Никита Куликов

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В МЕДИЦИНЕ

ОТ АЛГОРИТМА ДО КЛИНИЧЕСКОГО РЕШЕНИЯ

Практическое руководство по доказательствам, внедрению и безопасности



- Диагностика и прогнозирование
- Поддержка клинических решений
- Анализ медицинских данных
- Внедрение в клиники
- Правовые и этические аспекты
- Риски и безопасность

КЛИНИЧЕСКАЯ ЭФФЕКТИВНОСТЬ | ДАННЫЕ И ДОКАЗАТЕЛЬСТВА | ВНЕДРЕНИЕ И ИНТЕГРАЦИЯ | БЕЗОПАСНОСТЬ И КОНФИДЕНЦИАЛЬНОСТЬ | РЕГУЛИРОВАНИЕ И ОТВЕТСТВЕННОСТЬ

Никита Куликов

Искусственный интеллект в медицине

https://litres.ru/74747908
SelfPub; 2026

Аннотация

ИИ не заменяет врача, а меняет распределение задач. Алгоритм берёт на себя рутину, скорость и первичный анализ, но клиническое суждение, ответственность и финальное решение остаются за человеком. Там, где это правило соблюдается, ИИ приносит реальную пользу. Там, где его забывают, появляются новые риски – от слепого доверия к модели до скрытых ошибок, которые никто не проверяет.

Отдельная часть посвящена ЭКГ как модельному примеру: именно электрокардиография стала полигоном, где ИИ прошёл путь от распознавания ритма до выявления скрытых кардиомиопатий, и где уже накоплен масштабный опыт реального внедрения, включая московскую ЕМИАС.

Книга адресована сразу нескольким аудиториям. Врачам она поможет понять, как устроены алгоритмы, чего от них ждать и как не потерять клиническую бдительность. Организаторам здравоохранения – как планировать внедрение, оценивать

эффективность и управлять изменениями. Разработчикам и аналитикам – как выглядит клинический контекст.

Содержание

ВВЕДЕНИЕ 6
Часть I. Основы ИИ в медицине 11
Глава 1. Зачем медицине искусственный интеллект 11
Глава 2. Данные как фундамент клинического ИИ 14
Глава 3. Типы клинических задач и алгоритмов 18
Глава 4. Как оценивать медицинский ИИ 22
Глава 5. Этика, право и регулирование 26
Глава 6. Кардиология и ЭКГ 30
Глава 7. Радиология и визуализация 34
Глава 8. Патоморфология 38
Глава 9. Офтальмология 41
Глава 10. Дерматология 44
Глава 11. Онкология 47
Глава 12. Другие направления 50
Конец ознакомительного фрагмента. 51

Никита Куликов Искусственный интеллект в медицине

ТИТУЛЬНЫЙ ЛИСТ

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В МЕДИЦИНЕ: от алгоритма до клинического решения

Практическое руководство по доказательствам, внедрению и безопасности

Никита Куликов

ВВЕДЕНИЕ

Эта книга написана в тот момент, когда искусственный интеллект перестал быть экспериментом и стал частью повседневной клинической практики.

Ещё несколько лет назад разговоры об ИИ в медицине велись в основном на конференциях и в научных статьях. Сегодня алгоритмы анализируют кардиограммы в поликлиниках, приоритизируют срочные находки в радиологии, помогают патологам искать метастазы и подсказывают врачу приёмного отделения, кому из пациентов нужна помощь в первую очередь. Это уже не будущее – это настоящее, и оно требует не восторга, а трезвого профессионального разговора.

Главный тезис книги прост: **ИИ не заменяет врача, а меняет распределение задач**. Алгоритм берёт на себя рутину, скорость и первичный анализ, но клиническое суждение, ответственность и финальное решение остаются за человеком. Там, где это правило соблюдается, ИИ приносит реальную пользу. Там, где его забывают, появляются новые риски – от слепого доверия к модели до скрытых ошибок, которые никто не проверяет.

Книга адресована сразу нескольким аудиториям. **Врачам** она поможет понять, как устроены алгоритмы, чего от них ждать и как не потерять клиническую бдительность. **Орга-**

низаторам здравоохранения – как планировать внедрение, оценивать эффективность и управлять изменениями. **Разработчикам и аналитикам** – как выглядит клинический контекст, в который приходит их модель. **Студентам** – как смотреть на ИИ не как на чудо, а как на инструмент с доказательствами, ограничениями и зоной ответственности.

Структура книги выстроена как путь от основ к практике. Сначала мы разберём, на каких данных и алгоритмах строится медицинский ИИ и как его оценивать. Затем пройдём по ключевым специальностям – кардиологии, радиологии, патоморфологии, офтальмологии, дерматологии, онкологии.

Отдельная часть посвящена ЭКГ как модельному примеру: именно электрокардиография стала полигоном, где ИИ прошёл путь от распознавания ритма до выявления скрытых кардиомиопатий, и где уже накоплен масштабный опыт реального внедрения, включая московскую ЕМИАС.

Далее – внедрение в систему здравоохранения, экономика, безопасность, этика, право и образование. Завершают книгу практикум, дорожная карта и приложения с чек-листами и метриками.

Одна терминологическая оговорка. Под «искусственным интеллектом» в этой книге понимаются прежде всего **машинное обучение и клинические алгоритмы поддержки решений**: модели, обученные на данных и выдающие прогноз, классификацию или рекомендацию.

Мы не будем обсуждать фантастические сценарии «силь-

ного ИИ» – они не помогают врачу сегодня. Зато будем говорить о том, что можно проверить, измерить и внедрить.

