

От пилота к масштабу

как встроить ИИ в процессы
и получить отдачу

Авторы

Александр Диденко

Руководитель Лаборатории ИИ
Школы управления SKOLKOVO

Владислав Запылихин

Инженер по машинному обучению
Лаборатории ИИ Школы управления
SKOLKOVO, аспирант ИБДА РАНХиГС

Анна Шабанова

Исследователь-координатор
Лаборатории ИИ Школы управления
SKOLKOVO

Александр Антипов

Инженер по машинному
обучению Лаборатории ИИ Школы
управления SKOLKOVO

Руслана Раемгулова

Исследователь Лаборатории ИИ
Школы управления SKOLKOVO

Ася Филатова

Научный сотрудник Центра
образовательных разработок
на основе технологий
искусственного интеллекта ТюмГУ

Редактор

Григорий Маслов

Руководитель проектов Школы
управления SKOLKOVO

Оглавление

Введение	4		
Методология исследования	7		
Ключевые выводы исследования	8		
Инструментарий, разработанный по итогам исследования	10		
Глава 1		Глава 2	
Как культура работы со знанием влияет на внедрение ИИ	11	Как распределяется работа между человеком и ИИ	26
Что такое эпистемическая культура	12	Управленческие рекомендации	45
Как устроена эпистемическая культура	14		
Три типа эпистемических культур	16	Глава 3	
Как неудачи ИИ-проектов связаны с типом культуры	18	Как взаимное непонимание губит ИИ-проекты	46
Эмпирические результаты	23	Управленческие рекомендации	68
Управленческие рекомендации	25	Источники	69

Введение

Релиз первой версии ChatGPT в конце 2022 года стал переломным моментом в истории технологий. Всего за пять дней сервис привлек 1 млн пользователей, а через два месяца их число превысило 100 млн — такого не бывало никогда. ChatGPT вызвал глобальный ажиотаж, сопоставимый с появлением смартфонов, и, по мнению ряда авторов, открыл новую эпоху — экономики генеративных технологий, «AI-номики»¹.

К 2025 году около 5% населения Земли – сотни миллионов человек – постоянно используют генеративные модели в рабочих или личных целях, а в том или ином виде с генеративными моделями знакома большая половина человечества. 78% мировых компаний – по крайней мере в ключевых регионах – внедряют генеративные модели в бизнес-процессы: от маркетинга и клиентской поддержки до управления цепочками поставок^{2 3 4}.

От технологии ждут если не чуда, то колоссального экономического эффекта. McKinsey прогнозирует, что генеративный ИИ может заметно повысить производительность труда и увеличить глобальный ВВП на \$2,6-4,4 трлн, что равносильно появлению на карте мира новой крупной державы⁵. 9 из 10 топ-менеджеров планируют нарастить инвестиции в ИИ, рассчитывая на рост эффективности и новые источники ценности⁶.

Но по мере того как первый восторг проходит, перед бизнесом встает куда более прагматичный вопрос: как показать реальную отдачу от LLM. И здесь начинаются трудности.

Массачусетский технологический институт в недавнем отчете констатирует: несмотря на \$30–40 млрд, уже вложенных компаниями во внедрение генеративных моделей, 95% бизнесов не фиксируют отдачи от инвестиций в ИИ. До промышленной эксплуатации доходит лишь 1 из 20 проектов⁷.

Хотя конкретные показатели внедрения ИИ зависят от отрасли и зрелости организации, а итоговые цифры в различных исследованиях разнятся, общий вывод очевиден: компании столкнулись с **системной проблемой внедрения LLM**.

Чтобы понять, какие факторы мешают проектам переходить к устойчивой эксплуатации, мы провели комплексный анализ академических публикаций, отраслевых отчетов и материалов консалтинговых агентств. В фокусе оказались как количественные данные, так и практические кейсы – от статистики до конкретных примеров успехов и провалов.

Вслед за принятой в литературе традицией мы используем расширительное определение «неудачной реализации». Под этим понимаются два сценария:

- **Преждевременное завершение проекта** на любом этапе до промышленной эксплуатации — будь то невыход из пилота, остановка на этапе внедрения или закрытие вскоре после запуска.
- **Отсутствие заявленной ценности** — превышение сроков или бюджета, недостижение KPI по ROI, низкий уровень принятия пользователями либо принудительная остановка по требованиям безопасности или этики.

1 Исследование [The Economic Potential of Generative AI](#) от McKinsey (2023) →

2 Оценки компании [Statista на 2025 год](#) →

3 Исследование [The State of AI: How Organizations are Rewiring to Capture Value](#) от компании McKinsey (2025) →

4 Исследование [Trust, Attitudes and Use of Artificial Intelligence](#) от KPMG (2025) →

5 Исследование [The Economic Potential of Generative AI](#) от McKinsey (2023)

6 Исследование [Superagency in the Workplace: Empowering People to Unlock AI's Full Potential](#) от McKinsey (2025) →

7 Исследование [The GenAI Divide State of AI in Business 2025](#) от MIT (2025) →

Анализ литературы показал, что причины таких исходов описываются по-разному, но часто пересекаются. Тем не менее их можно сгруппировать в несколько ключевых блоков:

- недостатки стратегического планирования,
- технические барьеры,
- сложности управления организационными изменениями,
- нехватка ресурсов и компетенций,
- внешние рыночные и регуляторные факторы.

Если посмотреть на факторы успеха, картина оказывается столь же разрозненной. Согласно нашему метаисследованию, наиболее значимые из них (интегральная оценка вклада 0,72–0,76):

- поддержка высшего руководства,
- системное обучение сотрудников,
- межфункциональное сотрудничество,
- зрелое управление данными.

