 0/200 [00:00<?, ?it/s]
Лучшая метрика: 0.7159
Лучший набор гипер параметров: {'max_depth': 5, 'class_weight': 'balanced', 'min_samples_split': 5, 'n_estimators': 131}
Модель LGBMClassifier
 0%|          | 0/200 [00:00<?, ?it/s]
Лучшая метрика: 0.7652
Лучший набор гипер параметров: {'class_weight': 'balanced', 'boosting_type': 'dart', 'lambda_1': 9.307783467055643e-05, 'lambda_2': 0.6115481057443414, 'num_leaves': 86, 'feature_fraction': 0.7711063087337053, 'bagging_fraction': 0.6731132976196819, 'bagging_freq': 7, 'min_child_samples': 12, 'max_depth': 13, 'learning_rate': 0.41337378869658714}
Модель XGBClassifier
 0%|          | 0/200 [00:00<?, ?it/s]
Лучшая метрика: 0.7479
Лучший набор гипер параметров: {'max_depth': 8, 'class_weight': None, 'learning_rate': 0.024879558455671767, 'gamma': 4.7256522463885267e-07, 'min_child_weight': 0.018897691644452836, 'subsample': 0.8421728223941465, 'colsample_bytree': 0.9631116213951567, 'lambda': 0.002756999328080796, 'alpha': 4.2312208701523285e-05}
Модель CatBoostClassifier
 0%|          | 0/200 [00:00<?, ?it/s]
Лучшая метрика: 0.7631
Лучший набор гипер параметров: {'depth': 9, 'learning_rate': 0.03265495983273885, 'l2_leaf_reg': 0.15831816058566017, 'random_strength': 2.2070808346389824e-08, 'bagging_temperature': 1.0247703988194803e-06, 'border_count': 172}

```

Рисунок 5. Оценка качества моделей по метрике F1-масро.

3.2 Архитектура и алгоритм работы рекомендательной системы

Разработанная модель машинного обучения была интегрирована в прототип клинической рекомендательной системы, предназначенной для выбора хирургической тактики при тетраде Фалло. Алгоритм работы системы представляет собой конвейер последовательных этапов обработки данных.

Блок ввода и первичной обработки данных. Медицинский работник через интуитивно понятный интерфейс вводит 23 ключевых клинико-инструментальных показателя, включая антропометрические данные (возраст в днях, вес, рост), показатели оксигенации (SpO_2 , градиент давления), эхокардиографические параметры (размеры левого желудочка, характеристики клапана лёгочной артерии) и описание сопутствующих врождённых пороков сердца.

Блок автоматического анализа и предобработки. На серверной стороне система выполняет преобразование сырых данных: расчёт перцентилей роста и веса относительно возрастных нормативов, определение статуса недоношенности, анализ текстовых описаний, а также вычисление логарифмического индекса комбинации признаков «АВнАо × ЛАИ». На этом этапе также реализованы правила автоматической верификации и фильтрации противоречивых или критических значений, основанные на клинических протоколах (например, коррекция градиентов, превышающих 100 мм рт. ст.).

Блок машинного вывода и генерации рекомендации. Предобработанные данные подаются на вход финальной обученной модели (на выборке из 294 клинических случаев). Модель, адаптированная под российские клинические протоколы, вычисляет вероятность принадлежности случая к одному из четырёх классов хирургической тактики:

Радикальная коррекция (код 0): Полная анатомическая коррекция порока.

Реконструкция выводного отдела правого желудочка (код 1): Гемодинамическая коррекция, выполняемая как первый или второй этап хирургического лечения.

Системно-лёгочный анастомоз (код 2): Паллиативная коррекция на первом этапе.

Транслюминальная баллонная вальвулопластика клапана ЛА / стентирование выводного отдела (код 3): Миниинвазивное паллиативное вмешательство.

Блок интерпретации и вывода результатов. Система возвращает пользователю не только текстовую рекомендацию по выбору тактики, но и визуализацию ключевых параметров, повлиявших на решение модели (например, график важности признаков для конкретного предсказания). Это обеспечивает интерпретируемость работы «чёрного ящика» и доверие со стороны врача.

3.3 Валидация и стабильность модели

Финальным этапом разработки стала комплексная оценка устойчивости модели. Помимо стандартной проверки на отложенной тестовой выборке с построением матрицы ошибок (confusion matrix), была проведена оценка стабильности предсказаний при многократных запусках на различных подвыборках (кросс-валидация). Отсутствие значительных колебаний точности и сопоставимость результатов на обучающей и тестовой выборках подтвердили отсутствие переобучения и высокую надёжность разработанного инструмента. Время полного цикла анализа от ввода данных до получения рекомендации не превышает 2-3 секунд, что позволяет интегрировать систему в реальный клинический процесс. Актуализация модели планируется дважды в год по мере появления новых клинических данных и рекомендаций.

Глава IV. РЕЗУЛЬТАТЫ

Эффективность моделей, полученных после применения алгоритмов к первичным данным датасета, представлена в таблице 8.

Таблица 8. Сравнение показателей метрики F1 макро алгоритмов МО на тренировочной и тестовой выборках.

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

Macro F1 – это усредненное значение F1 для каждого класса без взвешивания, то есть все классы обрабатываются одинаково. Представляет собой гармоническое среднее между Precision и Recall, обеспечивая между ними баланс, что особенно полезно при неравномерном распределении классов. 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.

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. RandomForestClassifier демонстрирует значительный разрыв между результатами на тренировочной (0.6972) и тестовой (0.6280) выборках, что может указывать на переобучение модели.

XGBClassifier (XGBoost) и CatBoostClassifier показывают схожие результаты на тренировочной выборке (~ 0.75), но XGBoost хуже обобщается на тестовых данных (0.6660 против 0.7037 у CatBoost).

LogisticRegression имеет самые низкие показатели среди всех алгоритмов (0.5788 на тренировочной и 0.5973 на тестовой выборке), что ожидаемо для линейной модели на сложных данных.

Одним из критически важных шагов при создании эффективной модели является правильный выбор метрики для оценки её качества, поскольку некорректный выбор может привести к ошибочным выводам и, как следствие, к принятию не самых оптимальных решений. В связи с этим на сегодняшний день существует значительное количество метрик, подходящих для различных задач и ситуаций.

Качество моделей было оценено нами с помощью AUC-площади (Area Under Curve) под ROC-кривой (Receiver Operating Characteristics curve), выраженной через отношение доли истинно положительных прогнозов (TPR) к доли ложноположительных (FPR). ROC-кривые для пяти моделей представлены на рисунке 6.

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.




Рисунок 6. ROC- кривые сравнения всех используемых моделей МО.

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

CatBoost (фиолетовый) и *XGBClassifier* (красный) — показывают наивысшую чувствительность на начальном участке. *LogisticRegression* (синий) — самая низкая чувствительность в этой зоне. *RandomForest* (оранжевый) и *LGBM* (зеленый) — занимают промежуточное положение.

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 требует значительного роста False Positive Rate.

Разница между лучшими моделями (*CatBoost/XGBoost*) и остальными становится заметной при False Positive Rate около 0.2-0.4 - важный диапазон для многих практических применений. *LGBMClassifier* и *RandomForest* показывают схожую производительность, находясь между бустинговыми моделями и логистической регрессией.

Для критически важных задач, где важна максимальная точность, стоит выбрать CatBoost или XGBoost. Если важна интерпретируемость, можно рассмотреть RandomForest. LogisticRegression может быть полезна как базовый ориентир, несмотря на более низкую производительность. График хорошо демонстрирует преимущество современных алгоритмов бустинга (CatBoost, XGBoost, LGBM) перед традиционными методами для данной задачи.

Анализ работы различных моделей МО показал следующие результаты (Рисунок 7,8,9,10,11).

Модель LGBMClassifier продемонстрировала наилучшие показатели в 1 и 3 группах. В группе РК ТФ она совпала с решениями хирургов в 45 из 50 случаев (90%), при этом в 2 случаях (4%) рекомендовала РПОПЖ и в 3 случаях (6%) - СЛА. В группе СЛА совпадение составило 23 из 25 случаев (92%), при этом в 2 случаях (8%) модель не смогла определить правильную тактику. Однако для 2 и 4 групп из-за малого количества пациентов точность прогнозирования оказалась существенно ниже.




Рисунок 7. Матрица ошибок модели машинного обучения LGBM Classifier

Модель Cat Boost Classifier в группе РК ТФ показала совпадение в 44 из 50 случаев (88%), рекомендуя в 2 случаях (4%) РПОПЖ и в 4 случаях (8%) СЛА. В группе РПОПЖ совпадение составило лишь 3 из 7 случаев (42.9%), при этом в 3 случаях (42.9%) модель ошибочно рекомендовала РК ТФ и в 1 случае (14.2%) - СЛА. В группе СЛА точность составила 20 из 25 случаев (80%), с ошибочными рекомендациями РК ТФ в 4 случаях (16%) и РПОПЖ в 1 случае (4%). Для группы стентирования ВОПЖ совпадение наблюдалось в 4 из 7 случаев (57.1%), с ошибочным предложением СЛА в 3 случаях (42.9%).




Рисунок 8. Матрица ошибок модели машинного обучения CatBoostClassifier.

Logistic Regression показала высокую точность в группе РК ТФ - 45 из 50 случаев (90%), с ошибками в виде рекомендации РПОПЖ в 4 случаях (8%) и ТЛБВП ЛА в 1 случае (2%). В группе РПОПЖ совпадение составило 4 из 7 случаев (57.1%), с ошибочными рекомендациями РК ТФ в 2 случаях (28.6%) и СЛА в 1 случае (14.3%). Для группы СЛА точность была ниже - 14 из 25 случаев (56%), с ошибками: РК ТФ в 5 случаях (20%), РПОПЖ в 2 случаях (8%) и ТЛБВП ЛА в 4 случаях (16%). В группе стентирования ВОПЖ совпадение составило лишь 3 из 7 случаев (42.9%), с ошибочной рекомендацией СЛА в 4 случаях (57.1%).




Рисунок 9. Матрица ошибок модели машинного обучения Logistic Regression

Random Forest Classifier в группе РК ТФ показал совпадение в 43 из 50 случаев (86%), рекомендуя в 3 случаях (6%) РПОПЖ и в 4 случаях (8%) СЛА. В группе РПОПЖ точность была особенно низкой - лишь 2 из 7 случаев (28.6%), с ошибочными рекомендациями РК ТФ в 3 случаях (42.9%) и СЛА в 2 случаях (28.6%). В группе СЛА совпадение составило 20 из 25 случаев (80%), с ошибками в виде рекомендации РК ТФ в 5 случаях (20%). Для группы стентирования ВОПЖ точность составила 3 из 7 случаев (42.9%), с ошибочной рекомендацией СЛА в 4 случаях (57.1%).