Книга не обещает лёгких решений. Она предлагает дисциплину мышления: сначала данные и валидация, потом пилот, потом масштаб. Если этот порядок соблюдён, ИИ становится надёжным помощником. Если нарушен – дорогой игрушкой или, хуже того, источником новых ошибок. Именно об этом – всё, что дальше

Оглавление

ВВЕДЕНИЕ
Часть I. Основы ИИ в медицине
Глава 1. Зачем медицине искусственный интеллект
Глава 2. Данные как фундамент клинического ИИ
Глава 3. Типы клинических задач и алгоритмов
Глава 4. Как оценивать медицинский ИИ
Глава 5. Этика, право и регулирование
Часть II. Клинические применения по специальностям
Глава 6. Кардиология и ЭКГ
Глава 7. Радиология и визуализация
Глава 8. Патоморфология
Глава 9. Офтальмология
Глава 10. Дерматология
Глава 11. Онкология

Глава 12. Другие направления
Часть III. ЭКГ как модельный пример применения ИИ
Глава 13. Почему ЭКГ идеальна для ИИ
Глава 14. Московская модель: ЕМИАС и цифровые электрокардиографы
Глава 15. Экстренная диагностика: инфаркт и снижение ложных тревог
Глава 16. Скрытые болезни: ГКМП, амилоидоз, ревматическая болезнь
Глава 17. Новые технологии: смартфон, ECG-GPT, носимые устройства
Глава 18. Ограничения и ошибки ЭКГ-ИИ
Глава 19. Чек-лист внедрения ЭКГ-ИИ
Часть IV. Внедрение ИИ в систему здравоохранения
Глава 20. Архитектура и интеграция
Глава 21. Клинические процессы и роли
Глава 22. Валидация и мониторинг
Глава 23. Безопасность и кибербезопасность
Глава 24. Экономика и оценка эффективности
Глава 25. Управление изменениями и обучение
Глава 26. Региональные модели
Часть V. Человек, этика, право, общество
Глава 27. Врач и ИИ: новая роль
Глава 28. Пациент и доверие
Глава 29. Прозрачность и объяснимость
Глава 30. Предвзятость и справедливость

Глава 31. Ответственность и юридические риски
Глава 32. Образование специалистов
Часть VI. Будущее и практикум
Глава 33. Тренды: мультимодальность и генеративный ИИ
Глава 34. Дорожная карта внедрения
Глава 35. Практические кейсы и сценарии
Глава 36. Домашняя ЭКГ как новый базовый навык: от тонометра к монитору ритма
Заключение
Приложения
Приложение А. Глоссарий
Приложение Б. Чек-листы внедрения и аудита
Приложение В. Метрики оценки клинического ИИ
Приложение Г. Шаблон протокола локальной валидации

Часть I. Основы ИИ в медицине

Глава 1. Зачем медицине искусственный интеллект

Медицина столкнулась с парадоксом: возможностей для диагностики и лечения стало больше, чем способности человека их своевременно обработать. Объём медицинских данных растёт быстрее, чем число врачей. Один пациент за госпитализацию генерирует тысячи лабораторных значений, изображений и сигналов. Врач физически не может просматривать всё с одинаковым вниманием. Именно в этом разрыве между объёмом информации и ограниченным человеческим ресурсом и появляется ИИ.

Первый аргумент в пользу ИИ – **дефицит кадров и времени**. Приём длится минуты, а решений нужно принять десятки. Алгоритм не устаёт, не отвлекается и обрабатывает сигнал за секунды. Он не заменяет врача, но снимает с него часть рутины: первичную сортировку, измерение, поиск отклонений по формальным признакам. Освободившееся внимание врач может направить туда, где человек незаменим – на клиническое суждение, общение с пациентом, сложные и

нетипичные случаи.

Второй аргумент – **скорость в критических ситуациях**. При инфаркте, инсульте или сепсисе счёт идёт на минуты. ИИ способен мгновенно выделить тревожный сигнал из потока и передать его дежурному специалисту. Это не отменяет решения врача, но сокращает путь от данных до действия.

Третий аргумент – **поиск скрытого**. Алгоритмы умеют находить на стандартных исследованиях признаки болезней, которые традиционно выявляются только другими методами. ЭКГ может подсказать о кардиомиопатии, снимок – о редкой патологии. Это расширяет возможности скрининга там, где раньше он был недоступен.

Однако честный разговор требует назвать и **где ИИ пока слаб**. Редкие болезни представлены в данных плохо, и модель может их не увидеть. Малые выборки дают нестабильные результаты. Ответственность за ошибку нельзя переложить на алгоритм. Наконец, ИИ не понимает контекста жизни пациента – он видит данные, но не человека. Поэтому книга построена не вокруг восторга, а вокруг границ применимости.

Отдельно стоит развенчать несколько мифов. Миф первый: «ИИ заменит врача». Реальность: он меняет распределение задач, а не упраздняет профессию. Миф второй: «ИИ всегда точнее человека». Реальность: на одних задачах точнее, на других – нет, и это нужно проверять. Миф третий:

«ИИ объективен». Реальность: модель наследует смещения своих данных. Миф четвёртый: «Внедрить ИИ просто». Реальность: технология – меньшая часть работы, большая – интеграция, обучение и контроль.

Из этого следует главная мысль главы: **ИИ нужен медицине не как замена человека, а как инструмент, снижающий нагрузку и повышающий скорость там, где это измеримо полезно**. Всё дальнейшее в книге – разбор того, как отличить полезное применение от красивого, но бесполезного.

Глава 2. Данные как фундамент клинического ИИ

Любая модель машинного обучения – это не более чем отражение данных, на которых она обучена. В медицине это правило приобретает особую остроту: ошибки в данных оборачиваются ошибками у постели пациента. Поэтому разговор об ИИ правильнее начинать не с алгоритмов, а с данных – откуда они берутся, какого они качества и какие риски в себе несут.

Источники клинических данных разнообразны. Электронные медицинские карты хранят структурированные записи – диагнозы, назначения, лабораторные значения – и неструктурированные тексты врачебных осмотров. Системы визуализации содержат изображения: рентген, КТ, МРТ, гистологию. Цифровые приборы дают сигналы – ЭКГ, ЭЭГ, мониторинг жизненных функций. Носимые устройства добавляют непрерывные данные о ритме, активности, сне. Каждый источник имеет свою специфику, свои единицы измерения и свои дефекты.

Центральная проблема – **качество данных**. Даже в крупных базах встречаются пропуски, дубли, ошибочные единицы, несогласованные справочники. Лабораторное значение может быть записано в разных единицах в разных учрежде-

ниях. Диагноз может быть кодирован по-разному. Временные метки могут не совпадать с реальным моментом измерения. Модель, обученная на таких данных, наследует все эти несовершенства и воспроизводит их с уверенностью, которая не имеет основания.