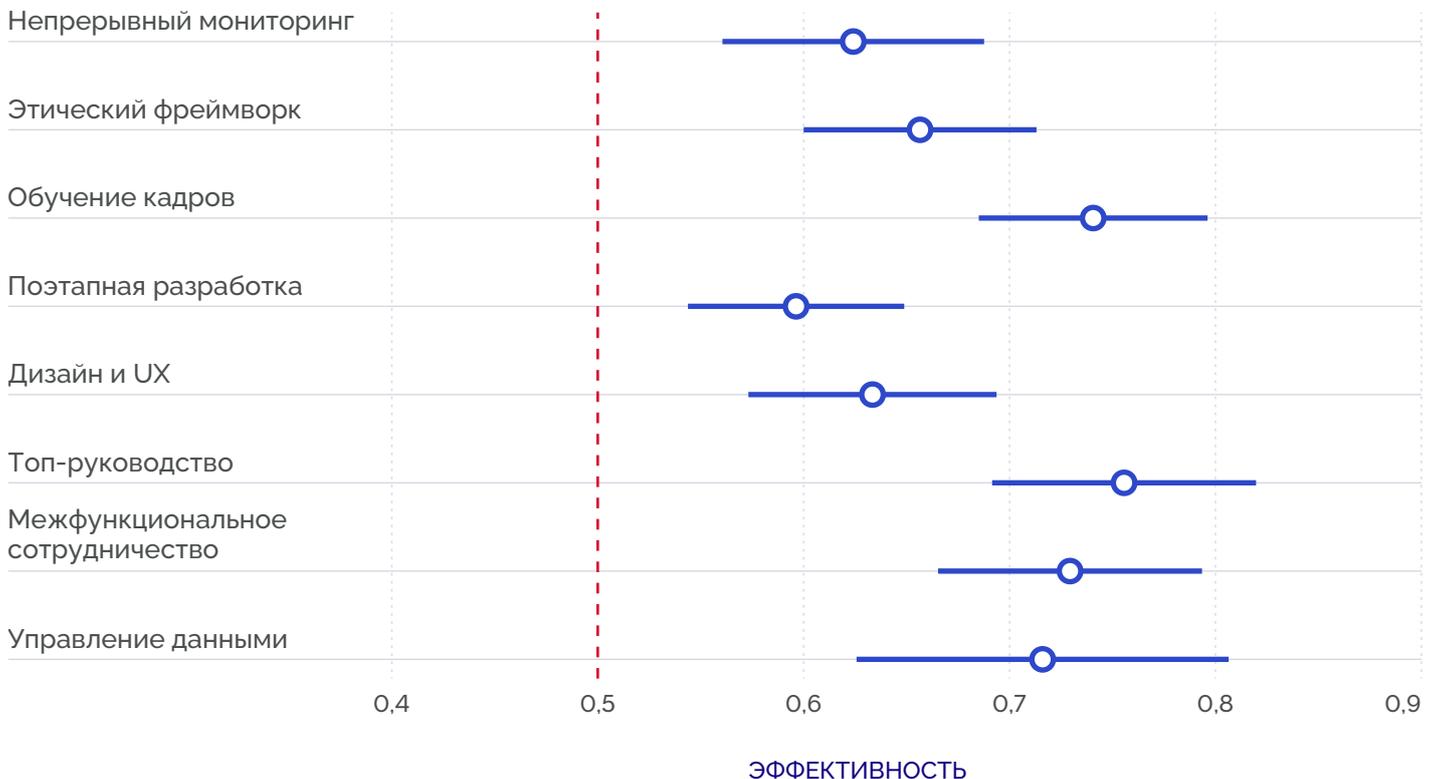
Менее выраженный, но стабильный положительный эффект оказывают (оценка 0,62–0,66):

- наличие этических рамок,
- ориентация на пользовательский опыт,
- регулярный мониторинг моделей после запуска.

График Факторы успеха ИИ-проектов

ФАКТОРЫ

○ Среднее значение





Проблема в отсутствии единой концептуальной основы, которая объединяла бы все эти элементы в стройную систему. Из-за этого рекомендации в литературе и отраслевых отчетах часто противоречат друг другу и не объясняют, почему одни и те же практики работают в одних организациях, но проваливаются в других.

Цель нашего исследования — выработать единую теоретическую рамку, которая помогла бы систематизировать причины неудач и понять, при каких условиях работают лучшие практики разработки, внедрения и масштабирования ИИ-решений. На ее основе мы предлагаем набор практических инструментов, которые помогают повысить шансы на успех ИИ-инициатив.

Теоретико-методологической основой исследования выступает когнитивная теория фирмы, рассматривающая организацию как распределенную познавательную систему. Этот выбор продиктован самой природой объекта исследования: внедрение ИИ, по сути, означает делегирование, или аугментацию, ключевых когнитивных функций организации — распознавания паттернов, анализа данных, выработки суждений и принятия решений.

Мы трактуем интеграцию ИИ не просто как технологическую инновацию, а как глубокую реконфигурацию познавательной архитектуры фирмы. Такой взгляд позволяет точнее выявлять причины неудач, которые часто связаны с разрывами и несовпадениями между существующими организационными практиками и новыми когнитивными возможностями, привносимыми технологиями.

Предложенный подход интегрирует несколько ключевых концепций:

- **Эпистемические культуры (К. Knorr-Cetina)**, описывающие институционально обусловленные различия в способах производства знания внутри организаций.
- **Когнитивная дистанция (В. Nooteboom)**, показывающая, как различия в языках, ментальных моделях и целях стейкхолдеров влияют на совместную продуктивность.
- **Когнитивные активы работников и менеджмента (М. Aoki)**.
- **Модель циркуляции знания SECI (Nonaka & Takeuchi)**.
- Для анализа вклада нечеловеческих агентов мы используем **аналитическую схему Грегора Шамаю (Chamaou, 2015)**, где работа ИИ-систем концептуализируется на трех уровнях — распознавание, принятие решений и исполнение — с двумя режимами на каждом: полная автономия или аугментация человеческих способностей.

Такой комплексный подход позволяет детально показать, как внедрение ИИ меняет то, как в компании принимаются решения и используется информация.



Методология исследования

Исследование проводилось в несколько этапов:

1

Систематический анализ литературы

Мы изучили академические публикации и отраслевые отчеты, чтобы выделить и классифицировать факторы, которые чаще всего связаны с успехом или провалом ИИ-проектов.

2

Сбор и разметка кейсов

С помощью мультиагентной системы собрали массив данных о внедрении ИИ в 25 отраслях (генеративные и дискриминативные модели, роботизация процессов). Все кейсы структурировали и разметили для последующего анализа.

3

Экспертная валидация

Результаты автоматической разметки проверили четыре независимых эксперта в области ИИ и организационного познания. Чтобы исключить предвзятость, каждый эксперт работал с материалами отдельно, а расхождения обсуждались и устранялись коллективно (процедура двойного слепого чтения).

4

Сбор полевых данных

Мы провели 30 полуструктурированных интервью — то есть бесед по единому плану, но с возможностью уточняющих вопросов — с руководителями, менеджерами проектов и разработчиками из российских компаний, чтобы выявить наиболее типичные причины неудач и эффективные стратегии их преодоления.

Ключевые выводы исследования

Шансы ИИ-проекта определяет не технология, а культура работы со знанием.

Иначе говоря, эпистемическая культура – то, как организация работает с информацией и принимает решения. Наш анализ показал: компании с преобладанием культуры, ориентированной на данные (data-driven), успешнее внедряют ИИ, чем организации, полагающиеся на авторитет отдельных экспертов (people-driven) или формальное следование регламентам (process-driven). Хотя некоторые отрасли в силу специфики лучше работают с гибридной моделью

Что делать

Оцените культуру принятия решений в компании с помощью опросника СКОЛКОВО, чтобы понять, насколько вы реально data-driven.