Матрица ошибок RandomForestClassifier




Рисунок 10. Матрица ошибок модели машинного обучения Random Forest Classifier.

XGB Classifier в группе РК ТФ показал совпадение в 42 из 50 случаев (84%), рекомендуя в 3 случаях (6%) РПОПЖ и в 5 случаях (10%) СЛА. В группе РПОПЖ точность составила 3 из 7 случаев (42.9%), с ошибочными рекомендациями РК ТФ в 2 случаях (28.6%) и СЛА в 2 случаях (28.6%). В группе СЛА совпадение наблюдалось в 16 из 25 случаев (64%), с ошибками: РК ТФ в 4 случаях (16%) и РПОПЖ в 5 случаях (20%). Для группы стентирования ВОПЖ точность составила 5 из 7 случаев (71.4%), с ошибочной рекомендацией СЛА в 2 случаях (28.6%).




Рисунок 11. Матрица ошибок модели машинного обучения Random Forest Classifier.

Признаками с высокой значимостью были: **насыщение капиллярной крови кислородом SpO_2 (0.08202)** – самый влиятельный признак в модели, что может указывать на его критическую роль в прогнозируемом исходе; **размер ствола ЛА (0.04382)** – второй по значимости, связан с анатомией ЛА; **log - натуральный логарифм произведения значений АВнАо и ЛАИ пациента (отношение суммы диаметров устьев легочных артерий к диаметру нисходящей аорты * легочно-артериальный индекс). (0.03596)** – логарифмированная метрика; **градиент давления ПЖ/ЛА (0.03371)** – важный гемодинамический параметр, отражающий разницу давления между ПЖ и ЛА; **иКДО ЛЖ (0.02472)** – индексированный размер ЛЖ. Эти признаки играют ключевую роль в предсказании модели и должны быть тщательно контролируемы в клинической практике.

Признаки средней значимости: диаметры устьев лёгочных артерий (0.02247, 0.02135) и ЛАИ (0.02247), диаметр фиброзного кольца ЛА (0.01348), индекс Наката (0.01236) все параметры говорят об анатомии лёгочного русла. Возраст (0.00899) – возраст в месяцах, что важно для педиатрических

исследований. Эти переменные вносят умеренный вклад в модель, но их нельзя игнорировать. Остальные факторы имеют низкую или нулевую важность, поэтому были исключены из модели. График помогает понять, какие параметры наиболее критичны для модели, что полезно для оптимизации алгоритма и клинической интерпретации результатов.




Рисунок 12. Важность признаков для моделей машинного обучения.

На графике представлена значимость (feature importance) различных переменных, используемых в модели МО. Чем выше значение коэффициента (coef), тем больше влияние признака на предсказание модели.

Создана электронная платформа для определения тактики хирургического лечения детей с ТФ: <https://huggingface.co/spaces/aakretov/TOF>. На общедоступном бесплатном хостинге приложений от HuggingFace. Интерфейс сделан с помощью питоновской библиотеки streamlit.

Алгоритм работы рекомендательной системы для выбора хирургической тактики при тетраде Фалло

Ввод медицинских параметров

- Медицинский работник вводит 23 ключевых показателя пациента через интуитивный интерфейс:
- Антропометрические данные (возраст в днях, вес, рост)
- Показатели оксигенации (SpO₂, градиент давления ПЖ/ЛА)
- Эхокардиографические параметры (размеры ЛЖ, характеристики клапана ЛА)
- Особенности анатомии (наличие сопутствующих ВПС)

Автоматический анализ параметров

Система преобразует данные:

- Рассчитывает перцентили роста/веса по возрастным нормативам
- Определяет статус недоношенности
- Анализирует текстовые описания особенностей клапана ЛА
- Вычисляет логарифмические показатели ($AB_{нAo} \times LAI$)

Интеграция с медицинскими алгоритмами

Автоматически учитываются:

- Критические значения градиентов (>100 мм рт.ст. корректируются)
- Возрастные группы (новорожденные, 1-12 мес., старше года)
- Морфологические особенности клапанного аппарата

Генерация рекомендации

Искусственный интеллект на основе обученной модели (294 клинических случая) предлагает 1 из 4 тактик:

Код	Хирургическая тактика	Клиническое применение
0	РК	Полная анатомическая коррекция
1	Реконструкция выводного тракта ПЖ	Гемодинамическая коррекция в качестве 1 или 2 этапа
2	Системно-лёгочный анастомоз	Паллиативная коррекция в качестве 1 этапа
3	ТЛБВП клапана ЛА/стентирование ВОПЖ	Миниинвазивная паллиативная коррекция в качестве 1 этапа

Интерпретация результата

Система предоставляет: четкую текстовую рекомендацию, автоматическую верификацию введенных данных, визуализацию критических параметров, повлиявших на выбор тактики

Особенности работы системы:

- Адаптирована под российские клинические протоколы
- Учитывает возрастные нормы роста/развития
- Автоматически фильтрует противоречивые данные
- Обновляется 2 раза в год с интеграцией новых клинических рекомендаций

Для использования достаточно последовательно заполнить поля ввода и нажать кнопку “Собрать данные”. Система не требует технических навыков - весь анализ выполняется автоматически за 2-3 секунды.

Рекомендательная система хирургической тактики тетрады Фалло

Пол мужской -1, женский -2

1



Возраст (дни)

0,00



Вес, кг

0,00



Рост, см

0,00



БСА-см/м2

0,00



Сопвпс, описание

Гествозраст, дни

0,00



насыщение капиллярной крови кислородом SpO2 (%)

0,00



Одышцианприст, 1 - нет, 2 - есть

1



ФВ ЛЖ первич, %

0,00



КДР ЛЖ, см

0,00



КСР ЛЖ, см

0,00



КДО ЛЖ, мм

0,00



УстьеПЛА, мм

0,00



УстьеЛЛА, мм

0,00



СтволЛА, мм

0,00



ФК ЛА, мм

0,00 - +

створки клапана ЛА

градиент давления ПЖ/ЛА (мм.рт.ст.)

0,00 - +

дмжпмм

0,00 - +

давлениеПЖ

0,00 - +

ЛАИ

0,00 - +

АВнАо

0,00 - +

Собрать данные

Модель успешно загружена

Рисунок 13. Макет рекомендательной системы хирургической тактики ТФ.



Рисунок 14. QR код для перехода на сайт рекомендательной системы, recommending surgical tactics in TФ.

Глава V. ОБСУЖДЕНИЕ

ТФ остается одним из самых распространенных цианотических врожденных пороков сердца, требующих хирургической коррекции. Несмотря на значительный прогресс в кардиохирургии, отдаленные результаты лечения варьируют, а пациенты сталкиваются с риском развития жизнеугрожающих осложнений, включая аритмии, сердечную недостаточность и внезапную смерть. В этой связи прогнозирование и ИИ открывают новые возможности для персонализированной медицины.

Проведенное исследование демонстрирует ряд важных особенностей, которые можно сопоставить с данными других российских и международных работ.

Базовые характеристики пациентов

В нашем исследовании средний возраст пациентов на момент операции составил 137 дней, что соответствует современной тенденции к ранней коррекции пороков сердца [75]. Российские исследования также указывают на смещение хирургической активности в сторону ранних сроков (в среднем 3-6 месяцев), что связано с улучшением методов диагностики и предоперационной подготовки [76]. Однако в некоторых зарубежных центрах, например, в исследованиях Boston Children's Hospital, средний возраст коррекции может быть еще ниже (1-2 месяца), особенно при использовании гибридных методов [77–79].

Распределение по полу в нашем исследовании (62,3% мужчин) согласуется с мировой статистикой, где мужской пол преобладает среди пациентов с ТФ (примерно 60–65%). Это подтверждается как российскими, так и международными регистрами, включая данные Европейской ассоциации кардиоторакальных хирургов (EACTS) [80,81].

Среди нашей когорты пациентов летальности не было, хотя в ряде российских исследований прошлых лет она была (3-5%), а в ведущих центрах США и Европы она составляет 1-2% [82–86]. Это косвенно может

свидетельствовать о высоком уровне подготовленности и опыта в оказываемой хирургической помощи в центре.

Поддержка принятия решений при хирургическом лечении ТФ и других ВПС

В нашем исследовании самая точная модель LGBMClassifier показала точность 90-92% для групп РК ТФ и СЛА, что соответствует или превосходит большинство мировых работ в этой области. Для более редких случаев – в нашей серии это РПОПЖ и стентирование ВОПЖ – точность снижалась до 28-57% из-за малого объема данных. В исследовании Ishikita и соавт. 2023 г. была разработана модель машинного обучения для прогнозирования серьёзных неблагоприятных сердечно-сосудистых событий у взрослых пациентов после радикальной коррекции тетрады Фалло [65]. Авторами включены в анализ клинические параметры, данные МРТ правого желудочка, электрокардиографические показатели и лабораторные данные. Модель градиентного бустинга продемонстрировала AUC 0,82 при прогнозировании комбинированной конечной точки, включавшей смертность, устойчивые желудочковые тахикардии и госпитализацию по поводу сердечной недостаточности. Практическое значение работы в данном случае позволяет оценить возможности использования алгоритма для определения сроков повторных вмешательств при ТФ, включая замену лёгочного клапана. Как и в нашей серии работа подтверждает эффективность методов машинного обучения в контексте тетрады Фалло, доказывая, что ансамблевые алгоритмы способны решать как задачи стратификации риска, так и задачи тактического выбора вмешательства в популяции пациентов с данным диагнозом.