Особого внимания требует **разметка**. Для обучения с учителем нужны метки – «есть болезнь» или «нет». В медицине метки часто неоднозначны: два опытных врача могут разойтись в трактовке одного снимка. Если разметка делалась по историческим диагнозам, она отражает не истину, а сложившуюся практику, включая её ошибки. Если разметка делалась узкой группой экспертов, она может не отражать разнообразие реальной популяции. Качество меток – это качество потолка модели: выше него алгоритм не поднимется.

Отдельно стоит **смещение данных**. Если обучающая выборка собрана в крупном городском центре, она может плохо представлять сельскую популяцию, пожилых пациентов, беременных, людей с редкими сопутствующими заболеваниями. Модель, обученная на одной группе, при переносе в другую начинает ошибаться тише и опаснее – она не предупреждает о своей неуверенности. Смещение по полу, возрасту, этничности и социально-экономическому статусу – не абстрактная этическая проблема, а измеримый источник клинического риска.

Ещё одна тонкость – **утечка данных**. Если при подготовке выборки в обучающий набор случайно попадают сведе-

ния, которые в реальной практике будут недоступны на момент прогноза, модель показывает блестящие результаты на тесте и разочаровывает в клинике. Классический пример – когда в признаки попадает информация о последующих назначениях или исходах. Такие модели выглядят точными, но предсказывают не то, что нужно.

Ответом на часть этих проблем становится **федеративное обучение** и защита персональных данных. Вместо того чтобы собирать все данные в одном месте, модель обучается на локальных данных в разных учреждениях, обмениваясь только параметрами, а не самими записями. Это снижает юридические риски и позволяет использовать данные, которые иначе остались бы недоступны. Но и здесь нужна дисциплина: федеративная схема не отменяет требований к качеству и репрезентативности.

Наконец, важно развеять простое заблуждение: **«больше данных – всегда лучше»**. Объём не заменяет качество. Миллион однотипных записей из одного центра не научит модель разнообразию. Хорошо размеченная, разнообразная и честно описанная выборка среднего размера часто полезнее гигантской, но смещённой. Вопрос не в том, сколько данных, а в том, насколько они представляют ту популяцию, где модель будет работать.

Главный вывод главы: **данные – это клинический актив, а не побочный продукт**. Их нужно собирать осознанно, описывать прозрачно, проверять на смещения и защи-

щать. Алгоритм – лишь надстройка над этим фундаментом. Если фундамент слаб, никакая архитектура модели не спасёт.

Глава 3. Типы клинических задач и алгоритмов

Данные становятся полезными только тогда, когда под них правильно выбрана задача. Одна из самых частых ошибок при разработке медицинского ИИ – начать с модного алгоритма, а не с клинического вопроса. Правильный порядок обратный: сначала формулируется, какое решение нужно поддержать, затем подбирается тип задачи, и лишь потом – архитектура модели. Эта глава описывает основные типы клинических задач и соответствующие им классы алгоритмов.

Классификация – самый распространённый тип. Модель относит объект к одной из категорий: «есть патология» или «нет», «доброкачественное» или «злокачественное», «норма», «пограничное», «патология». Именно так работают многие системы анализа ЭКГ и маммографии. Важно помнить: бинарная классификация почти всегда скрывает порог. Модель выдаёт вероятность, а решение принимается при некотором пороге, и выбор порога – это клиническое, а не техническое решение, потому что он определяет баланс между пропущенными и ложными случаями.

Регрессия предсказывает непрерывную величину: уровень биомаркера, риск события в процентах, предпола-

гаемую длительность госпитализации, возраст сердца по ЭКГ. Регрессионные модели полезны для прогнозирования и стратификации, но их результаты труднее интерпретировать клинически: «риск 17%» требует объяснения, что этот процент значит для конкретного пациента.

Детекция и сегментация – основа компьютерного зрения. Детекция отвечает на вопрос «где находится объект»: очаг на снимке, новообразование, зубец на сигнале. Сегментация размечает границы: контур органа, зона ишемии, область интереса на гистологическом препарате. В радиологии и патоморфологии эти задачи позволяют не только найти патологию, но и измерить её, что критично для оценки динамики и планирования лечения.

Анализ временных рядов занимает особое место в медицине, потому что многие сигналы имеют временную природу: ЭКГ, ЭЭГ, артериальное давление, частота дыхания, данные мониторинга в реанимации. Здесь модель должна учитывать не только значения, но и их последовательность, ритм, интервалы. Именно на этом типе задач построены системы, предсказывающие ухудшение состояния пациента за часы до клинических проявлений.

Обработка естественного языка работает с текстом: врачебными записями, заключениями, выписками. Задачи здесь разнообразны – извлечение структурированных признаков из свободного текста, классификация жалоб, поиск упоминаний лекарств и побочных эффектов, автоматиче-

ское формирование черновиков заключений. Большие языковые модели сделали этот класс задач особенно заметным, но одновременно и особенно рискованным: генеративный текст может звучать убедительно, не будучи верным.

Мультимодальные модели объединяют несколько типов данных – например, изображение, текст и лабораторные показатели. Клинически это наиболее перспективное направление, потому что реальный врач тоже опирается на разные источники. Но мультимодальность усложняет и валидацию: нужно проверять не только каждую модальность, но и то, как модель их сочетает, и не подменяет ли она одно информативным признаком другое.

Параллельно с типом задачи стоит различать **типы обучения**. Обучение с учителем требует размеченных данных и даёт наиболее предсказуемые результаты. Обучение без учителя помогает находить структуру в данных – например, группы пациентов со схожими признаками, – но его результаты труднее привязать к клиническому решению. Обучение с подкреплением в медицине пока применяется ограниченно, в основном в исследовательских задачах выбора тактики лечения.

Отдельно нужно сказать о **генеративных моделях**. Они не предсказывают метку, а создают новый контент: текст, изображение, ответ на вопрос. В клинической документации это открывает реальные возможности – черновики описаний, суммаризация истории болезни, помощь в кодирова-

нии. Но генеративная модель может «галлюцинировать» – выдавать правдоподобный, но ложный текст. Поэтому её место в клинике – там, где есть обязательная проверка человеком, а не там, где решение принимается автоматически.