Ключевой барьер — низкое качество исходных данных.

Даже лучшие алгоритмы не работают, если входные данные хаотичны: корпоративная система переполнена дублями, устаревшими файлами и несовместимыми форматами. Во многих кейсах именно подготовка и стандартизация данных занимала больше ресурсов, чем сама разработка модели. Без Data Story — общего для бизнеса и ИТ описания качества и доступности данных — риск провала резко возрастает.

Что делать

Проведите аудит данных до старта проекта и создайте Data Story как «единый источник правды» для бизнеса и ИТ.

Тотальная автоматизация не нужна: это непропорциональный риск.

Мы выделили три ключевые когнитивные функции в работе организаций: распознавание, принятие решений и исполнение. Каждая из них может выполняться вручную, совместно с ИИ (аугментированно) или полностью автоматически. Как выяснилось, попытки автоматизировать все подряд чаще приводят к провалам. Наибольший эффект достигается при грамотном сочетании режимов: ИИ усиливает или заменяет человека там, где это оправдано, а ключевые процессы остаются за людьми.

Что делать

С помощью методологии СКОЛКОВО разбейте ключевые процессы на этапы и определите, где безопасно автоматизировать, а где важно оставить человека.



ИИ-проекты буксуют, если стейкхолдеры не работают в одной логике.

Дело в когнитивной дистанции – различиях в языке и мышлении между топ-менеджерами, владельцами процессов и разработчиками. Если разрыв слишком велик — проекты буксуют из-за недоверия и срывов сроков. Если слишком мал — возникает групповое мышление, и вместо реальных KPI выбираются суррогатные метрики. Важен баланс.

Что делать

Создавайте кросс-функциональные команды и назначайте брокеров знаний, чтобы бизнес и разработка разговаривали на одном языке.

Решает не скорость запуска, а скорость итераций.

Проекты, где команды показывают результат короткими циклами (прототип → тест → обратная связь → улучшение), значительно устойчивее: быстрее выявляют ошибки и корректируют ожидания. Напротив, длинные изолированные спринты без демонстрации промежуточных версий приводят к накоплению ошибок, росту недоверия и увеличению рисков провала.

Что делать

Запрашивайте у команды рабочий прототип каждые 3–4 недели и обсуждайте прототипы вместе с бизнесом, а не только внутри разработки.

Старые методологии больше не работают — нужен новый фреймворк.

Классический CRISP-DM был разработан для статичных проектов анализа данных и не учитывает реалии машинного обучения и генеративных моделей. Мы предлагаем ряд бизнес-рекомендаций для управления когнитивной дистанцией внутри организации и мониторинга внедрения ИИ от начала до самого конца.

Что делать

Внедрите разработанные SKOLKOVO управленческие рекомендации, чтобы эффективнее встроить ИИ в бизнес-процессы.



Инструментарий, разработанный по итогам исследования

Диагностический чек-лист эписте- мической культуры

Позволяет быстро определить, на чем в компании строится работа со знанием: на личном опыте сотрудников (people-driven), на регламентах и процессах (process-driven) или на данных (data-driven). Это отправная точка для оценки шансов на успешное внедрение ИИ.

Управленческие рекомендации

Структурированные рекомендации к управлению ИИ-проектами. В отличие от классических фреймворков, способствуют снижению когнитивной дистанции между основными стейкхолдерами внедрения ИИ. Повышает вероятность перехода от прототипа к промышленной эксплуатации.

Навигатор применимости ИИ

Методика помогает выбрать оптимальный уровень автоматизации для конкретного бизнес-процесса: оставить ручное управление, усилить его с помощью ИИ (аугментированный режим) или полностью передать системе. Это снижает риск «тотальной автоматизации» там, где она связана с избыточными рисками.



Глава 1

Как культура работы со знанием влияет на внедрение ИИ



1.1

Что такое эпистемическая культура

Эпистемическая культура — это совокупность сложившихся в организации практик и механизмов, определяющих, как она получает, проверяет и использует знание.

Термин ввела социолог Карин Кнорр-Цетина для описания научных сообществ, но он отлично ложится и на бизнес и государственную сферу.

Согласно этой концепции, организации в ходе работы формируют собственные «режимы знания»: что считать достоверной информацией, какие методы аргументации признавать легитимными и кто (человек или алгоритм) имеет право выработать знание, принимаемое к действию.

Например, в одной компании новое решение считается обоснованным только после одобрения признанного эксперта — это **people-driven** культура. В другой ключевым источником легитимности выступают регламенты: пока документ не обновлен, инновация не будет внедрена — это **process-driven** культура. А в организациях с **data-driven** подходом решающим аргументом служит эксперимент или результат анализа данных: если цифры подтверждают гипотезу, решение принимается без дополнительных «авторитетов».

От того, какая культура доминирует в той или иной организации, напрямую зависит, как компания внедряет новые технологии, в том числе ИИ.

Адаптируя эту концепцию, мы рассматриваем организацию как «когнитивный ассамбляж» (Hayles, 2025) — систему, в которой вместе работают люди и «нечеловеческие агенты» — ИИ-системы, базы данных и другие цифровые инструменты. Все они связаны общей познавательной архитектурой.

То, какая культура работы со знанием преобладает в компании, напрямую определяет ее шансы на успешное внедрение ИИ. Например:

- В компаниях с культурой, ориентированной на данные и эксперименты, новые решения приживаются быстрее: цифры сами по себе считаются достаточным обоснованием.
- В более консервативных организациях — юридических фирмах или регуляторных органах — знание должно пройти через интерпретацию человека и проверку на соответствие прецеденту. В таких условиях машинные выводы часто отвергаются, что приводит к задержкам или полному провалу ИИ-проектов

1.2

Как устроена эпистемическая культура

Для систематического анализа мы выделяем три взаимосвязанных компонента эпистемической культуры: нормативный, архитектурный и инфраструктурный. Каждый из них отражает свою сторону того, как в компании рождается, проверяется и используется знание.

1 Нормативный компонент

Отвечает на вопрос: что именно считается знанием и кто имеет право его производить? Иначе говоря, это критерии легитимности знания и его носителей.

- **Критерий знания** — что принимается как достоверная основа для действий (формализованный отчет, экспертное заключение, личный опыт или статистическая метрика).
- **Субъект знания** — кто или что обладает правом производить это знание (топ-менеджер, профильный эксперт, рабочая группа или сертифицированный алгоритм).
- **Валидация и передача** — как знание проверяется на достоверность и распространяется внутри организации (устная коммуникация, формальные документы, дашборды, API-интерфейсы).

Этот компонент задает правила: какие факты считать убедительными и кому верить в организации.

2 Архитектурный компонент

Описывает, как именно организация работает с информацией внутри себя — от хранения до превращения в управленческие действия.