В исследовании Lo Muzio и соавт. 2021 г. представлена модель интраоперационной поддержки принятия решений при хирургии тетрады Фалло на основе алгоритмов машинного обучения [73]. В работу были включены 12 последовательных пациентов с ТФ. Интраоперационно регистрировались высокочастотные (200 кадров/с) видеозаписи эпикардальной кинематики

правого желудочка до и после коррекции. Всего было проанализировано 86 видеозаписей: 43 до вмешательства и 43 после него. Из временных рядов движения правого желудочка извлекались частотные признаки, а для классификации состояния «до коррекции» и «после коррекции» использовались две модели контролируемого машинного обучения: оптимизированный алгоритм k-nearest neighbors (KNN) и support vector machine (SVM). Обучение проводилось с применением 10-кратной перекрёстной валидации и гиперпараметрической оптимизации. По результатам анализа KNN продемонстрировал истинно-положительную долю (TPR) 95,3% для состояния до операции и 97,7% после коррекции, при минимальном числе ложных отрицательных классификаций (4,7% и 2,3% соответственно). Для SVM TPR составила 97,7% до вмешательства и 95,3% после него. Площадь под ROC-кривой достигала 0,97 для KNN и 0,99 для SVM, что соответствует почти идеальной дискриминационной способности моделей. Особый интерес представляла клиническая проверка алгоритма на пациентах вне обучающей выборки. У пациента с благоприятным исходом протезирования клапана ЛА видеокинематические параметры после операции классифицировались моделью как «здоровое» состояние. У пациента с неблагоприятным исходом и последующей летальностью послеоперационные данные продолжали классифицироваться как «нездоровые», что свидетельствует о возможности выявления отсутствия функционального улучшения правого желудочка непосредственно в операционной. Работа, как и в нашем случае, продемонстрировала принципиально новый формат применения ИИ при хирургии тетрады Фалло: не для ретроспективного анализа, а для интраоперационной и проспективной оценки эффективности. Высокие показатели $TPR > 95\%$ и AUC до 0,99 подтверждают потенциал машинного обучения как инструмента объективной количественной поддержки принятия решений в кардиохирургии врождённых пороков сердца. В работе авторов,

также, как и в нашей, продемонстрирована высокая прогностическая и классификационная способность моделей машинного обучения.

В большом систематическом обзоре Mohammadi и соавт. 2024 г. проанализированы 35 исследований, посвящённых применению методов искусственного интеллекта и машинного обучения в хирургии врождённых пороков сердца [12]. С точки зрения поддержки принятия хирургических решений наиболее значимым направлением оказалась предоперационная оценка риска. В 16 исследованиях основной конечной точкой являлась госпитальная или 30-дневная летальность, при этом дискриминационная способность моделей варьировала от 0,72 до 0,94 по показателю AUC, а в отдельных регистрах достигала 0,926. Ансамблевые алгоритмы, включая Random Forest, gradient boosting и XGBoost, демонстрировали устойчивую прогностическую эффективность выше 0,80, что превышало показатели традиционных шкал стратификации риска, таких как RACHS-1 и STS-EACTS. С клинической точки зрения такие модели могут использоваться для количественной оценки хирургического риска, определения оптимального времени вмешательства, направления пациента в специализированный центр и планирования объёма предоперационной подготовки. В ряде описываемых в систематическом обзоре исследований машинное обучение применялось для прогнозирования послеоперационных осложнений, включая острое повреждение почек, пролонгированную искусственную вентиляцию лёгких, неврологические нарушения и неблагоприятное течение после операции Норвуда при СГЛС. В этих задачах значения AUC составляли 0,71-0,95, а прогностические модели позволяли заранее выделить пациентов высокого риска, что имеет значение для выбора стратегии интенсивной терапии и распределения ресурсов отделения реанимации. В когортах пациентов с одножелудочковой гемодинамикой и после процедуры Норвуда модели достигали AUC 0,94–0,95 при прогнозировании трансплантационно-независимой выживаемости в течение одного года, что может влиять на решения о дальнейшем этапе паллиации или рассмотрении

варианта трансплантации. Авторы отдельно отмечают, что тип хирургического вмешательства нередко являлся одним из наиболее значимых предикторов неблагоприятного исхода, в некоторых моделях его вклад в совокупную прогностическую важность достигал 45%. Процедура Норвуда стабильно ассоциировалась с наиболее высоким риском 30-дневной смертности. Тем не менее, обзор подчёркивает, что существующие модели носят преимущественно ретроспективный характер, внешняя валидация выполнена лишь в ограниченном числе работ, а алгоритмы, автономно определяющие тип хирургической коррекции, в настоящее время отсутствуют. Как и в нашем исследовании машинное обучение по данным систематического обзора продемонстрировало клинически значимую прогностическую способность при хирургии врожденных пороков сердца, подтверждая высокую воспроизводимость решений и возможность количественной поддержки клинической тактики. При этом, в публикациях, включённых в обзор, МО преимущественно прогнозирует исход после принятого решения, тогда как в нашей работе алгоритм участвует в формировании самого решения о тактике вмешательства.

Крайне важной с практической точки зрения и значимой в историческом контексте является работа Ruiz-Fernandez и соавт. 2016 г. в которой представлена одна из ранних систем поддержки принятия решений при хирургии врожденных пороков сердца на основе алгоритмов машинного обучения [87]. В исследовании проанализированы 2432 последовательных случая кардиохирургических вмешательств при ВПС у детей, включающих ДМЖП, дефект межпредсердной перегородки, частичный и общий атриовентрикулярный канал, ТФ, коарктацию аорты и ТМА. В качестве эталона стратификации использовалась шкала RACHS-1 с разделением на три категории сложности. В анализ были включены 87 клинических переменных, охватывающих демографические данные, сопутствующие синдромы, признаки сердечной недостаточности и гипоксии, особенности операции и ранние послеоперационные осложнения. Для обучения применялась 10-кратная перекрестная валидация. Как и в нашей работе

исследование продемонстрировало высокую классификационную способность моделей МО в хирургии ВПС. При использовании полного набора данных многослойный перцептрон (нейросетевая модель с одним или несколькими скрытыми слоями, способная выявлять сложные нелинейные взаимосвязи между клиническими параметрами и прогнозируемым исходом) обеспечил корректную классификацию 2429 из 2432 случаев с общей точностью 99,87 %, радиально-базисная нейронная сеть достигла 95,60%, тогда как дерево решений C4.5 и самоорганизующиеся карты показали 80,09% и 81,79% соответственно. Наши данные также подтверждают высокую воспроизводимость алгоритмического решения с AUC выше 0,8 и F1-macro 0,818, что свидетельствует о сопоставимом уровне прогностической состоятельности моделей, демонстрируя преимущество нейросетевых алгоритмов перед более простыми классификационными методами. При этом модель, используемая авторами, преимущественно воспроизводит и уточняет уже существующую стратификацию риска по RACHS-1, фактически усиливая традиционную систему оценки сложности операции. В нашем исследовании алгоритм используется не для воспроизведения шкалы риска, а для выбора типа хирургической тактики при тетраде Фалло, то есть участвует в формировании стратегического решения до вмешательства.

В одной из методологически основополагающих в обсуждаемой области мультицентровой обзорной статье Jone и соавт. 2022 г. систематизированы направления, где ИИ уже работает как клинический инструмент поддержки решений при ВПС, и по ряду позиций это хорошо согласуется с тем, что мы получили в собственной выборке: наибольшую практическую ценность дают модели, которые либо повышают выявляемость патологии на этапе скрининга, либо дают измеримый выигрыш в прогнозе осложнений и исходов для выбора тактики и уровня наблюдения [68]. На пренатальном этапе показано, что модели на основе эхокардиографии способны достигать высокой дискриминации при дифференцировке нормальных сердец плода от сердец с ВПС. В работе Chen и

соавт. модель на базе рекуррентной нейросети для выделения стандартных фетальных плоскостей на видео продемонстрировала AUC 0,95, хотя тестирование проводилось на здоровой популяции без проверки на конкретных подтипах ВПС, что ограничивает переносимость результата в клинический скрининг с реальными пороками [88]. При большем и более приближенном к реальности массиве данных Dong и соавт. проанализировали 3910 плодов, из них 14,1% – с ВПС [89]. В данной выборке random forest по табличным признакам показал AUC 0,94 при чувствительности 0,85 и специфичности 0,88. Указанные результаты совпадают с полученными нами выводами: даже при ограниченном наборе доступных признаков модель может стабильно давать клинически полезный прирост в выявляемости, но при этом теряется «анатомическая конкретика» по подтипам пороков, что важно для маршрутизации беременной и планирования перинатальной тактики. Дополнительно к этому Arnaout и соавт. показали очень высокие показатели для CNN-классификации фетальных УЗ-изображений (AUC 0,99, чувствительность 0,95, специфичность 0,96), однако в обзоре подчеркивается, что алгоритмы не опубликованы и в рутинную практику не введены, то есть в реальной системе принятия решений этот результат на данный момент не завершил цикл внедрения [90]. В постнатальном периоде обзор показывает, что для поддержки решений важны не только изображения, но и рутинно собираемые диагностические данные (пульсоксиметрия, аускультация, ЭКГ и т.д.), которые можно масштабировать. Данный вывод перекликается с нашими наблюдениями о ценности простых, доступных на местах данных. Например, для первичного скрининга по аускультации Gharenhbaghi и соавторами приводятся модели с чувствительностью 0,86 и специфичностью 0,87 (здоровые дети и дети с 2-створчатым клапаном аорты), а в другой своей работе при более сложной постановке (здоровые дети, септальные дефекты, клапанная регургитация) нейросетевая архитектура дала чувствительность 0,92, но без полноценных независимых тестовых наборов [91,92]. Для пульсоксиметрии Lai соавт. показали AUC 0,91 при

чувствительности 95,8 и специфичности 86,4 для выявления ВПС у новорождённых, что практически напрямую подтверждает идею ранней стратификации риска, когда решение о срочной маршрутизации критично [93].

На уровне прогнозирования исходов и осложнений, то есть там, где ИИ становится частью выбора тактики и интенсивности ведения, в обзоре Jone приведены работы с метриками, сопоставимыми по уровню с нашими результатами. Jalali и соавт. на когорте 549 пациентов с одножелудочковой физиологией сравнивали несколько подходов, включая логистическую регрессию, деревья решений, random forest, градиентный бустинг и глубокую нейросеть [94]. При этом для прогноза комбинированной конечной точки «летальность/трансплантация» AUC достигал 0,95, а для прогноза пролонгированной длительности госпитализации AUC составил 0,94. Важная уточнение в обзоре заключается в смещении исходной популяции за счёт исключения наиболее тяжёлых пациентов, что повышает выживаемость и потенциально упрощает задачу модели. Тем не менее, сам факт устойчиво высокой дискриминации на клинических признаках и данных операции хорошо согласуется с нашим выводом: модели дают наибольшую пользу там, где нужно не «объяснять патогенез», а корректно выделить группу высокого риска и заранее усилить мониторинг, профилактику осложнений и ресурсное планирование.