Наконец, важное различение – **уровень вмешательства**. Одни алгоритмы только информируют: показывают вероятность, выделяют область. Другие рекомендуют действие. Третьи встроены в автоматический контур, например приоритизируют очередь исследований. Чем выше уровень автономии, тем строже должны быть требования к валидации, мониторингу и возможности человека вмешаться.

Главный вывод главы: **задача первична, алгоритм вторичен**. Клинический вопрос определяет тип задачи, тип задачи – требования к данным, а данные – допустимый уровень автономии. Когда этот порядок соблюдён, модель решает реальную проблему. Когда нарушен, появляется технически красивый инструмент, которому не находится места в клиническом процессе.

Глава 4. Как оценивать медицинский ИИ

Модель, которая хорошо работает на бумаге, не обязательно полезна у постели пациента. Разрыв между результатами в статье и реальной практикой – одна из главных проблем медицинского ИИ. Эта глава посвящена тому, как оценивать алгоритмы так, чтобы отличать клинически значимый результат от статистически красивого.

Начинать нужно с **базовых метрик качества**. Чувствительность показывает, какую долю больных модель выявляет; специфичность – какую долю здоровых она правильно называет здоровыми. Эти два показателя находятся в обратной зависимости: снижая порог, мы ловим больше больных, но получаем больше ложных тревог. Поэтому по отдельности они мало о чём говорят – важна их пара и клинический контекст. Для скрининга опасного заболевания приоритет отдаётся чувствительности, для подтверждающего теста – специфичности.

Однако чувствительности и специфичности недостаточно. Нужны **прогностические ценности** – PPV[1] и NPV[2], ко-

[1] **Положительная прогностическая ценность (PPV, Positive Predictive Value)** — это вероятность того, что у человека с положительным результатом диагностического теста действительно есть исследуемое заболевание или состо-

торые отвечают на практический вопрос: если модель сказала «патология», какова вероятность, что пациент действительно болен? Эти показатели зависят от распространённости болезни в популяции, и именно здесь часто рушатся иллюзии: алгоритм с отличными метриками в исследовании может давать массу ложных срабатываний при низкой распространённости в реальной практике.

AUC[3] – площадь под ROC-кривой – популярная интегральная метрика, но её легко переоценить. AUC усредняет качество по всем возможным порогам, тогда как в клинике работает один конкретный порог. Две модели с одинаковым AUC могут вести себя совершенно по-разному при выбранной рабочей точке. Поэтому AUC полезна для сравнения, но не заменяет анализа при рабочем пороге.

Отдельно стоит **калибровка**. Модель может правильно ранжировать пациентов по риску и при этом систематически завышать или занижать абсолютные вероятности. Если алгоритм говорит «риск 30%», а на практике событие происходит у 10%, клиницист, опирающийся на эту цифру, при-

---

яние. Этот показатель помогает оценить надёжность положительных результатов теста.

[2] **Отрицательная прогностическая ценность (Negative Predictive Value, NPV)** в медицине — это вероятность того, что заболевание действительно отсутствует у пациента с отрицательным результатом диагностического теста

[3] **AUC (Area Under the Curve, площадь под ROC-кривой)** — это метрика, которая оценивает способность бинарного классификатора ранжировать объекты двух классов. Она сводит всю информацию, представленную ROC-кривой, к одному числу

мет неверное решение. Калибровка проверяется графически и численно, и она критична везде, где вероятность используется для выбора тактики.

Ещё один уровень – **клиническая полезность**. Метрики качества отвечают на вопрос «насколько точно модель предсказывает», а клиническая полезность – «улучшает ли она исходы». Это разные вещи. Анализ полезности может включать оценку числа пациентов, которых нужно обследовать, чтобы предотвратить одно событие, влияния на время до диагноза, на долю ненужных процедур. Модель, немного уступающая по AUC, но лучше встроенная в процесс, может приносить больше пользы.

Ключевое требование – **валидация**. Внутренняя валидация на отложенной части тех же данных показывает, что модель не переобучена. Внешняя валидация на данных другого учреждения, другого периода или другой популяции показывает, что модель переносима. Именно внешняя валидация чаще всего выявляет проблемы: домен-сдвиг, различия в оборудовании, в протоколах, в кодировании. Без неё заявлять о готовности к клинике нельзя.

Самым убедительным доказательством остаются **проспективные исследования** и рандомизированные испытания, где алгоритм встроен в реальный процесс и оценивается его влияние на исходы. Таких исследований пока немного, и это честно признаётся в литературе. Ретроспективные работы полезны для отбора идей, но не заменяют проспек-

тивной проверки.

Наконец, типичные **ошибки в исследованиях ИИ**: утечка данных, отсутствие внешней валидации, сравнение с искусственно ослабленным базовым методом, отбор показательных примеров вместо систематической оценки, отсутствие описания популяции и условий применения. Эти ошибки часто незаметны в тексте статьи, но именно они определяют, можно ли доверять результату.

Главный вывод главы: **оценка ИИ – это клиническая дисциплина, а не техническая формальность**. Хорошая модель должна быть точной, откалиброванной, проверенной на чужой популяции и полезной в реальном процессе. Только совокупность этих критериев позволяет говорить о готовности к внедрению.

Глава 5. Этика, право и регулирование

Технология, которая влияет на здоровье человека, не может существовать вне правового и этического поля. Медицинский ИИ – не исключение. Более того, здесь пересекаются сразу несколько регуляторных режимов: обращение медицинских изделий, защита персональных данных, врачебная тайна, ответственность за причинение вреда. Разобраться в этом необходимо каждому, кто разрабатывает, внедряет или использует алгоритмы.

Первый вопрос – **регуляторный статус**. Медицинское программное обеспечение во многих юрисдикциях приравнивается к медицинскому изделию и требует регистрации. Это означает, что разработчик должен доказать безопасность и эффективность, предоставить документацию, описать показания и противопоказания, а также обеспечить постмаркетинговый мониторинг. Алгоритм, который выдаёт диагностическую рекомендацию, – это не «просто программа», а изделие с клиническими обязательствами. Важно и то, что регистрация обычно привязана к заявленным условиям применения: модель, одобренная для одного типа оборудования или популяции, не автоматически переносится на другие.