- **Память** — как хранится и извлекается знание: это может быть опыт сотрудников, корпоративная база данных, архив документов.
- **Внимание** — какие сигналы организация воспринимает как значимые (например, KPI или стратегические приоритеты), а какие игнорирует.
- **Восприятие и обучение** — фильтры обработки информации и способы накопления нового знания: наставничество, тренинги, анализ данных.
- **Принятие решений** — как именно информация превращается в управленческое действие: кто принимает решение и на основании каких аргументов.

Этот компонент показывает, как «думает» организация.

3 Инфраструктурный компонент

Это материально-техническая основа, на которой держится работа со знанием в организации.

- **Носители** — где хранится знание (документы, облачные хранилища, репозитории кода).
- **Инструменты** — через что собираются и обрабатываются данные (датчики, CRM, ERP, BI-платформы, ML-инструменты).
- **Интерфейсы** — насколько удобно сотрудникам взаимодействовать с системами, в том числе с ИИ.
- **Интеграция систем** — связность информационных потоков между подразделениями: единое «поле данных» или набор разрозненных «островков».

Иначе говоря, инфраструктурный компонент отражает, насколько организация создала «экосистему знания» — удобные связные каналы, по которым информация двигается и используется. От этого напрямую зависит, сможет ли ИИ работать в полную силу.



1.3

Три типа эпистемических культур

Анализ существующих классификаций и результаты нашего исследования позволяют выделить три базовых типа культур работы со знанием:

- **People-driven (ориентированная на людей).** Знание формируется через экспертизу, опыт и неформальные связи сотрудников. Решения принимаются на основе интуиции, консенсуса или авторитета лидеров.
- **Process-driven (ориентированная на процессы).** Знание закрепляется в стандартизированных процедурах, регламентах и формальных правилах. Правомерность (легитимность) решения определяется соответствием установленному процессу.
- **Data-driven (ориентированная на данные).** Знание рождается из анализа эмпирических данных и алгоритмов. Решения обосновываются метриками, результатами экспериментов и предиктивными моделями.



Таблица 1.1.
Характеристики типов эпистемических культур

Критерий	People-driven	Process-driven	Data-driven
Нормативность			
Легитимный источник знания	Экспертиза и опыт сотрудников	Стандартизированные процедуры и правила	Эмпирические данные и аналитика
Производитель знания	Люди (через обсуждения)	Системы процессов и аудитов	Алгоритмы и базы данных
Легитимный источник знания	Экспертиза и опыт сотрудников	Стандартизированные процедуры и правила	Эмпирические данные и аналитика
Когнитивная архитектура			
Способ хранения знания	В памяти сотрудников, в традициях	В базах процедур, в архивах	В базах данных, в облачных хранилищах
Фокус внимания	Приоритеты команды и лидеров	Регламентированные графики, KPI	Анализ данных, предиктивные модели
Приоритет в информации	Контекстные и неформальные нюансы	Соответствие или отклонение от стандарта	Паттерны и корреляции в данных
Инфраструктура			
Ключевые инструменты	Коммуникационные платформы	Системы управления процессами (ERP)	Аналитические инструменты (BI, ML)
Способ доступа к знанию	Через личные сети и менторов	Через стандартизированные базы знаний	Через API и дашборды реального времени
Фокус инвестиций	Развитие людей (тренинги)	Оптимизация процессов	Данные и ИИ-технологии



1.4

Как неудачи ИИ-проектов связаны с типом культуры

Наша гипотеза заключается в том, что организации с преобладанием *people-driven* и *process-driven* культур сталкиваются с системными барьерами при внедрении ИИ. Эта гипотеза получила подтверждение по трем независимым каналам:

- 1 **Интервью с респондентами** — руководители и разработчики указывали на трудности, связанные с культурой принятия решений.
- 2 **Статистическое моделирование базы кейсов** — показало устойчивую корреляцию между типом культуры и результатами внедрения.
- 3 **Кабинетный анализ литературы** — выявил аналогичные выводы в академических и отраслевых исследованиях.

1.4.1

Можно ли доверять машинному знанию

В **people-driven** культурах машинные выводы признаются значимыми только после проверки человеком. Критерием успеха выступает не формальная метрика, а экспертная интерпретация.

Так, в одном из изученных нами кейсов образовательной организации успех проекта определялся вручную держателем процесса:

«Проект для нас был качественным, а не количественным: успех определялся сессией обратной связи с держателем процесса. Она смотрела результат — “здесь хорошо попал... здесь — ‘фуфло’”. Промежуточная метрика — одобрение эксперта. По итогам — “да, продолжаем в следующем году”»

Представитель
образовательного учреждения

Цитата из глубинного интервью,
проведенного в рамках исследования

Машина может предложить вариант, но окончательная точка ставится экспертом — будь то врач, продюсер или мастер на производстве. Особенно это заметно в креативных индустриях, где качество результата определяется не цифрами, а эстетикой и профессиональным чутьем:

«Все равно нужны люди, чтобы отличать одно от другого. Нейросеть что-то генерирует, но “эстетика” критически важна и не сводится к [выбору генеративной. – здесь и далее прим. авторов исследования] модели»

Представитель
креативного сектора

Цитата из глубинного интервью,
проведенного в рамках исследования

Показательный пример — эволюция **Netflix**. Компания добилась успеха как **data-driven** платформа, опираясь на алгоритмы рекомендаций. Но, начав собственное производство, Netflix столкнулась с Голливудом — индустрией, где решения традиционно основываются на интуиции продюсеров, репутации талантов и личных связях. Возникло напряжение между «технической» командой, доверяющей данным от 117 млн зрителей, и «контентной» командой, полагающейся на творческое чутье.

Кульминацией стал спор вокруг сериала **Glow** («Блеск» в русскоязычной адаптации): алгоритмы не рекомендовали его продлевать, но контент-директора настояли на продолжении ради отношений с авторами. Компромисс был найден в разделении бюджета на «контент, формируемый данными» и «контент, ведомый людьми»¹.

1 The tension between people and data at Netflix



В производственных **people-driven** средах похожее напряжение возникает, когда автоматизация затрагивает действия, традиционно считавшиеся частью профессионального мастерства.

В одном из рассмотренных нами кейсов после внедрения системы автоматического управления линией обогащения руды руководитель цеха металлургического предприятия обратился к команде цифровизации с прямым вопросом:

«Зачем вы одеваливаете моих мастеров? Если теперь решения за них принимает система, то в чем тогда заключается их работа?»

Представитель
нефтегазового сектора

Цитата из глубинного интервью,
проведенного в рамках исследования

Эта реакция отражает важный принцип: в таких организациях ядро профессии связано с правом человека принимать ответственные экспертные решения. Когда машина начинает вторгаться в эту зону, сотрудники ощущают угрозу своей профессиональной роли, а легитимность результата системы ставится под сомнение.