Для ТФ обзор приводит пример именно риск-стратификации жизнеугрожающих событий. Atallah и соавт. использовали random forest и дерево решений для разделения на низкий, умеренный и высокий риск желудочковых аритмий и жизнеугрожающих событий [95]. Для группы высокого риска получены чувствительность 0,54 и специфичность 0,86, что является типичным профилем модели, которая хорошо отсекает низкий риск (высокая специфичность), но требует доработки для повышения выявляемости событий (умеренная чувствительность). В клинической логике это ближе к поддержке решения о более плотном наблюдении и дообследовании у выявленных

высокорисковых пациентов, чем к универсальному скринингу. В том же направлении, уже на взрослых с ВПС, Diller и соавт. показали, что CNN по текстовым медицинским отчётам и данным обследований может классифицировать диагностические группы с точностью 91%, сложность порока с точностью 96% и функциональный класс NYHA с точностью 90%, что концептуально близко нашему подходу, когда модель формализует клиническую сложность случая и снижает вариабельность интерпретации между специалистами [96].

Важным для масштабной поддержки принятия решений в хирургии ВПС являются модели, основанные на больших реестрах [97]. Bertsimas и соавт. проанализировали около 235000 пациентов и 295000 операций, используя клинические и предоперационные факторы для прогноза летальности, длительности ИВЛ и длительности госпитализации [98]. Данный класс работ поддерживает вывод, к которому мы также приходим в нашем исследовании: на уровне системного управления качеством и ресурсами, а также для предварительной оценки риска до операции, наиболее устойчивые решения строятся на стандартизированных, легко собираемых переменных, а ценность модели определяется не только AUC, но и тем, насколько она помогает изменять тактику ведения конкретного пациента и маршрутизацию [99].

Заключая, можно с уверенностью сделать вывод о том, что материал обзора расширяет и усиливает нашу аргументацию: по мере перехода от «узких» задач (выделение плоскостей фетального сердца, распознавание отдельных сигналов) к клинически значимым решениям (прогноз летальности, трансплантации, длительности госпитализации, риск жизнеугрожающих аритмий при ТФ) точность многих моделей выходит на уровень AUC около 0,9 и выше, но практическая применимость определяется ограничениями данных, валидацией и возможностью встроить модель в реальный клинический контур. В этом смысле наши результаты выглядят как ожидаемая часть общей тенденции: при корректно выбранных доступных признаках ИИ даёт воспроизводимый

выигрыш именно там, где врачу нужно принять решение в условиях неопределённости и высокой цены ошибки, а не заменить клиническое мышление [100].

В обзорной работе Sethi и соавт. систематизированы современные направления применения искусственного интеллекта и методов машинного обучения в диагностике, прогнозировании и хирургическом лечении врожденных пороков сердца [101]. Анализ показал, что наиболее значимая область применения ИИ в кардиохирургии ВПС связана с созданием систем поддержки принятия клинических решений, направленных на предоперационную оценку риска, оптимизацию хирургического планирования и прогнозирование послеоперационных исходов.

На предоперационном этапе алгоритмы машинного обучения используются для прогнозирования неблагоприятных исходов и стратификации риска хирургического вмешательства. В частности, в ряде работ применялись модели градиентного бустинга (XGBoost), искусственные нейронные сети (ANN) и специализированные архитектуры глубокого обучения, такие как RCRnet, позволяющие анализировать большие клинические наборы данных пациентов с врожденными пороками сердца. Эти модели применялись для прогнозирования вероятности летальности и осложнений при различных типах ВПС, включая тетраду Фалло, дефекты межпредсердной и межжелудочковой перегородки, а также пороки с лево-правым шунтом. Показано, что подобные алгоритмы способны выявлять сложные нелинейные взаимосвязи между клиническими параметрами пациента, что позволяет формировать индивидуализированные прогнозы хирургического риска и потенциальных послеоперационных исходов. Аналогично полученным нами данным, авторы обзора обращают внимание, что использование моделей машинного обучения значительно повышает точность и объективность предоперационной стратификации риска и позволяет более обоснованно подходить к выбору хирургической тактики [102].

В интраоперационном контексте технологии ИИ применяются для анализа гемодинамических параметров и оптимизации хирургической навигации. Отмечено использование методов контролируемого машинного обучения, включая алгоритм k-ближайших соседей (KNN) и метод опорных векторов (SVM), для моделирования потоковой гемодинамики и оценки кинематики внутрисердечного кровотока во время вмешательства. Это особенно важно при сложных реконструктивных операциях при врожденных пороках сердца, где точная оценка гемодинамических параметров может определять эффективность коррекции. Дополнительным направлением является применение алгоритмов компьютерного зрения для автоматической сегментации изображений КТ и МРТ. В одном из приведенных примеров автоматизированная сегментация анатомических структур сердца выполнялась приблизительно за 2 минуты, тогда как традиционная ручная сегментация требовала 2–3 часов, что существенно ускоряло планирование вмешательства и позволяло использовать эти данные непосредственно во время операции. Такие подходы демонстрируют концептуальное сходство с нашими результатами, поскольку также направлены на повышение точности хирургических решений за счет анализа сложных многомерных данных.

Послеоперационный этап является еще одной областью активного применения методов машинного обучения. Алгоритмы анализа ЭКГ-данных и других физиологических параметров используются для прогнозирования развития желудочковой дисфункции, сердечной недостаточности и долгосрочной смертности после хирургической коррекции врожденных пороков сердца. Кроме того, в ряде исследований применялись модели «optimal classification trees» (ОСТ), позволяющие прогнозировать продолжительность искусственной вентиляции легких и длительность госпитализации после операций на сердце. Эти модели позволяют ранее выявлять пациентов с высоким риском осложнений и своевременно корректировать тактику интенсивной терапии. Полученные результаты демонстрируют концептуальное

совпадение с нашими данными, поскольку подтверждают эффективность применения алгоритмов машинного обучения для прогнозирования послеоперационного течения и оптимизации ведения пациентов после коррекции ВПС.

В целом анализ представленных в обзоре исследований показывает, что применение искусственного интеллекта в хирургии врожденных пороков сердца позволяет существенно повысить точность предоперационной оценки риска, улучшить планирование хирургического вмешательства и оптимизировать послеоперационное ведение пациентов. Аналогично нашим результатам, авторы подчеркивают, что ключевым преимуществом методов машинного обучения является способность интегрировать большие массивы клинических данных и выявлять сложные закономерности, недоступные традиционным статистическим подходам. При этом ИИ рассматривается не как замена врача, а как инструмент поддержки клинических решений, способный повысить безопасность и эффективность лечения пациентов с врожденными пороками сердца и приблизить кардиохирургию к концепции персонализированной или «точной» кардиологии.

В исследовании Chang Junior J. и соавт., упоминаемом ранее, разработана одна из наиболее последовательных моделей предоперационной поддержки принятия решений при хирургии врожденных пороков сердца, основанная исключительно на предоперационных данных и адаптированная к особенностям конкретной региональной популяции [51]. В анализ были включены 2240 последовательных прооперированных пациентов с ВПС за 2014-2018 гг., а для построения прогноза использовали 83 предоперационные переменные, включая демографические характеристики, сатурацию артериальной крови кислородом, рост, массу тела, индекс массы тела, синдромальные формы, необходимость ИВЛ, инотропной поддержки, наличие отдельных анатомических вариантов ВПС, в том числе тетрады Фалло и проч. Целевой конечной точкой служила госпитальная летальность, определённая как смерть в стационаре или в течение

30 дней после операции. Для обучения и валидации были протестированы шесть алгоритмов машинного обучения: MLP, Random Forest, Extra Trees, Stochastic Gradient Boosting, AdaBoost Classification и Bagged Decision Trees, с использованием 10-кратной перекрестной валидации и балансировки выборки, поскольку смертность в когорте составляла 10,8%, а выживаемость 89,2%.

По результатам сравнения моделей наилучшие характеристики для клинической задачи идентификации пациентов высокого риска показал алгоритм Random Forest. Его ROC AUC составила 0,902, recall 92,2%, precision 54,7%, specificity 77,5%, accuracy 80,8%, average precision 0,73. Bagged Decision Trees формально продемонстрировал более высокий ROC AUC, 0,926, и average precision 0,81, однако уступал Random Forest по чувствительности, 70,6% против 92,2%, а потому был менее пригоден именно для задачи поиска пациентов с максимальным риском летального исхода. Напротив, многослойный перцептрон продемонстрировал высокую общую точность, 90,2%, и специфичность, 98,5%, но при этом имел крайне низкую чувствительность, всего 20,8%, то есть практически не решал клиническую задачу своевременного выявления пациентов, действительно находящихся в группе риска. Авторы отдельно подчеркивают, что для несбалансированной выборки ориентироваться только на точность модели было бы методологически ошибочно, поэтому ключевое значение приобретали ROC AUC, чувствительность и положительная прогностическая ценность. В тестовой выборке модель Random Forest не распознала только 4 из 51 случаев летального исхода, правильно классифицировав 47 из 51 пациента с неблагоприятным исходом, что дополнительно подтверждает её практическую ценность именно как инструмента поддержки решения, а не как формально точного, но клинически «слепого» классификатора.

Существенный интерес представляет анализ значимости признаков. В модели Random Forest шесть ключевых предикторов формировали 67,8% общей прогностической важности: предшествующая госпитализация в ОИТ, 22,2%;

диагностическая группа, 15,8%; рост пациента на момент операции, 11,6%; синдром гипоплазии левых отделов сердца, 6,5%; индекс массы тела, 6,3%; сатурация артериальной крови кислородом, 5,5%. Дополнительно заметный вклад вносили площадь поверхности тела, 5,4%, легочная атрезия, 4,3%, масса тела, 2,4%, возраст на дату операции, 1,9%, а также принадлежность к ряду конкретных диагнозов, включая тетраду Фалло и единственный желудочек, хотя их удельный вклад был ниже. Авторы делают важный клинический вывод: госпитальная летальность была выше у пациентов с ростом до 66 см и ИМТ ниже 13,0, а вероятность смерти снижалась по мере увеличения сатурации кислорода. Более высокий риск также отмечался у пациентов с предшествующей госпитализацией в ОИТ и у больных с наиболее тяжелыми диагностическими группами, прежде всего при СГЛС. Тем самым модель не только прогнозировала исход, но и делала видимыми клинически осмысленные паттерны риска, позволяя врачам и семьям обсуждать целесообразность вмешательства на основе количественной оценки, а не только экспертного впечатления. Важным практическим продолжением работы стало создание веб-инструмента CgntSCORE, доступного через браузер или смартфон, что переводит модель из чисто исследовательской плоскости в формат прикладной системы поддержки принятия решений.