Второй вопрос – **ответственность**. Когда алгоритм ошибается, кто отвечает: врач, который принял решение, медицинская организация или разработчик? Правовая практика в разных странах различается, но общий принцип таков: врач остаётся субъектом клинического решения и не освобождается от ответственности ссылкой на рекомендацию ИИ. Разработчик отвечает за качество и безопасность изделия в пределах заявленных характеристик. Медицинская организация – за организацию процесса, обучение персонала и условия применения. Эта трёхчастная ответственность требует прозрачности: кто, на каком основании и с какой проверкой принял решение.

Третий вопрос – **данные и согласие**. Медицинские данные относятся к особо чувствительным категориям. Их обработка требует законного основания, защиты, ограничения целей и, как правило, информированного согласия пациента. Пациент должен понимать, что его данные используются для работы алгоритма, какие результаты он получает и как они влияют на его лечение. Особую сложность создаёт вторичное использование данных для обучения моделей: здесь нужны либо обезличивание, либо специальные правовые режимы, либо федеративные схемы, при которых данные не покидают учреждение.

Четвёртый вопрос – **прозрачность и объяснимость**. Этический принцип гласит, что пациент и врач имеют право знать, на каком основании принято решение. На практи-

ке «объяснимый ИИ» – это спектр: от полностью «чёрного ящика» до моделей, где вклад каждого признака можно увидеть. Полная интерпретируемость не всегда достижима и не всегда гарантирует безопасность: модель может быть объяснимой, но неверной. Поэтому прозрачность должна пониматься шире – как раскрытие происхождения данных, известных ограничений, условий применения и результатов валидации, а не только как визуализация признаков.

Пятый вопрос – **аудит и подотчётность**. Алгоритм, работающий в клинике, должен оставлять след: какие данные использовались, какая версия модели применялась, какое решение было предложено и что сделал врач. Без такой документации невозможно ни разобрать инцидент, ни улучшить систему, ни доказать соблюдение требований. Аудит должен быть регулярным: модель деградирует со временем, меняется популяция, обновляются протоколы.

Наконец, **этические принципы** задают рамку, которая шире правовых норм. Польза и безопасность: применение оправдано, только если польза доказана. Справедливость: алгоритм не должен систематически ухудшать помощь уязвимым группам. Автономия: пациент сохраняет право на информацию и выбор. Подотчётность: у каждого решения есть ответственный субъект. Эти принципы не дают готовых ответов на все случаи, но помогают задавать правильные вопросы до того, как технология внедрена.

Главный вывод главы: **право и этика – не бюрократи-**

ческое препятствие, а часть клинического качества. Алгоритм, внедрённый без регуляторной ясности, без согласия, без прозрачности и без аудита, создаёт риски, которые не компенсируются точностью модели. Устойчивое внедрение начинается с правовой и этической определённости, а не заканчивается ею.

Часть II. Клинические применения по специальностям

Глава 6. Кардиология и ЭКГ

Кардиология стала первой специальностью, где ИИ вышел из исследовательской лаборатории в повседневную практику. Причина не в том, что сердце проще других органов, а в том, что электрокардиография идеально подходит для машинного обучения: сигнал стандартизирован, исследование массово, результат имеет понятную клиническую ценность. Именно поэтому ЭКГ стала модельным примером, которому посвящена отдельная часть этой книги. Здесь же – общий взгляд на кардиологию как направление.

Распознавание ритма – исторически первая задача, которую ИИ решил на уровне, сопоставимом с врачом. Алгоритмы уверенно различают синусовый ритм, фибрилляцию предсердий, желудочковые и наджелудочковые нарушения, блокады. Это направление особенно ценно для массового скрининга: фибрилляция предсердий часто протекает бессимптомно, но повышает риск инсульта, и её своевременное выявление меняет тактику антикоагулянтной терапии. Носимые устройства и портативные регистраторы сделали такой скрининг доступным вне клиники.

Ишемия и инфаркт – следующая зона, где ИИ показывает клинически значимые результаты. Речь идёт не только о распознавании очевидных изменений, но и о снижении доли

ложных тревог. Проблема ложноположительных активаций при подозрении на инфаркт с подъёмом сегмента ST хорошо известна: чрезмерная тревога ведёт к ненужным транспортировкам, перегрузке рентгеноперационных и стрессу пациента. Алгоритмы, обученные на больших массивах, способны переклассифицировать часть ложных случаев и одновременно не пропустить истинные, что меняет баланс в пользу более точной сортировки. Этому посвящена отдельная глава части III.

Скрытые кардиомиопатии – направление, которое сложно переоценить. Гипертрофическая кардиомиопатия, амилоидоз, ряд наследственных заболеваний долгое время выявлялись поздно, часто уже после серьёзных осложнений. ИИ научился находить на обычной ЭКГ признаки, которые человеческий глаз не связывает с этими болезнями. Фактически алгоритм выполняет роль «второго взгляда», направляющего пациента на углублённое обследование – эхокардиографию, МРТ, генетическое тестирование. Это не диагноз, а триаж, и именно в таком качестве он наиболее полезен.

Прогнозирование – ещё одна область применения. По ЭКГ можно оценивать риск аритмий, внезапной сердечной смерти, декомпенсации сердечной недостаточности. Такие модели не заменяют клиническую оценку, но дают дополнительный сигнал для стратификации. Важно понимать: прогноз вероятностный, и его ценность зависит от того, как он

встроен в маршрут пациента и какие действия за ним следуют.

Дистанционный мониторинг и носимые устройства расширяют кардиологию за пределы кабинета. Умные часы, нагрудные датчики, имплантируемые регистраторы генерируют огромные объёмы данных. ИИ помогает отфильтровывать шум, выделять значимые эпизоды и снижать нагрузку на врача, который иначе утонул бы в уведомлениях. Но здесь особенно остро стоит вопрос ложных срабатываний: чрезмерная чувствительность порождает тревожность и лишние обращения, а недостаточная – пропуски. Баланс настраивается под конкретную популяцию и клинический сценарий.

Отдельно нужно сказать о **границах**. Кардиологический ИИ обучен на данных конкретных популяций. Пациенты с имплантированными устройствами, редкими врождёнными аномалиями, нестандартным расположением электродов могут выпадать из зоны уверенности модели. Артефакты, шум, неправильное наложение электродов остаются источником ошибок, которые алгоритм не всегда распознаёт как таковые. Наконец, ИИ не знает анамнеза, жалоб и клинической картины – он видит сигнал, но не пациента. Поэтому его вывод всегда должен интерпретироваться в контексте.