В итоге формируется негласная «граница непередаваемых функций»: определенный набор задач закреплен за человеком и поддерживает статус-кво профессиональной группы.

1.4.2.

Как хаос мешает формализации знания

В **people-driven** организациях когнитивная инфраструктура складывается вокруг неформализованного знания — личного опыта сотрудников и разрозненных цифровых артефактов. Такая архитектура почти неизбежно ведет к фрагментации: данные хранятся в разных форматах и структурах, без единых стандартов и контроля качества.

«[Мы] столкнулись с тем, что есть большая проблема именно в отсутствии таких структурированных данных. [У заказчика] каждый источник по-разному сегментируют, структурируют, данные хранятся по-разному. А нормализация данных — это основа в работе с моделями, ее увы нет.»

Владелец продукта
с ИИ-компонентой

Цитата из глубинного интервью,
проведенного в рамках исследования

Результат предсказуем: каждый источник превращается в отдельный «остров информации», и собрать единый датасет можно только ценой больших дополнительных усилий.

«А где-то это написано? Нет, не написано, это в головах у сотрудников. [Экспертное] знание, оно на бумагу никак не переносится»

Руководитель
из ИИ-блока FMCG-компании

Цитата из глубинного интервью,
проведенного в рамках исследования

Главная проблема в том, что знания остаются в головах сотрудников и нигде не фиксируются. Их нельзя напрямую использовать для обучения моделей или тиражирования практик. Попытки «достать» это знание упираются в то, что опыт и интуицию людей трудно формализовать и перевести в данные.

«[В предприятиях] все хаотично, люди зачастую заняты другими делами, и о сборе данных никто не парится. Поэтому мы пошли с этой стороны, решили [сначала просто] собирать данные»

Разработчик ИИ-решений

Цитата из глубинного интервью,
проведенного в рамках исследования

Организационные приоритеты в **people-driven** культурах редко включают системный сбор и структурирование данных. В таких условиях проектные команды, отвечающие за внедрение ИИ, начинают не с алгоритмов, а с «уборки», «причесывания» и систематизации разрозненной информации.

«[У заказчика] нету данных, нормальных данных... и получается, любой документ, одна папка, несколько одинаковых версий, версии разные, документы названия одинаковые, и модель как бы как-нибудь делает, но в таком балагане она не разберется»

Консультант по внедрению
генеративных моделей

Цитата из глубинного интервью,
проведенного в рамках исследования

Хаотичное хранение документов создает информационный беспорядок, в котором даже самые продвинутые алгоритмы теряют эффективность. Здесь особенно остро проявляется принцип **garbage in — garbage out: качество результатов внедрения ИИ напрямую зависит от качества исходных данных**. Если в систему загружается «мусор» — дубли, устаревшие, неактуальные версии документов — то и на выходе бизнес получает такие же «мусорные» прогнозы и рекомендации.

«Сложно, занимает большое количество времени разложить процесс на составляющие. Когда [заказчики] говорят: а у нас вот столько отчетов, мы делаем столько презентаций, а как нам сделать, чтобы из отчетов получались презентации? Но ... [для разработки архитектуры проекта и обучения модели] нужно разложить [отчеты и презентации] на много составляющих.

Откуда берется информация из отчета? Из каких источников? Из каких ресурсов? По каким критериям она обрабатывается? Как она превращается в презентацию? Каким образом вы раскладываете это на слайды? Почему вы используете именно эти изображения?

Владелец компании
по разработке ИИ-решений

Цитата из глубинного интервью,
проведенного в рамках исследования

Очень много вещей, которые люди делают уже кто-то на автомате, кто-то там 10 лет работает, они <...> так привыкли делать и не могут объяснить: это предложение я беру вот отсюда, потому



что оно важно, и так далее. И на то, чтобы процесс детализировать и объяснить, где можно встроить [ИИ] и где нет, уходит много времени»

Декомпозиция экспертных практик оказывается крайне трудозатратной: профессионалы действуют интуитивно, не осознавая алгоритма своих решений.

«[Много] знаний не оцифровано, их тяжело положить в модель. В том числе, потому что, например, в год вы выпускаете 20 фильмов, [и] ни одна модель нормально не посчитает что-то на 20 [образцах, для качественных результатов нужна более широкая выборка]»

Продюсер медиаиндустрии

Цитата из глубинного интервью,
проведенного в рамках исследования

В ряде отраслей - например, в креативных индустриях - сама природа данных ограничивает эффективность статистических методов: выборки слишком малы, продукты слишком уникальны.

Практический вывод: в *people-driven* организациях внедрение ИИ опирается не в алгоритмы, а в хаос в данных. Прежде чем автоматизировать процессы, компаниям приходится тратить огромные ресурсы на «уборку» и структурирование информации — иначе модели дают сбой. Часть знаний вообще остается только в головах сотрудников и недоступна для оцифровки. Поэтому ключевой барьер здесь — не техника, а культура работы с данными: без ее перестройки ИИ не принесет ценности.

1.4.3 Когда стейкхолдеры говорят на разных языках

Даже самые продвинутые дашборды и графики могут оказаться бесполезными, если заказчик не понимает, что именно в них искать. Руководители и менеджеры часто ждут объяснений в привычной форме — через примеры, истории или описание последовательности действий. А сухие цифры и визуализации без контекста остаются для них «немыми».

«Мы строим аналитику, мы строим дашборды, мы их отдаем заказчику. А заказчик не понимает, что в этих дашбордах он может увидеть. Он не понимает, как читать график, он не понимает, что ему нужно. И часто либо это откладывается, либо они ждут какую-то компетенцию, которая появится у них в компании»