Аналогично нашему исследованию, машинное обучение в исследовании авторов используется не для абстрактной классификации изображений или ретроспективного описания исходов, а как инструмент клинической стратификации, позволяющий формализовать решение до вмешательства. Как и в наших данных, модель работает с реальными клинико-анатомическими переменными, а не с искусственно упрощённым набором признаков, и демонстрирует, что наибольшая ценность ИИ проявляется там, где нужно совместно учитывать морфологическую тяжесть порока, гемодинамическую нестабильность и клиническое состояние пациента. Как и в нашей работе в исследовании на первый план выходят не единичные анатомические признаки, а

их сочетание с параметрами общего статуса и предоперационной тяжести. Если в нашей модели решающую роль играли SpO_2 , размеры легочного русла, интегральные анатомические показатели и градиент ПЖ-ЛА, то в работе Chang Junior и соавт. ключевыми предикторами также стали сатурация, принадлежность к тяжелой диагностической группе, показатели физического развития и предшествующая интенсивная терапия. Выявленное сходство результатов имеет принципиальное значение: как в нашей, так и в описываемой работе алгоритм фактически формализует клиническую логику врача, но делает её более прозрачной, количественной и воспроизводимой.

Необходимо сказать, что в нашей работе модель направлена на выбор хирургической тактики при тетраде Фалло, то есть участвует в формировании самого решения о типе вмешательства. В исследовании Chang Junior и соавт. алгоритм не выбирает конкретный вариант операции, а оценивает вероятность летального исхода при уже предполагаемом хирургическом лечении. Т.о. в нашем исследовании ИИ работает на этапе тактической стратификации, в то время как в описываемой работе – на этапе количественной предоперационной оценки риска. Однако данные различия не противоречат друг другу, а, напротив, подчеркивают последовательность уровней клинической интеграции ИИ: сначала модель помогает определить, какой тип вмешательства предпочтителен, затем аналогичные инструменты могут уточнить индивидуальный риск реализации этой стратегии. В этом смысле результаты Chang Junior и соавт. концептуально дополняют наши данные и подтверждают, что МО способно быть не только средством прогноза постфактум, но и частью полноценного предоперационного контура принятия решений.

Отдельно следует отметить ещё одну важную закономерность, согласующуюся с нашими результатами: работа авторов, также, как и наша, показывает ограниченность универсальных международных шкал в условиях выраженной гетерогенности ВПС и локальных особенностей популяции. Авторы прямо указывают, что региональная когорта включала значительное число

пациентов с низкой массой тела и нутритивными нарушениями, то есть с характеристиками, недостаточно представленными в больших международных регистрах. Именно поэтому локально обученная модель выявила такие значимые переменные, как рост, индекс массы тела и предшествующая интенсивная терапия, которые могли бы иметь меньший вес в усреднённых глобальных шкалах. Данное положение особенно хорошо согласуется с нашими результатами, где тактика коррекции тетрады Фалло также определялась не абстрактным «средним» пациентом, а реальным сочетанием анатомии легочного русла, степени гипоксемии и гемодинамической нагрузки правого желудочка в конкретной когорте [103]. Т.о. работа авторов, как и наша, подтверждает, что клиническая ценность ИИ максимальна тогда, когда модель чувствительна к особенностям именно той популяции, в которой она применяется. В совокупности это формирует целостное представление о том, как системы машинного обучения могут последовательно сопровождать хирурга и кардиолога на различных этапах: от выбора стратегии вмешательства до персонализированной предоперационной оценки риска. Именно подобный переход от усреднённых шкал к индивидуализированным алгоритмам и отражает движение современной кардиохирургии ВПС в сторону по-настоящему точной, пациент-ориентированной медицины.

ЗАКЛЮЧЕНИЕ

Целью проведённого исследования являлась разработка и анализ возможностей применения методов искусственного интеллекта и машинного обучения для использования в качестве поддержки принятия решений при выборе хирургической тактики и прогнозировании результатов лечения у пациентов с тетрадой Фалло.

Ключевым методологическим способом явилось применение алгоритмов машинного обучения, позволяющих анализировать многомерные взаимосвязи клинических и инструментальных параметров, что принципиально отличает их от традиционных статистических моделей и экспертных оценок, основанных на ограниченном числе признаков.

В ходе исследования продемонстрировано, что построенные модели машинного обучения способны выявлять значимые предикторы выбора хирургической тактики и исходов лечения, формируя индивидуализированные прогнозы для конкретного пациента. При этом показано, что наибольшая эффективность моделей достигается при их обучении на данных, отражающих особенности конкретной клинической когорты, что обеспечивает более высокую чувствительность к популяционно-специфическим характеристикам.

Установлено, что применение методов машинного обучения позволяет перейти от использования усреднённых подходов к анализу к формированию персонифицированных алгоритмов поддержки принятия решений, учитывающих совокупность факторов, влияющих на выбор тактики лечения. Это создаёт предпосылки для повышения точности стратификации пациентов и оптимизации хирургической стратегии.

В работе показано, что точность прогностических моделей существенно варьирует в зависимости от представленности различных типов вмешательств в обучающей выборке. Для редких вариантов хирургических вмешательств отмечено снижение точности прогнозирования (28-57%), что обусловлено

ограниченным объёмом данных и указывает на необходимость расширения обучающих выборок для повышения надёжности моделей.

Полученные результаты свидетельствуют о том, что использование методов искусственного интеллекта позволяет выявлять скрытые закономерности в данных, недоступные при применении традиционных методов анализа, и формировать более сложные прогностические зависимости, учитывающие нелинейный характер взаимодействия признаков.

Кроме того, продемонстрировано, что внедрение алгоритмов машинного обучения в клиническую практику может служить основой для создания систем поддержки принятия врачебных решений, способствующих стандартизации подходов к лечению и снижению вариабельности тактики между различными учреждениями.

Таким образом, результаты исследования подтверждают перспективность использования технологий искусственного интеллекта и машинного обучения в кардиохирургии врождённых пороков сердца, позволяя рассматривать их как эффективный инструмент для прогнозирования исходов и выбора оптимальной хирургической тактики на основе анализа комплексных медицинских данных.

ВЫВОДЫ

Проведенное исследование позволило сформулировать следующие ключевые выводы, которые вносят вклад в понимание факторов, влияющих на выбор хирургической тактики и послеоперационное ведение пациентов с врожденными пороками сердца:

1. Наилучшие результаты точности прогнозирования хирургической тактики при ТФ достигнуты с использованием модели LGBMClassifier, показавшей соответствие с решениями хирургов в 90–92% случаев при стандартных типах операций.
2. Разработанная и внедрённая электронная платформа предоставляет специалистам дополнительный метод персонализированного выбора хирургической тактики при ТФ и может быть использована в кардиохирургических и кардиологических стационарах с целью увеличения объективности, стандартизации подходов и возможного снижения вероятности послеоперационных осложнений.
3. Анализ вклада отдельных предикторов в формирование прогностического решения позволяет выявлять значимые факторы и повышает интерпретируемость моделей машинного обучения.
4. Точность прогнозирования ИИ-модели для более редких хирургических вмешательств существенно ниже (28-57%) в связи с ограниченным представлением данных в обучающей выборке, что требует расширения клинического материала для надёжной стратификации подобных пациентов.
5. Модели машинного обучения могут быть использованы для поддержки принятия решений при планировании хирургической тактики у детей с тетрадой Фалло при наличии достаточного объёма верифицированных данных.

ПРАКТИЧЕСКИЕ РЕКОМЕНДАЦИИ

1. Для повышения клинической значимости и точности прогноза следует регулярно обновлять и дообучать модели ИИ на расширяющихся локальных и мультицентровых базах данных.
2. При анализе спорных или пограничных клинических случаев, когда модель предлагает альтернативную хирургическую тактику, рекомендуется совместное обсуждение результатов модели в мультидисциплинарной команде с участием кардиохирургов, анестезиологов и специалистов по ИИ.
3. Для оценки предикторов послеоперационного течения у детей с ТФ рекомендуется использовать значения эхокардиографических показателей в динамике (до и после операции), включая иКДО ЛЖ и градиент ПЖ–ЛА.
4. Разработанная модель ИИ не показала достаточной точности для редких видов вмешательств (например, РПОПЖ, ТЛБВП ЛА); для таких случаев необходимо воздерживаться от полагания на автоматические рекомендации без экспертной оценки.
5. При использовании алгоритмов ИИ важно проводить визуализацию значимости признаков (feature importance) для клинической интерпретации и контроля качества автоматических решений.
6. В условиях детских кардиохирургических центров рекомендуется применение специализированного калькулятора хирургической тактики, интегрированного в электронную медицинскую систему отделения.
7. Рекомендуется инициировать разработку и внедрение мультицентрового регистра пациентов с ТФ для повышения обобщающей способности моделей и выработки единых стандартов машинного прогнозирования.
8. При формировании обучающих выборок для моделей МО следует исключать пациентов с сопутствующими врожденными пороками сердца, чтобы обеспечить однородность данных и повысить точность прогноза.

9. Для перевода показателей роста и веса в стандартизированную шкалу рекомендуется использование центильных таблиц, даже при отсутствии точной информации о поле пациента, что позволяет проводить более корректную оценку физического развития.
10. В качестве дополнительного информативного признака при построении моделей рекомендуется использовать логарифмическое преобразование мультипликативных клинико-анатомических показателей (например, $\log(\text{ABнAo} \times \text{ЛАИ})$).
11. При недостаточности визуализации ЛА и ПЖ на ЭхоКГ рекомендуется дополнительная визуализация с использованием КТ или МРТ с последующей цифровой сегментацией и включением этих данных в модель.
12. Для минимизации вероятности ошибочной рекомендации модели необходимо предварительно исключить случаи с неполными или некорректно закодированными данными.
13. Внедрение цифровой платформы с ИИ-моделью в клинический процесс целесообразно сопровождать этапом пилотного тестирования и сопоставления рекомендаций с ретроспективными решениями хирургов.