Главный вывод главы: **кардиология – наиболее зрелое направление применения ИИ, но зрелость не означает вседозволенности**. Наибольшую пользу алгоритмы приносят там, где они встроены в конкретный маршрут: скри-

нинг, триаж, приоритизация, дистанционный мониторинг. Наименьшую – там, где они подменяют клиническое суждение. В следующей части мы разберём ЭКГ подробно, потому что именно на этом примере видно, как из технической задачи рождается системное изменение клинической практики.

Глава 7. Радиология и визуализация

Радиология – второе после кардиологии направление, где ИИ достиг практической зрелости. Причина та же: данные стандартизированы, объём огромен, а рутинная нагрузка на специалистов растёт быстрее, чем число самих специалистов. Компьютерное зрение научилось находить на изображениях то, что человек ищет вручную, и делать это за секунды. Но, как и в кардиологии, наибольшую пользу ИИ приносит не там, где он «заменяет», а там, где он «приоритизирует» и «подстраховывает».

Скрининг лёгких – один из самых известных примеров. Низкодозная компьютерная томография позволяет выявлять ранние стадии рака лёгкого, но требует просмотра сотен срезов на каждого пациента. Алгоритмы детекции узлов сокращают время чтения, помогают не пропустить мелкие образования и стандартизируют измерения. В программах скрининга это особенно важно: там, где исследование массовое, даже небольшое повышение чувствительности даёт ощутимый клинический эффект.

Маммография – другое зрелое направление. ИИ используется как «второе мнение» при чтении снимков, а в некоторых системах – как инструмент приоритизации подозрительных исследований. Клинические исследования пока-

зывают, что алгоритмы способны снижать долю пропусков и уменьшать нагрузку на рентгенологов при двойном чтении. Однако здесь же проявляется важное ограничение: эффективность зависит от плотности молочной железы, возраста, оборудования и протокола. Модель, обученная на одной популяции, не автоматически переносится на другую.

Компьютерная томография и МРТ охватывают широкий спектр задач: от детекции внутричерепных кровоизлияний и признаков инсульта до сегментации опухолей и оценки ответа на лечение. В нейрорадиологии ИИ особенно ценен в экстренных сценариях: приоритизация исследований с подозрением на кровоизлияние или крупную окклюзию сосуда сокращает время до вмешательства. В онкологии сегментация позволяет измерять очаги объективно и отслеживать динамику, что важно для клинических испытаний и выбора тактики.

Приоритизация срочных находок – пожалуй, самый практичный сценарий внедрения. Алгоритм не выносит заключение вместо врача, а сортирует очередь: исследования с тревожными признаками попадают к специалисту первыми. Это не отменяет планового чтения, но меняет порядок и снижает риск задержки критического диагноза. Именно такая модель внедрения наиболее безопасна: она не требует полного доверия к алгоритму, а лишь использует его как фильтр.

Снижение рутинной нагрузки – ещё один аргумент. Рентгенолог тратит значительную часть времени на нормаль-

ные или малозначимые исследования. Если алгоритм уверенно относит часть из них к категории «без патологии», специалист может сосредоточиться на сложных случаях. Но здесь кроется риск: слишком агрессивная фильтрация может привести к пропуску редкой находки, которую модель не увидела. Поэтому такие схемы требуют строгой валидации и выборочного контроля.

Отдельно стоит сказать о **естественном языке в радиологии**. Генеративные модели уже способны формировать черновики описаний на основе изображений и структурированных данных. Это обещает снизить рутинную нагрузку, но одновременно создаёт риск «гладких, но неверных» заключений. Генеративный текст звучит убедительно, и именно поэтому требует обязательной проверки специалистом.

Главные **ограничения** радиологического ИИ хорошо известны. Домен-сдвиг: разное оборудование, разные протоколы, разная популяция. Редкие патологии: модель может не увидеть то, чего почти не было в обучении. Артефакты и нестандартные укладки. Наконец, ответственность: алгоритм не подписывает заключение, и финальное решение остаётся за врачом. Это означает, что внедрение требует не только технической интеграции, но и изменения рабочих процессов, обучения и культуры недоверия к «слишком уверенным» подсказкам.

Главный вывод главы: **радиология – направление, где ИИ уже приносит измеримую пользу, но эта польза**

сосредоточена в конкретных сценариях: приоритизация, второе мнение, снижение рутины. Универсального «ИИ-рентгенолога» не существует, и рассчитывать на него в обозримом будущем не стоит. Реальная ценность – в интеграции алгоритма в процесс, а не в замене специалиста.

Глава 8. Патоморфология

Патоморфология долгое время оставалась наименее автоматизированной областью диагностики. Микроскопия, подсчёт клеток, оценка структуры ткани – всё это традиционно опирается на опыт и внимание врача. Цифровая патоморфология изменила ситуацию: гистологические препараты оцифровываются, превращаясь в изображения сверхвысокого разрешения, а значит, становятся доступными для компьютерного зрения. С этого момента ИИ получил вход в одну из самых сложных диагностических специальностей.

Анализ гистологических изображений – базовая задача. Алгоритмы сегментируют ткань, выделяют ядра, различают типы клеток, находят области опухоли. В отличие от радиологии, где объекты крупные, здесь речь идёт о микронном масштабе, и ошибка в несколько пикселей может означать разницу между доброкачественным и злокачественным. Поэтому качество оцифровки, калибровка сканеров и стандартизация окраски приобретают критическое значение: модель, обученная на одном протоколе окраски, может «поплыть» на другом.

Подсчёт митозов – один из наиболее убедительных примеров практической пользы. Число митозов в опухоли влияет на степень злокачественности и выбор лечения, но руч-

ной подсчёт утомителен и подвержен вариабельности между специалистами. ИИ выполняет эту задачу быстрее и воспроизводимее, а главное – одинаково при повторных измерениях. Именно воспроизводимость, а не только скорость, делает алгоритм ценным: он снижает субъективный разброс там, где решение влияет на тактику.