BI-аналитик

Цитата из глубинного интервью,
проведенного в рамках исследования



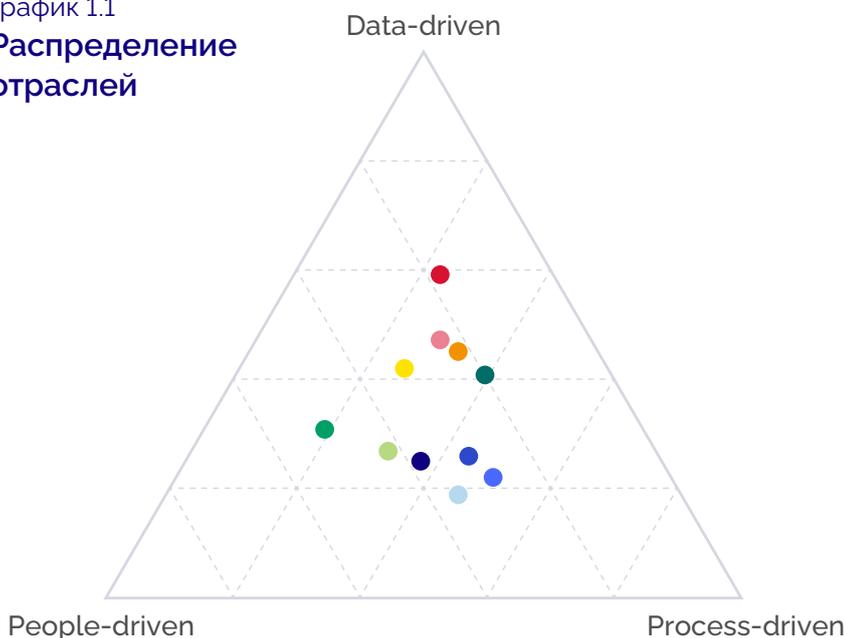
1.5

Эмпирические результаты

Как уже упоминалось, в рамках данного исследования мы опирались не только на данные глубинных интервью, но и на разработанную нами агентную ИИ-систему, которая собрала из открытых источников более 1600 кейсов внедрения ИИ за последнее десятилетие. База включала как успешные, так и «провальные» кейсы. Успешными кейсами, в данном случае, мы считаем ситуации, когда компания смогла полностью автоматизировать одну когнитивную функцию: распознавание, принятие решений или исполнения. Частичное вмешательство человека или ручное исполнение функции, следовательно, рассматривается как провал внедрения ИИ. Для каждого кейса был автоматически определен сектор и отрасль по классификации GICS. Еще одна агентная система собирала информацию об отраслевых признаках эпистемической культуры и назначала каждой отрасли тройной индекс [X, Y, Z], где X – означало близость к people-driven (от 0 до 100), Y – process-driven, Z – data-driven. Индексы были нормализованы с тем, чтобы их общая сумма была равна 100. Результаты разметки отраслей приведены на тернарном графике.

Видно, что ни одна из отраслей не относится к «чистому» архетипу. Они сконцентрированы ближе к середине, что свидетельствует о том, что в большинстве отраслей практикуется смешанный подход к управлению знаниями. При этом, разброс индексов достаточно значителен.

График 1.1
Распределение
отраслей



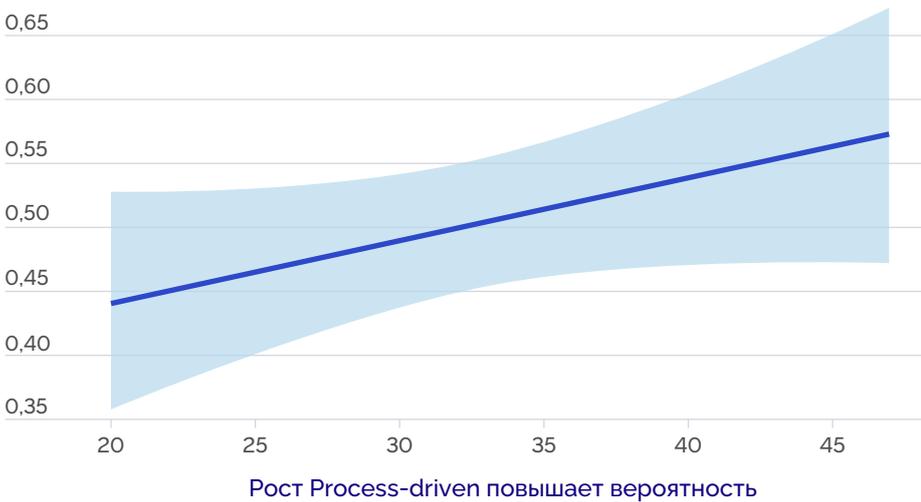
- ИТ
- Потребительские товары повседневного спроса
- Финансовый сектор
- Коммунальные услуги
- Потребительские товары повседневного спроса
- Недвижимость
- Здравоохранение
- Энергетика
- Промышленность
- Коммуникационные услуги
- Материалы

На втором этапе нашего эмпирического анализа мы оценили, с помощью двух байесовских логистических регрессий, объясняющих вероятность успеха кейса. В первой модели шансы успешного внедрения зависели от степени выраженности people-driven и data-driven эпистемических культура. Во второй модели вероятность успеха оценивалась с помощью process-driven и data-driven индексов. Монте-Карло стандартная ошибка (MCSE) среднего $\sim 0,001$, то есть Монте-Карло погрешность пренебрежимо мала; оценки средних и квантилей устойчивы. Результаты моделирования визуализированы на графиках ниже.

Графики 1.2 и 1.3

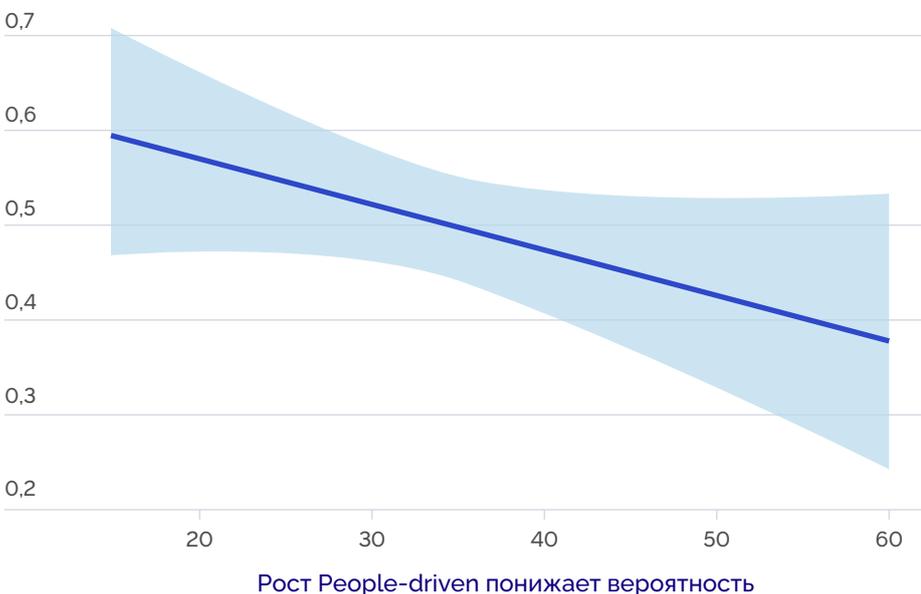
Моделирование вероятности успешного внедрения кейса

Вероятность успеха



Восходящий наклон кривой связан с более высокими шансами на успех при изменении культуры компании в сторону process-driven.

Вероятность успеха



Голубая граница - это 95% байесовский интервал неопределённости (ETI): диапазон правдоподобных значений кривой с учётом статистической неопределённости. Чем шире граница, тем выше неопределённость.

Нисходящий наклон говорит об обратном эффекте, рост индекса people-driven приводит к снижению вероятности полной автоматизации процесса.