14. Для оценки долгосрочной эффективности хирургической тактики и моделей ИИ необходимо внедрять систематическое катamnестическое наблюдение с повторной валидацией прогнозов на новых данных через 6–12 месяцев.

СПИСОК ЛИТЕРАТУРЫ

- [1] Ляпин АА, Тарасов РС. Отдаленные результаты радикальной коррекции тетрады Фалло: какие проблемы предстоит решить? Креативная Кардиология 2021;15:146–56. <https://doi.org/10.24022/1997-3187-2021-15-2-146-156>.
- [2] Омельченко АЮ, Войтов АВ, Горбатых ЮН, Кулябин ЮЮ, Горбатых АВ, Сойнов ИА, et al. Анатомо-Физиологическое Состояние Правого Желудочка В Отдаленном Периоде После Радикальной Коррекции Тетрады Фалло. Сибирский Научный Медицинский Журнал 2017;37:39–45.
- [3] Подзолков ВП, Ковалев ДВ, Костава ВТ, Матаева (Шинкарева) ТВ, Минаев АВ. Отдаленный Результат Применения Отечественного Протеза Из Яремной Вены Быка В Позиции Ствола Легочной Артерии У Взрослого Больного С Тетрадой Фалло. Грудная И Сердечно-Сосудистая Хирургия 2018;60:249–53.
- [4] Подзолков ВП, Данилов ТЮ, Чиаурели МР, Минаев АВ, Ковалев ДВ, Самсонов ВБ, et al. Структура осложнений и результаты повторных вмешательств у взрослых пациентов после ранее выполненной радикальной коррекции тетрады Фалло. Бюллетень Нцсх Им Ан Бакулева Рамн Сердечно-Сосудистые Заболевания 2021;22:213–20. <https://doi.org/10.24022/1810-0694-2021-22-2-213-220>.
- [5] Egbe AC, Kothapalli S, Borlaug BA, Ammash NM, Najam M, Bajwa N, et al. Mechanism and Risk Factors for Death in Adults With Tetralogy of Fallot. Am J Cardiol 2019;124:803–7. <https://doi.org/10.1016/j.amjcard.2019.05.048>.
- [6] Topol EJ. High-performance medicine: the convergence of human and artificial intelligence. Nat Med 2019;25:44–56. <https://doi.org/10.1038/s41591-018-0300-7>.
- [7] Zhang J, Gajjala S, Agrawal P, Tison GH, Hallock LA, Beussink-Nelson L, et al. Fully Automated Echocardiogram Interpretation in Clinical Practice. Circulation 2018;138:1623–35. <https://doi.org/10.1161/CIRCULATIONAHA.118.034338>.

- [8] Shademan A, Decker RS, Opfermann JD, Leonard S, Krieger A, Kim PCW. Supervised autonomous robotic soft tissue surgery. *Sci Transl Med* 2016;8:337ra64. <https://doi.org/10.1126/scitranslmed.aad9398>.
- [9] Yan, Wang, Yu, Wang, Et. A. Machine Learning-Based Surgical State Perception and Collaborative Control for a Vascular Interventional Robot. *IEEE Sens J* 2022. <https://doi.org/10.1109/jsen.2022.3154921>.
- [10] Armoundas AA, Narayan SM, Arnett DK, Spector-Bagdady K, Bennett DA, Celi LA, et al. Use of Artificial Intelligence in Improving Outcomes in Heart Disease: A Scientific Statement From the American Heart Association. *Circulation* 2024;149:e1028–50. <https://doi.org/10.1161/CIR.0000000000001201>.
- [11] Jone P-N, Gearhart A, Lei H, Xing F, Nahar J, Lopez-Jimenez F, et al. Artificial Intelligence in Congenital Heart Disease: Current State and Prospects. *JACC Adv* 2022;1:100153. <https://doi.org/10.1016/j.jacadv.2022.100153>.
- [12] Mohammadi I, Rajai Firouzabadi S, Hosseinpour M, Akhlaghpasand M, Hajikarimloo B, Zeraatian-Nejad S, et al. Using artificial intelligence to predict post-operative outcomes in congenital heart surgeries: a systematic review. *BMC Cardiovasc Disord* 2024;24:718. <https://doi.org/10.1186/s12872-024-04336-6>.
- [13] Bishop CM. Pattern recognition and machine learning. New York: Springer; 2006.
- [14] Zhang A, Lipton ZC, Li M, Smola AJ. Dive into Deep Learning 2023. <https://doi.org/10.48550/arXiv.2106.11342>.
- [15] Jumper J, Evans R, Pritzel A, Green T, Figurnov M, Ronneberger O, et al. Highly accurate protein structure prediction with AlphaFold. *Nature* 2021;596:583–9. <https://doi.org/10.1038/s41586-021-03819-2>.
- [16] Gou F, Liu J, Xiao C, Wu J. Research on Artificial-Intelligence-Assisted Medicine: A Survey on Medical Artificial Intelligence. *Diagnostics* 2024;14:1472. <https://doi.org/10.3390/diagnostics14141472>.

- [17] Esteva A, Kuprel B, Novoa RA, Ko J, Swetter SM, Blau HM, et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature* 2017;542:115–8. <https://doi.org/10.1038/nature21056>.
- [18] Hannun AY, Rajpurkar P, Haghpanahi M, Tison GH, Bourn C, Turakhia MP, et al. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. *Nat Med* 2019;25:65–9. <https://doi.org/10.1038/s41591-018-0268-3>.
- [19] Zaid M. Pneumonia Detection through X-Ray Using Deep Learning 2020. <https://doi.org/10.9790/0661-2201040811>.
- [20] Rajkomar A, Oren E, Chen K, Dai AM, Hajaj N, Hardt M, et al. Scalable and accurate deep learning with electronic health records. *NPJ Digit Med* 2018;1:18. <https://doi.org/10.1038/s41746-018-0029-1>.
- [21] Nemati S, Holder A, Razmi F, Stanley MD, Clifford GD, Buchman TG. An Interpretable Machine Learning Model for Accurate Prediction of Sepsis in the ICU. *Crit Care Med* 2018;46:547–53. <https://doi.org/10.1097/CCM.0000000000002936>.
- [22] Bogoch II, Watts A, Thomas-Bachli A, Huber C, Kraemer MUG, Khan K. Potential for global spread of a novel coronavirus from China. *J Travel Med* 2020;27:taaa011. <https://doi.org/10.1093/jtm/taaa011>.
- [23] Asan, Nattinger, Gurses, Tyszka, Et. A. Oncologists' Views Regarding the Role of Electronic Health Records in Care Coordination. *JCO Clin Cancer Inform* 2018. <https://doi.org/10.1200/CCI.17.00118>.
- [24] Sharabiani A, Bress A, Douzali E, Darabi H. Revisiting Warfarin Dosing Using Machine Learning Techniques. *Comput Math Methods Med* 2015;2015:560108. <https://doi.org/10.1155/2015/560108>.
- [25] Zou J, Huss M, Abid A, Mohammadi P, Torkamani A, Telenti A. A primer on deep learning in genomics. *Nat Genet* 2019;51:12–8. <https://doi.org/10.1038/s41588-018-0295-5>.

- [26] Esteva A, Robicquet A, Ramsundar B, Kuleshov V, DePristo M, Chou K, et al. A guide to deep learning in healthcare. *Nat Med* 2019;25:24–9. <https://doi.org/10.1038/s41591-018-0316-z>.
- [27] Hung AJ, Chen J, Che Z, Nilanon T, Jarc A, Titus M, et al. Utilizing Machine Learning and Automated Performance Metrics to Evaluate Robot-Assisted Radical Prostatectomy Performance and Predict Outcomes. *J Endourol* 2018;32:438–44. <https://doi.org/10.1089/end.2018.0035>.
- [28] Shah-Mohammadi F, Cui W, Finkelstein J. Entity Extraction for Clinical Notes, a Comparison Between MetaMap and Amazon Comprehend Medical. *Stud Health Technol Inform* 2021;281:258–62. <https://doi.org/10.3233/SHTI210160>.
- [29] Koh MCY, Ngiam JN, Oon JEL, Lum LH-W, Smitasin N, Archuleta S. Using ChatGPT for writing hospital inpatient discharge summaries - perspectives from an inpatient infectious diseases service. *BMC Health Serv Res* 2025;25:221. <https://doi.org/10.1186/s12913-025-12373-w>.
- [30] Perez MV, Mahaffey KW, Hedlin H, Rumsfeld JS, Garcia A, Ferris T, et al. Large-Scale Assessment of a Smartwatch to Identify Atrial Fibrillation. *N Engl J Med* 2019;381:1909–17. <https://doi.org/10.1056/NEJMoa1901183>.
- [31] Tsanas A, Little MA, McSharry PE, Spielman J, Ramig LO. Novel speech signal processing algorithms for high-accuracy classification of Parkinson's disease. *IEEE Trans Biomed Eng* 2012;59:1264–71. <https://doi.org/10.1109/TBME.2012.2183367>.
- [32] Avati A, Jung K, Harman S, Downing L, Ng A, Shah NH. Improving palliative care with deep learning. *BMC Med Inform Decis Mak* 2018;18:122. <https://doi.org/10.1186/s12911-018-0677-8>.
- [33] Shameer K, Johnson KW, Glicksberg BS, Dudley JT, Sengupta PP. Machine learning in cardiovascular medicine: are we there yet? *Heart* 2018;104:1156–64. <https://doi.org/10.1136/heartjnl-2017-311198>.
- [34] Wong A, Otles E, Donnelly JP, Krumm A, McCullough J, DeTroyer-Cooley O, et al. External Validation of a Widely Implemented Proprietary Sepsis Prediction

Model in Hospitalized Patients. *JAMA Intern Med* 2021;181:1065–70. <https://doi.org/10.1001/jamainternmed.2021.2626>.

[35] Bates DW, Levine D, Syrowatka A, Kuznetsova M, Craig KJT, Rui A, et al. The potential of artificial intelligence to improve patient safety: a scoping review. *NPJ Digit Med* 2021;4:54. <https://doi.org/10.1038/s41746-021-00423-6>.

[36] Joudaki H, Rashidian A, Minaei-Bidgoli B, Mahmoodi M, Geraili B, Nasiri M, et al. Using data mining to detect health care fraud and abuse: a review of literature. *Glob J Health Sci* 2014;7:194–202. <https://doi.org/10.5539/gjhs.v7n1p194>.

[37] Yu L, Guo Y, Wang Y, Yu J, Chen P. Segmentation of Fetal Left Ventricle in Echocardiographic Sequences Based on Dynamic Convolutional Neural Networks. *IEEE Trans Biomed Eng* 2017;64:1886–95. <https://doi.org/10.1109/TBME.2016.2628401>.