Поиск метастазов в лимфоузлах – ещё один сценарий с высокой клинической значимостью. Микрометастазы легко пропустить при рутинном просмотре, а их наличие меняет стадию и лечение. Алгоритмы, обученные на размеченных препаратах, помогают выделять подозрительные участки и направлять внимание патолога. Здесь важно подчеркнуть: ИИ не ставит диагноз, он выполняет роль «второго взгляда», снижая вероятность пропуска.

Предсказание молекулярных маркеров – направление, которое выходит за пределы морфологии. Опухоль на стекле может выглядеть одинаково, но различаться по мутациям, определяющим чувствительность к терапии. Исследования показывают, что алгоритмы способны по гистологическому изображению предсказывать некоторые молекулярные характеристики с точностью, достаточной для триажа на генетическое тестирование. Это не заменяет лабораторный анализ, но позволяет расставить приоритеты и сократить время до получения результата.

Контроль качества и воспроизводимость – менее заметная, но важная функция. ИИ может проверять качество

окраски, выявлять артефакты, обнаруживать расхождения между препаратами одного пациента. В крупных лабораториях это снижает долю переделок и повышает доверие к результатам. Кроме того, алгоритмы помогают стандартизировать оценку между разными специалистами и учреждениями – там, где человеческая вариабельность особенно велика.

Ограничения здесь не менее серьёзны, чем в радиологии. **Гетерогенность окраски и оборудования** – главный источник домен-сдвига. **Редкие опухоли** представлены в данных плохо. **Разметка** требует участия опытных патологов, а их время дорого, что ограничивает объём качественных обучающих наборов.

Наконец, **ответственность**: заключение подписывает врач, и алгоритм не может быть единственным основанием для диагноза. Всё это означает, что патоморфологический ИИ развивается медленнее, чем радиологический, но именно здесь его вклад в воспроизводимость и снижение пропусков может быть особенно значимым.

Главный вывод главы: **в патоморфологии ИИ ценен прежде всего как инструмент воспроизводимости и второго взгляда**. Он не заменяет микроскоп и опыт, но снижает субъективный разброс, ускоряет рутинные измерения и помогает не пропустить критически важные находки. По мере стандартизации оцифровки это направление будет усиливаться, но требования к валидации останутся высокими.

Глава 9. Офтальмология

Офтальмология оказалась одной из первых специальностей, где ИИ вышел за пределы научных публикаций и стал реальным инструментом скрининга. Причина в характере данных: снимки глазного дна и оптическая когерентная томография (ОКТ) дают стандартизированное, хорошо воспроизводимое изображение, а заболевания, которые на нём видны, имеют огромную распространённость. Диабетическая ретинопатия, глаукома и возрастная макулярная дегенерация – ведущие причины слепоты, и их раннее выявление напрямую влияет на исход.

Диабетическая ретинопатия – наиболее зрелый сценарий. Алгоритмы обучены распознавать микромикроаневризмы, кровоизлияния, экссудаты и признаки пролиферации, а также классифицировать степень тяжести. Несколько систем получили регуляторное одобрение как автономные инструменты скрининга: они способны самостоятельно выдать заключение «патология не выявлена» или «требуется осмотр офтальмолога». Это особенно ценно в условиях дефицита специалистов, где очередь на плановый осмотр растягивается на месяцы, а пациент с диабетом годами не получает проверки глазного дна.

Глаукома сложнее для алгоритмов, чем ретинопатия. Ди-

агноз опирается не только на снимок диска зрительного нерва, но и на динамику, внутриглазное давление, поля зрения, толщину слоя нервных волокон. ИИ здесь чаще выступает как инструмент оценки риска и приоритизации, а не как самостоятельный диагност. Тем не менее даже такой триаж полезен: он помогает выделить тех, кому нужно углублённое обследование в первую очередь.

Возрастная макулярная дегенерация – ещё одно направление, где алгоритмы демонстрируют сопоставимую с экспертами точность в классификации стадий и выявлении признаков прогрессирования. Поскольку лечение эффективно прежде всего на ранних стадиях, своевременное выявление критично, а массовый скрининг при помощи ИИ делает его экономически возможным.

Автономные ИИ-системы – важная особенность офтальмологии. В отличие от многих других специальностей, здесь регуляторы допустили полностью автоматический скрининг без участия врача на первом этапе, с обязательным направлением положительных результатов к специалисту. Это создаёт модель, где ИИ берёт на себя роль фильтра в массовой программе, а человек сосредотачивается на подтверждении и лечении. Такая схема особенно востребована в регионах, где офтальмолог физически недоступен.

Ограничения, однако, остаются. **Качество изображения** критично: мутные среды, плохая фиксация, неудачная съёмка сводят точность к нулю, и алгоритм должен уметь

распознавать некачественный снимок и отказываться от заключения. **Разнообразие популяций** – вторая проблема: пигментация глазного дна, возрастные изменения, сопутствующие болезни могут влиять на признаки. **Редкие заболевания** выпадают из зоны уверенности модели. Наконец, скрининг без последующего маршрута бесполезен: если положительный результат не ведёт к обследованию и лечению, вся цепочка теряет смысл.

Главный вывод главы: **офтальмология показывает, как ИИ может работать автономно в ограниченной, но чётко очерченной роли**. Успех здесь определяется не только точностью модели, но и качеством снимков, организацией маршрута пациента и готовностью системы здравоохранения принять автоматический скрининг. Это делает офтальмологию одним из наиболее убедительных примеров практической пользы ИИ.

Глава 10. Дерматология

Дерматология привлекает разработчиков ИИ по понятной причине: кожа доступна визуальному осмотру, а дерматоскопические изображения легко оцифровываются. Одно время казалось, что достаточно собрать большое количество снимков и обучить модель, чтобы получить «ИИ-дерматолога». Реальность оказалась сложнее, и именно поэтому дерматология – поучительный пример того, как визуальная доступность данных ещё не гарантирует клинической надёжности.

Дерматоскопия и триаж новообразований – центральная задача. Алгоритмы учатся различать доброкачественные и злокачественные образования, а также выделять те, что требуют биопсии. В исследовательских условиях точность нередко сопоставима с опытными дерматологами, и это породило волну оптимизма. Однако перенос в реальную практику выявил проблемы: дерматоскопические снимки в клинике делаются в стандартизированных условиях, а в обучающих наборах часто представлены «идеальные» изображения. Разница между ними – источник ошибок.