Управленческие рекомендации

Выясните, какая эпистемическая культура преобладает в вашей компании

Перед запуском ИИ-инициативы важно определить, на чем держится принятие решений в организации: на опыте людей, на процессах или на данных. Это поможет выявить риски и выбрать правильную стратегию внедрения.

Начинайте с быстрых побед — и затем масштабируйте

ИИ-проекты нужно запускать с задач, где результат можно сразу увидеть и измерить. Быстрые победы снижают скепсис, упрощают взаимодействие стейкхолдеров и дают руководству уверенность, что ИИ работает на реальные результаты.

Учитывайте профессиональную идентичность сотрудников

Задачи, которые руководителю кажутся рутинными, для сотрудника могут быть сердцем его профессии. Если просто «забрать» их и отдать ИИ, внедрение встретит сильное сопротивление. Если автоматизация все же необходима, ее нужно сопровождать деликатным управлением изменениями: объяснять смысл нововведений, договариваться о новых ролях и показывать, что ИИ расширяет возможности, а не «отбирает работу».

1

2

Сблизьте ожидания ключевых стейкхолдеров

Разные команды — топ-менеджеры, владельцы процессов и разработчики — по-разному понимают цели ИИ-проектов. Чтобы сблизить их, экспертные знания и ожидания нужно превратить в понятные всем параметры: критерии, датасеты, метрики. В организациях с ориентацией на процессы стоит также обновить регламенты под новые задачи, которые решает ИИ. Более подробно о том, как согласовывать цели и языки различных групп стейкхолдеров — во второй главе.

3

4

Переводите результаты ИИ на язык бизнеса

Графики и дашборды сами по себе редко помогают принять решение в компаниях, где все традиционно строится вокруг опыта (people-driven) или регламентов (process-driven). В таких случаях выводы моделей нужно дополнять «человеческим переводом» — текстовыми пояснениями. Такой подход снижает риск недопонимания и помогает быстрее превращать выводы ИИ в управленческие решения.

5



Глава 2

Как распределяется работа между человеком и ИИ

2

В этой главе мы смещаем фокус: от общих организационных архетипов (data-/process-/people-driven) — к уровню конкретных бизнес-процессов. Для анализа используем теорию распределенного познания (Distributed Cognition, DCog), предложенную Эдвином Хатчинсом.

Ее ключевая идея проста: мышление и принятие решений происходят не только «в голове» отдельного человека, а в рамках всей социотехнической системы — команды людей, инструментов и артефактов, с которыми они работают. Это позволит точнее понять, почему ИИ-проекты «ломаются» не на уровне технологий, а в том, как люди и системы работают вместе.

Классический пример Хатчинса — работа навигационной команды на мостике военного корабля. Определение местоположения судна — это не задача одного офицера. Один измеряет пеленг, другой фиксирует время, третий наносит данные на карту, четвертый ведет журнал. Ни у кого по отдельности нет полного знания, но вместе их действия складываются в общую картину.

При этом «думает» не только команда, но и артефакты: бумажная карта выступает не просто как носитель данных, а как инструмент, преобразующий сложные координаты в удобную для анализа схему. Штурманские приборы берут на себя часть вычислений, превращая оптические сигналы в числа. Журнал фиксирует промежуточные шаги — по сути, это внешняя память всей системы.

Подход DCog подтверждается практикой: сбои при цифровизации возникают не из-за ошибки одного человека или системы, а из-за сбоев во всей экосистеме — там, где пересекаются люди, процессы и инструменты.

Например, в **исследовании службы технической поддержки IBM** (Maglio, Kandogan, and Haber, 2003) выяснилось, что проблема не «обнаруживается» в готовом виде. Ее приходится буквально собирать как пазл: кто-то анализирует логи, кто-то обрабатывает команды, кто-то сверяется с документацией. Критично не столько наличие данных, сколько умение участников согласовать между собой общую картину происходящего. Когда контекст передается неполно или с искажениями, поиск решения затягивается.

Итог

Знание о положении корабля рождается не у одного человека, а в координации людей и инструментов. Именно взаимодействие и обмен информацией превращаются в «вычисление».

Схожая динамика наблюдалась в системе диспетчеризации скорой помощи Лондона (Furniss, 2004). Попытка заменить бумажные карточки инцидентов цифровым интерфейсом сломала привычный порядок работы. Карточки служили внешней памятью и помогали расставлять приоритеты. Когда их убрали, время отклика выросло.

В инженерной фирме (Rogers and Ellis, 1992) «низкотехнологичная» доска для визуальной координации, задуманная как вспомогательный инструмент, наоборот, усложнила коммуникацию. В итоге инженеры тратили больше времени на согласования, что увеличивало вероятность ошибок.

Аналогичные выводы сделаны в исследовании корпоративной ИТ-поддержки (Bosua, Scheepers, and Lakomski, 2004): ИТ-системы, хорошо работающие в «штатных» условиях, оказались неэффективными при сбоях и авариях. Причина — разрыв между тем, как система хранит и структурирует информацию, и тем, какой обмен знаниями требуется людям в экстренных ситуациях.

В рамках настоящего исследования и с опорой на теорию DCoг мы будем использовать три базовых понятия для описания когнитивной работы в организации. Они позволяют разложить любую интеллектуальную задачу на последовательные этапы:

- **Распознавание (Recognition):** превращение сырых данных в понятные сигналы или признаки.
- **Принятие решения (Decision-making):** выбор конкретного плана действий на основе этих сигналов.
- **Исполнение (Execution):** воплощение выбранного плана в виде реальных действий — цифровых или физических.

На каждом из этих этапов мы рассматриваем три возможных режима работы:

- **Полностью автоматически (Auto):** функция выполняется системой автономно, без участия человека, по заранее заданным правилам.
- **Аугментировано человеком (Augmented):** система и человек работают совместно. Машина берет на себя рутинные или вычислительно сложные задачи (например, анализ или генерацию вариантов), а человек отвечает за экспертную интерпретацию, творческие решения и финальную проверку.
- **Полностью вручную (Manual):** функция полностью выполняется человеком, система не задействована либо играет вспомогательную роль.

Итог

Теория DCoг позволяет взглянуть на внедрение ИИ и цифровых решений с нестандартного угла. Ошибки рождаются не в коде или в действиях конкретного сотрудника, а в том, как выстроено взаимодействие всей системы — людей, процессов и инструментов. Успех зависит от качества «согласования пазла»: передачи контекста, связности каналов и правильной настройки артефактов, будь то дашборды, журналы или физические карточки.



Проведенные в рамках исследования интервью показали: многие неудачи связаны с тем, что компании пытаются «автоматизировать все» — на всех трех стадиях (распознавание, принятие решений, исполнение). Но далеко не все процессы к этому готовы: мешают ограничения моделей, сложность контекста и внешние требования.