[38] Tian Y, Qin W, Zhao Z, Wang C, Tian Y, Zhang Y, et al. Deep Learning Based Automatic Left Ventricle Segmentation from the Transgastric Short-Axis View on Transesophageal Echocardiography: A Feasibility Study. *Diagnostics* 2024;14:1655. <https://doi.org/10.3390/diagnostics14151655>.

[39] Ketola JHJ, Heino H, Juntunen MAK, Nieminen MT, Siltanen S, Inkinen SI. Generative adversarial networks improve interior computed tomography angiography reconstruction. *Biomed Phys Eng Express* 2021;7. <https://doi.org/10.1088/2057-1976/ac31cb>.

[40] Slesnick TC, Yoganathan AP. Computational modeling of Fontan physiology: at the crossroads of pediatric cardiology and biomedical engineering. *Int J Cardiovasc Imaging* 2014;30:1073–84. <https://doi.org/10.1007/s10554-014-0442-8>.

[41] Zhang X, Mao B, Che Y, Kang J, Luo M, Qiao A, et al. Physics-informed neural networks (PINNs) for 4D hemodynamics prediction: An investigation of optimal framework based on vascular morphology. *Comput Biol Med* 2023;164:107287. <https://doi.org/10.1016/j.compbiomed.2023.107287>.

[42] Raissi, Perdikaris, Karniadakis. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear

- partial differential equations. J Comput Phys 2019.
<https://doi.org/10.1016/j.jcp.2018.10.045>.
- [43] Tack P, Victor J, Gemmel P, Annemans L. 3D-printing techniques in a medical setting: a systematic literature review. Biomed Eng Online 2016;15:115.
<https://doi.org/10.1186/s12938-016-0236-4>.
- [44] Ma Y, Ding P, Li L, Liu Y, Jin P, Tang J, et al. Three-dimensional printing for heart diseases: clinical application review. Bio-Des Manuf 2021;4:675–87.
<https://doi.org/10.1007/s42242-021-00125-8>.
- [45] Van Arsdell GS, Hussein N, Yoo S-J. Three-dimensional printing in congenital cardiac surgery-Now and the future. J Thorac Cardiovasc Surg 2020;160:515–9.
<https://doi.org/10.1016/j.jtcvs.2019.12.131>.
- [46] Ma XJ, Tao L, Chen X, Li W, Peng ZY, Chen Y, et al. Clinical application of three-dimensional reconstruction and rapid prototyping technology of multislice spiral computed tomography angiography for the repair of ventricular septal defect of tetralogy of Fallot. Genet Mol Res GMR 2015;14:1301–9.
<https://doi.org/10.4238/2015.February.13.9>.
- [47] Свободов АА, Гуласарян РС, Армаганова АА, Волков СС, Шилкин ДН, Черных НА. Применение 3D-моделирования для определения тактики хирургического лечения сложного врожденного порока сердца с аномалией расположения и формирования сердца. Грудная И Сердечно-Сосудистая Хирургия 2023;65:119–23. <https://doi.org/10.24022/0236-2791-2023-65-1-119-123>.
- [48] Xue X, Liu Z, Xue T, Chen W, Chen X. Machine learning for the prediction of acute kidney injury in patients after cardiac surgery. Front Surg 2022;9:946610.
<https://doi.org/10.3389/fsurg.2022.946610>.
- [49] Yang M, Liu C, Wang X, Li Y, Gao H, Liu X, et al. An Explainable Artificial Intelligence Predictor for Early Detection of Sepsis. Crit Care Med 2020;48:e1091–6.
<https://doi.org/10.1097/CCM.0000000000004550>.
- [50] Smith AH, Gray GM, Ashfaq A, Asante-Korang A, Rehman MA, Ahumada LM. Using machine learning to predict five-year transplant-free survival among infants with

hypoplastic left heart syndrome. *Sci Rep* 2024;14:4512. <https://doi.org/10.1038/s41598-024-55285-1>.

[51] Chang Junior J, Binuesa F, Caneco LF, Turquetto ALR, Arita ECTC, Barbosa AC, et al. Improving preoperative risk-of-death prediction in surgery congenital heart defects using artificial intelligence model: A pilot study. *PloS One* 2020;15:e0238199. <https://doi.org/10.1371/journal.pone.0238199>.

[52] Duci M, Bossi A, Uccheddu F, Fascetti-Leon F. A roadmap of artificial intelligence applications in pediatric surgery: a comprehensive review of applications, challenges, and ethical considerations. *Pediatr Surg Int* 2025;41:286. <https://doi.org/10.1007/s00383-025-06185-6>.

[53] Cooper JN, Minneci PC, Deans KJ. Postoperative neonatal mortality prediction using superlearning. *J Surg Res* 2018;221:311–9. <https://doi.org/10.1016/j.jss.2017.09.002>.

[54] Lal Vallath A, Sivasubramanian BP, Chatterjee A, Erva S, Ravikumar DB, Dasgupta I. Ventricular Septal Rupture and Artificial Intelligence (AI)-Assisted Healthcare. *Cureus* 2023;15:e36581. <https://doi.org/10.7759/cureus.36581>.

[55] Mohr FW, Falk V, Diegeler A, Walther T, Gummert JF, Bucerius J, et al. Computer-enhanced “robotic” cardiac surgery: experience in 148 patients. *J Thorac Cardiovasc Surg* 2001;121:842–53. <https://doi.org/10.1067/mtc.2001.112625>.

[56] Arghami A, Jahanian S, Daly RC, Hemmati P, Lahr BD, Rowse PG, et al. Robotic Mitral Valve Repair: A Decade of Experience With Echocardiographic Follow-up. *Ann Thorac Surg* 2022;114:1587–95. <https://doi.org/10.1016/j.athoracsur.2021.08.083>.

[57] Choi E, Schuetz A, Stewart WF, Sun J. Using recurrent neural network models for early detection of heart failure onset. *J Am Med Inform Assoc JAMIA* 2017;24:361–70. <https://doi.org/10.1093/jamia/ocw112>.

[58] Gorecki G-P, Tomescu D-R, Pleş L, Panaitescu A-M, Dragosloveanu Şerban, Scheau C, et al. Implications of using artificial intelligence in the diagnosis of

- sepsis/sepsis shock. *Germes* 2024;14:77–84. <https://doi.org/10.18683/germes.2024.1419>.
- [59] Zhu Z, Li C, Shen J, Wu K, Li Y, Liu K, et al. New Internet-Based Warfarin Anticoagulation Management Approach After Mechanical Heart Valve Replacement: Prospective, Multicenter, Randomized Controlled Trial. *J Med Internet Res* 2021;23:e29529. <https://doi.org/10.2196/29529>.
- [60] Liu S, Xu Q, Xu Z, Liu Z, Sun X, Xie G, et al. Reinforcement Learning to Optimize Ventilator Settings for Patients on Invasive Mechanical Ventilation: Retrospective Study. *J Med Internet Res* 2024;26:e44494. <https://doi.org/10.2196/44494>.
- [61] Tilborghs S, Liang T, Raptis S, Ishikita A, Budts W, Dresselaers T, et al. Automated biventricular quantification in patients with repaired tetralogy of Fallot using a three-dimensional deep learning segmentation model. *J Cardiovasc Magn Reson Off J Soc Cardiovasc Magn Reson* 2024;26:101092. <https://doi.org/10.1016/j.jocmr.2024.101092>.
- [62] Jacquemyn X, Kutty S, Manlhiot C. The Lifelong Impact of Artificial Intelligence and Clinical Prediction Models on Patients With Tetralogy of Fallot. *CJC Pediatr Congenit Heart Dis* 2023;2:440–52. <https://doi.org/10.1016/j.cjcpc.2023.08.005>.
- [63] Diller GP, Orwat S, Vahle J, Bauer UMM, Urban A, Sarikouch S, et al. Prediction of prognosis in patients with tetralogy of Fallot based on deep learning imaging analysis. *Heart* 2020;106:1007–14. <https://doi.org/10.1136/heartjnl-2019-315962>.
- [64] Mira A, Lamata P, Pushparajah K, Abraham G, Mauger CA, McCulloch AD, et al. Le Cœur en Sabot: shape associations with adverse events in repaired tetralogy of Fallot. *J Cardiovasc Magn Reson Off J Soc Cardiovasc Magn Reson* 2022;24:46. <https://doi.org/10.1186/s12968-022-00877-x>.
- [65] Ishikita A, McIntosh C, Hanneman K, Lee MM, Liang T, Karur GR, 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:e015205. <https://doi.org/10.1161/CIRCIMAGING.122.015205>.
- [66] Holt DB, El-Bokl A, Stromberg D, Taylor MD. Role of Artificial Intelligence in Congenital Heart Disease and Interventions. *J Soc Cardiovasc Angiogr Interv* 2025;4:102567. <https://doi.org/10.1016/j.jscai.2025.102567>.
- [67] Xi L, Xiang M, Wu C, Pan Z, Dai J, Wang G, 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;12:125–36. <https://doi.org/10.21037/tp-22-246>.
- [68] Jone P-N, Gearhart A, Lei H, Xing F, Nahar J, Lopez-Jimenez F, et al. Artificial Intelligence in Congenital Heart Disease: Current State and Prospects. *JACC Adv* 2022;1:100153. <https://doi.org/10.1016/j.jacadv.2022.100153>.
- [69] Samad MD, Wehner GJ, Arbabshirani MR, Jing L, Powell AJ, Geva T, et al. Predicting deterioration of ventricular function in patients with repaired tetralogy of Fallot using machine learning. *Eur Heart J - Cardiovasc Imaging* 2018;19:730–8. <https://doi.org/10.1093/ehjci/jey003>.
- [70] Ishikita A, McIntosh C, Lee MM, Raptis S, Liang T, Hanneman KA, 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:A12563–A12563. https://doi.org/10.1161/circ.146.suppl_1.12563.
- [71] Ishikita A, McIntosh C, Roche SL, Barron D, Oechslin E, Benson LN, 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:A13861–A13861. https://doi.org/10.1161/circ.148.suppl_1.13861.
- [72] Ishikita A, McIntosh C, Roche SL, Barron DJ, Oechslin E, Benson L, et al. Incremental value of machine learning for risk prediction in tetralogy of Fallot. *Heart* 2024;110:560–8. <https://doi.org/10.1136/heartjnl-2023-323296>.