Смартфонные приложения сделали дерматологический ИИ массовым. Пользователь фотографирует образование и получает оценку риска. Это создаёт сразу несколько рисков. Во-первых, качество снимка непредсказуемо: осве-

щение, ракурс, разрешение. Во-вторых, приложение не знает анамнеза, динамики, субъективных ощущений. В-третьих, ложное успокоение может привести к отказу от своевременного визита к врачу. Поэтому регуляторы в разных странах относятся к таким приложениям настороженно, а клинически ответственные решения строятся как инструменты поддержки, а не самостоятельной диагностики.

Разнообразие кожи – ключевое ограничение. Обучающие наборы долгое время были смещены в сторону светлой кожи, и модели хуже работали на тёмных фототипах. Кроме того, дерматологические проявления многих заболеваний различаются по цвету кожи, что делает перенос моделей между популяциями нетривиальным. Это не абстрактная проблема справедливости, а измеримый источник клинического риска: пропуск злокачественного образования у пациента из недопредставленной группы.

Редкие и атипичные проявления – вторая зона слабости. Дерматология насчитывает тысячи нозологий, и большинство из них представлено в данных единичными примерами. Алгоритм, обученный на частых болезнях, может уверенно называть неверный диагноз при редком состоянии. Для врача это напоминание: подсказка ИИ не отменяет дифференциальной диагностики.

Несмотря на ограничения, у дерматологического ИИ есть ясные практические ниши. **Триаж** – направление подозрительных образований на срочную консультацию, **сортиров-**

ка в телемедицинских сервисах, где дерматолог удалённо просматривает поток фотографий, **поддержка** в обучении и повышении квалификации. Во всех этих сценариях алгоритм сужает поток и помогает не пропустить срочное, но решение остаётся за врачом.

Главный вывод главы: **дерматология демонстрирует, что доступность изображений – не то же самое, что готовность к автономной диагностике**. Наибольшая польза здесь достигается в триаже и поддержке специалиста, а не в замене осмотра. Качество данных, разнообразие фототипов и прозрачность ограничений остаются условиями безопасного применения.

Глава 11. Онкология

Онкология – специальность, где ИИ применяется шире, чем в любой другой области, но одновременно и там, где цена ошибки наиболее высока. Если в радиологии или патоморфологии алгоритм чаще всего решает одну локальную задачу – найти, измерить, классифицировать, – то в онкологии он встраивается в длинную цепочку решений: от скрининга до выбора схемы лечения и оценки ответа. Именно эта многоэтапность делает онкологию одновременно самым перспективным и самым требовательным направлением.

Прогнозирование и стратификация риска – одна из ключевых задач. На основе изображений, молекулярных данных и клинических признаков модели предсказывают вероятность рецидива, скорость прогрессирования, общую и безрецидивную выживаемость. Такие прогнозы помогают выбрать интенсивность лечения: кому достаточно наблюдения, а кому нужна агрессивная терапия. Важно понимать, что прогноз вероятностный и не отменяет клинического суждения – он лишь добавляет информацию к решению, которое принимает врач вместе с пациентом.

Поддержка выбора тактики – следующий уровень. Здесь ИИ анализирует совокупность данных: гистологию, генетические маркеры, стадию, сопутствующие заболевания

– и предлагает варианты, сопоставимые с рекомендациями клинических руководств. Наибольшую ценность такие системы имеют в сложных случаях, где нет однозначного протокола, и в учреждениях, удалённых от крупных онкоцентров, где помощь мультидисциплинарной команды менее доступна. Но именно здесь особенно высок риск: рекомендация, основанная на смещённых данных, может систематически уводить от оптимальной тактики целые группы пациентов.

Лекарственный скрининг и разработка препаратов – направление, где ИИ меняет не клинику, а исследовательский процесс. Модели предсказывают взаимодействие молекул с мишенями, оценивают токсичность, предлагают комбинации, анализируют данные доклинических исследований. Это сокращает время и стоимость разработки, позволяет перепрофилировать существующие препараты под новые показания. Клинический эффект здесь отложенный, но масштабный.

Клинические испытания – ещё одна зона применения. ИИ помогает подбирать пациентов под критерии включения, анализировать данные в реальном времени, выявлять ранние сигналы эффективности или токсичности. Это снижает долю неудачных испытаний и ускоряет вывод препаратов на рынок. Однако автоматизация отбора пациентов требует прозрачности: если алгоритм систематически исключает определённые группы, результаты испытания могут оказать-

ся нерепрезентативными.

Главные **ограничения** онкологического ИИ связаны с биологической гетерогенностью. Опухоли одного типа могут радикально различаться по молекулярному профилю, и модель, обученная на одном подтипе, плохо работает на другом. Редкие опухоли представлены в данных слабо. Данные часто фрагментированы между учреждениями и несовместимы по форматам. Наконец, ответственность за решение о лечении остаётся на онкологе и пациенте – алгоритм не может быть единственным основанием для выбора терапии.

Главный вывод главы: **онкология – направление, где ИИ наиболее многогранен, но и наиболее уязвим к ошибкам обобщения**. Наибольшую пользу он приносит как инструмент стратификации, поддержки решений и ускорения исследований, а не как замена мультидисциплинарной команды. Успех здесь определяется не только точностью модели, но и качеством данных, прозрачностью ограничений и готовностью клиницистов интерпретировать вероятностный прогноз в контексте конкретного пациента.

Глава 12. Другие направления

За пределами кардиологии, радиологии, патоморфологии, офтальмологии, дерматологии и онкологии существует широкий спектр применений ИИ, которые менее заметны, но не менее важны. Эта глава завершает часть II и показывает, что принципы, разобранные на примере зрелых специальностей, работают и там, где ИИ только начинает входить в практику.

Конец ознакомительного фрагмента.

Текст предоставлен ООО «Литрес».

Прочитайте эту книгу целиком, купив полную легальную версию на Литрес.

Безопасно оплатить книгу можно банковской картой Visa, MasterCard, Maestro, со счета мобильного телефона, с платежного терминала, в салоне МТС или Связной, через PayPal, WebMoney, Яндекс.Деньги, QIWI Кошелек, бонусными картами или другим удобным Вам способом.