- [73] Lo Muzio FP, Rozzi G, Rossi S, Luciani GB, Foresti R, Cabassi A, et al. Artificial Intelligence Supports Decision Making during Open-Chest Surgery of Rare Congenital Heart Defects. *J Clin Med* 2021;10:5330. <https://doi.org/10.3390/jcm10225330>.
- [74] Faerber JA, Huang J, Zhang X, Song L, DeCost G, Mascio CE, 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. <https://doi.org/10.3389/fcvm.2021.685855>.
- [75] Авраменко АА, Арнаутова ИВ, Апханова ТВ, Барышникова ИЮ, Белов ВН, Бокерия ЛА, et al. Тетрада Фалло. Клинические рекомендации 2024. Бюллетень НЦССХ Им Ан Бакулева Рамн Сердечно-Сосудистые Заболевания 2025;26:228–66. <https://doi.org/10.24022/1810-0694-2025-26-3-228-265>.
- [76] Аتماшкин АА, Ким АИ, Рогова ТВ, Григорьянц ТР, Эдиев МО. Тетрада Фалло: место транспредсердной реконструкции выводного отдела правого желудочка с сохранением гипоплазированного кольца легочной артерии у детей младенческого возраста. *Детские Болезни Сердца И Сосудов* 2023;20:87–99. <https://doi.org/10.24022/1810-0686-2023-20-2-87-99>.
- [77] Jacob R. Miller, Expert Consensus Panel:, Stephens EH, Goldstone AB, Glatz AC, Kane L, et al. The American Association for Thoracic Surgery (AATS) 2022 Expert Consensus Document: Management of infants and neonates with tetralogy of Fallot. *J Thorac Cardiovasc Surg* 2023;165:221–50. <https://doi.org/10.1016/j.jtcvs.2022.07.025>.
- [78] Goldstein BH, Petit CJ, Qureshi AM, McCracken CE, Kelleman MS, Nicholson GT, et al. Comparison of Management Strategies for Neonates With Symptomatic Tetralogy of Fallot. *J Am Coll Cardiol* 2021;77:1093–106. <https://doi.org/10.1016/j.jacc.2020.12.048>.
- [79] Flores-Umanzor E, Alshehri B, Keshvara R, Wilson W, Osten M, Benson L, et al. Transcatheter-Based Interventions for Tetralogy of Fallot Across All Age Groups. *JACC Cardiovasc Interv* 2024;17. <https://doi.org/10.1016/j.jcin.2024.02.009>.

- [80] Head SJ, Howell NJ, Osnabrugge RLJ, Bridgewater B, Keogh BE, Kinsman R, et al. The European Association for Cardio-Thoracic Surgery (EACTS) database: an introduction. *Eur J Cardio-Thorac Surg Off J Eur Assoc Cardio-Thorac Surg* 2013;44:e175-180. <https://doi.org/10.1093/ejcts/ezt303>.
- [81] Голухова ЕЗ, Ким АИ, Завалихина ТВ, Нефедова (Зернова) ИЕ, Черногринов АЕ, Авакова СА. Анализ оказания медицинской помощи детям с врожденными пороками сердца в Российской Федерации и предпосылки к созданию регистра в современную эру цифровых медицинских информационных систем. *Креативная Кардиология* 2023;17:315–21. <https://doi.org/10.24022/1997-3187-2023-17-3-315-321>.
- [82] Трошин ЛВ, Анцыгин НВ, Глотова ЕВ, Довгань ВС, Ямгуров ДР, Кукулевич АМ, et al. Результаты протезирования клапана лёгочной артерии после транскатетерной пластики у детей с тетрадой Фалло, Издательство РАМН, Москва; 2025, р. 172.
- [83] Минаев АВ, Данилов ТЮ, Чиаурели МР, Ковалев ДВ, Самсонов ВБ, Донцова ВИ, et al. Радикальная коррекция Тетрады Фалло во взрослом возрасте: клинические особенности и результаты. *Бюллетень НЦССХ Им Ан Бакулева Рамн Сердечно-Сосудистые Заболевания* 2023;24:8.
- [84] Opatowsky AR, Khairy P, Diller G, Kasparian NA, Brophy J, Jenkins K, et al. Clinical Risk Assessment and Prediction in Congenital Heart Disease Across the Lifespan: JACC Scientific Statement. *J Am Coll Cardiol* 2024;83:2092–111. <https://doi.org/10.1016/j.jacc.2024.02.055>.
- [85] Romeo JLR, Etnel JRG, Takkenberg JJM, Roos-Hesselink JW, Helbing WA, van de Woestijne P, et al. Outcome after surgical repair of tetralogy of Fallot: A systematic review and meta-analysis. *J Thorac Cardiovasc Surg* 2020;159:220-236.e8. <https://doi.org/10.1016/j.jtcvs.2019.08.127>.
- [86] Cuypers JAAE, Menting ME, Konings EEM, Opić P, Utens EMWJ, Helbing WA, et al. Unnatural history of tetralogy of Fallot: prospective follow-up of 40 years after

- surgical correction. *Circulation* 2014;130:1944–53.
<https://doi.org/10.1161/CIRCULATIONAHA.114.009454>.
- [87] Ruiz-Fernández D, Monsalve Torra A, Soriano-Payá A, Marín-Alonso O, Triana Palencia E. Aid decision algorithms to estimate the risk in congenital heart surgery. *Comput Methods Programs Biomed* 2016;126:118–27.
<https://doi.org/10.1016/j.cmpb.2015.12.021>.
- [88] Chen H, Wu L, Dou Q, Qin J, Li S, Cheng J-Z, et al. Ultrasound Standard Plane Detection Using a Composite Neural Network Framework. *IEEE Trans Cybern* 2017;47:1576–86. <https://doi.org/10.1109/TCYB.2017.2685080>.
- [89] Dong J, Liu S, Liao Y, Wen H, Lei B, Li S, et al. A Generic Quality Control Framework for Fetal Ultrasound Cardiac Four-Chamber Planes. *IEEE J Biomed Health Inform* 2020;24:931–42. <https://doi.org/10.1109/JBHI.2019.2948316>.
- [90] Arnaout R, Curran L, Zhao Y, Levine JC, Chinn E, Moon-Grady AJ. An ensemble of neural networks provides expert-level prenatal detection of complex congenital heart disease. *Nat Med* 2021;27:882–91. <https://doi.org/10.1038/s41591-021-01342-5>.
- [91] Gharehbaghi A, Lindén M, Babic A. A Decision Support System for Cardiac Disease Diagnosis Based on Machine Learning Methods. *Stud Health Technol Inform* 2017;235:43–7.
- [92] Gharehbaghi A, Sepehri AA, Babic A. Distinguishing Septal Heart Defects from the Valvular Regurgitation Using Intelligent Phonocardiography. *Stud Health Technol Inform* 2020;270:178–82. <https://doi.org/10.3233/SHTI200146>.
- [93] Lai Z, Vadlaputi P, Tancredi DJ, Garg M, Koppel RI, Goodman M, et al. Enhanced Critical Congenital Cardiac Disease Screening by Combining Interpretable Machine Learning Algorithms. *Annu Int Conf IEEE Eng Med Biol Soc IEEE Eng Med Biol Soc Annu Int Conf* 2021;2021:1403–6.
<https://doi.org/10.1109/EMBC46164.2021.9630111>.
- [94] Jalali A, Lonsdale H, Do N, Peck J, Gupta M, Kutty S, et al. Deep Learning for Improved Risk Prediction in Surgical Outcomes. *Sci Rep* 2020;10:9289.
<https://doi.org/10.1038/s41598-020-62971-3>.

- [95] Atallah J, Gonzalez Corcia MC, Walsh EP, Participating Members of the Pediatric and Congenital Electrophysiology Society. Ventricular Arrhythmia and Life-Threatening Events in Patients With Repaired Tetralogy of Fallot. *Am J Cardiol* 2020;132:126–32. <https://doi.org/10.1016/j.amjcard.2020.07.012>.
- [96] Diller G-P, Kempny A, Babu-Narayan SV, Henrichs M, Brida M, Uebing A, et al. Machine learning algorithms estimating prognosis and guiding therapy in adult congenital heart disease: data from a single tertiary centre including 10 019 patients. *Eur Heart J* 2019;40:1069–77. <https://doi.org/10.1093/eurheartj/ehy915>.
- [97] Тимофеева О.Ю., Григорьянц Т.Р., Ким А.И. Автоматизированные системы поддержки принятия решений при врожденных пороках сердца: анализ последних достижений. *Детские Болезни Сердца И Сосудов* 2026;5–11.
- [98] Bertsimas D, Zhuo D, Dunn J, Levine J, Zuccarelli E, Smyrnakis N, et al. Adverse Outcomes Prediction for Congenital Heart Surgery: A Machine Learning Approach. *World J Pediatr Congenit Heart Surg* 2021;12:453–60. <https://doi.org/10.1177/21501351211007106>.
- [99] Ким АИ, Акатов ДС, Рогова ТВ, Тимофеева ОЮ, Глазунов АЮ, Кретов АА. Программа, рекомендующая хирургическую тактику у детей с тетрадой Фалло n.d.
- [100] Тимофеева ОЮ, Акатов ДС, Глазунов АЮ, Ким АИ. Возможности искусственного интеллекта при выборе тактики хирургического лечения при тетраде Фалло. *Кардиология И Сердечно-Сосудистая Хирургия* 2025;18:560–5. <https://doi.org/10.17116/kardio202518051560>.
- [101] Sethi Y, Patel N, Kaka N, Desai A, Kaiwan O, Sheth M, et al. Artificial Intelligence in Pediatric Cardiology: A Scoping Review. *J Clin Med* 2022;11:7072. <https://doi.org/10.3390/jcm11237072>.
- [102] Тимофеева ОЮ, Акатов ДС, Глазунов АЮ, Ким АИ, Рогова ТВ, Попеня ДЮ, et al. Искусственный интеллект в оптимизации хирургического лечения тетрады Фалло: разработка и валидация прогностической модели. *Наука*

Молодых Erud Juvenium 2025;13:603–14.
<https://doi.org/10.23888/HMJ2025134603-614>.

[103] Ким АИ, Григорьянц ТР, Тимофеева ОЮ. Стратегии лечения тетрады Фалло: радикальная коррекция, реконструкция запирающего элемента при трансаннулярной пластике лёгочной артерии, ремоделирование правого желудочка. Детские Болезни Сердца И Сосудов 2023;20:100–9.
<https://doi.org/10.24022/1810-0686-2023-20-2-100-109>.