Подход DCoг позволяет разложить процесс на этапы. При распознавании главное — однозначность данных. При принятии решений — ясность, кто отвечает за итог. При исполнении — четко определенный объект и понятный исполнитель.

Если хотя бы на одном из этих шагов нужны человеческая интерпретация или личная ответственность, сценарий «Auto-Auto-Auto» превращается в источник затрат и завышенных ожиданий. Гораздо лучше работают смешанные модели: там, где машина берет на себя рутину, а человек — то, что требует экспертизы и ответственности.

«Пусть мы имеем высококонкурентный и очень динамичный рынок, на нем большая корпорация. Если мы представим, что корпорация будет приоритетом ставить полную оцифровку всех процессов и данных в едином формате, то это будет большим тормозом. Если хотите быть лидером на таком рынке, нужно дробление и автономность подразделений - а описывать все процессы подробно и собирать все данные в едином формате будет занимать столько времени, что завтра вы потеряете рынок. Т.е. сплошная цифровизация, структурирование данных и регламентация для большой компании ее скорее всего погубит. Если не работать с данными совсем - скорее всего тоже. Вижу, что здесь секрет успеха в двойном балансе:

- Централизация/регламентация VS автономность/дробление
- people-driven VS data-driven

Причем в зависимости от конкретного подразделения подходы могут быть диаметрально противоположными. В одной части процессов и подразделений нужно строго соблюдать централизацию и оцифровку данных в едином формате, в другом лучше дать полную свободу и ограничиться локальной цифровизацией. Глобальная диагностика и усреднение для больших корпорация на мой взгляд не полезна, т.к. слишком обобщает.



Михаил Вишневский

Технический менеджер продукта
и ИИ-тренер в X5 Tech



При внедрении ИИ компании нужно следовать дифференцированному подходу:

1. Учиться выделять участки где data-driven преобладает и экспертное не формализованное - минимально. Для ИИ это низко висящие фрукты.
2. Для независимых подразделений с высокой динамикой изменений, и низкой кусочной автоматизацией, если это оправдано и необходимо, идти в небольшие ИИ проекты, персональные инструменты, которые упрощают работу конкретных ролей или локальных процессов, но не пытаться полностью занести процессы в одну ИИ систему/проект.

Чтобы перейти от теории к фактам, мы вновь обратились к собранной агентной ИИ-системой базе кейсов внедрения ИИ. Для каждого кейса мы определили, как именно выполнялись три ключевых этапа — **распознавание, принятие решений и исполнение** — и на каком уровне автоматизации они находились: **полностью автоматическом, совместном (человек+машина) или ручном**. После этого разметку проверили эксперты.

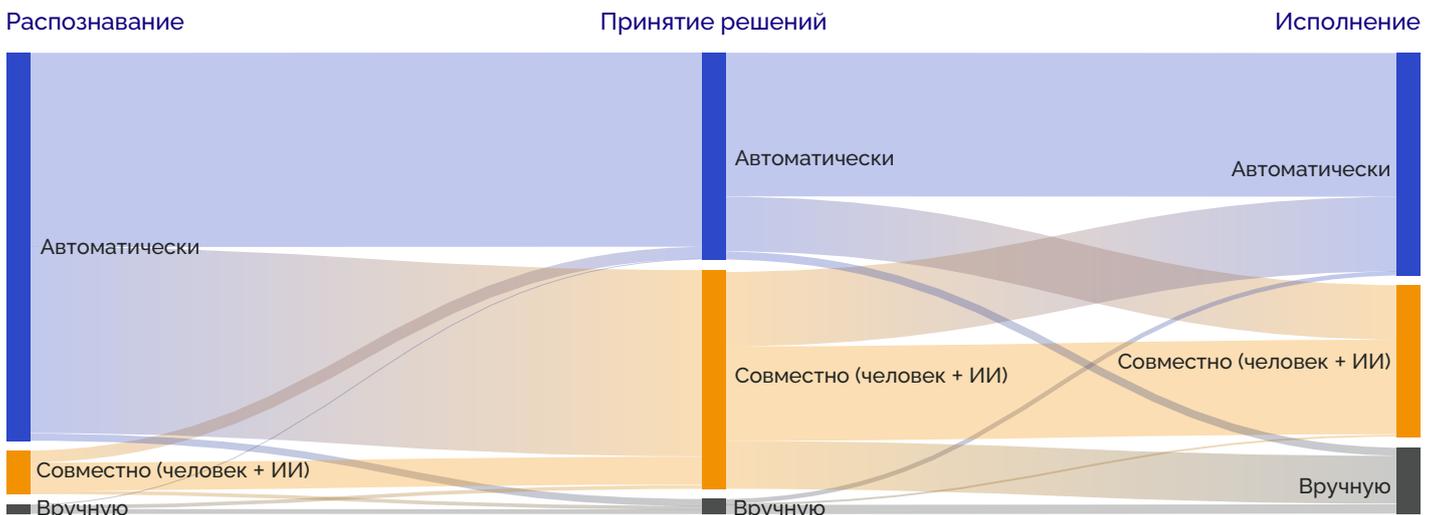
На диаграмме ниже показано, как в реальных проектах сочетаются разные режимы. Левая колонка — распознавание, центральная — принятие решений, правая — исполнение. Размер прямоугольников отражает, сколько кейсов попадает в тот или иной режим. Ленты показывают переходы между стадиями: например, нередко автоматическое распознавание ведет к совместному принятию решений, а дальше — либо к автоматическому, либо к ручному исполнению. Полностью ручные цепочки встречаются значительно реже.

Важно подчеркнуть:

эта диаграмма отражает именно структуру — какие комбинации встречаются чаще всего. Вопрос о том, какие из них дают лучший результат, мы разберем отдельно, в следующем разделе.

График 2.1

Переходы: распознавание — принятие решений — исполнение



На тернарных диаграммах ниже показано, как распределяются режимы работы по трем стадиям — **распознавание, принятие решений и исполнение**.

Каждая точка отражает ситуацию в целой отрасли: она показывает, в какой пропорции проекты работают в **автоматическом (Auto)**, **совместном (Augmented)** или **ручном (Manual)** режиме.

Диаграмма читается так:

- вершины треугольника обозначают «чистые» режимы — 100% Auto, 100% Manual или 100% Augmented;
- чем ближе точка к вершине Auto, тем выше доля автоматизации;
- чем ближе к Manual — тем чаще работа выполняется вручную;
- очки на стороне между двумя вершинами показывают, что отрасль сочетает оба режима примерно поровну;
- расположение внутри треугольника отражает баланс всех трех режимов.

Для наглядности точки окрашены по отраслям (по классификации GICS), чтобы различия между ними были видны сразу.

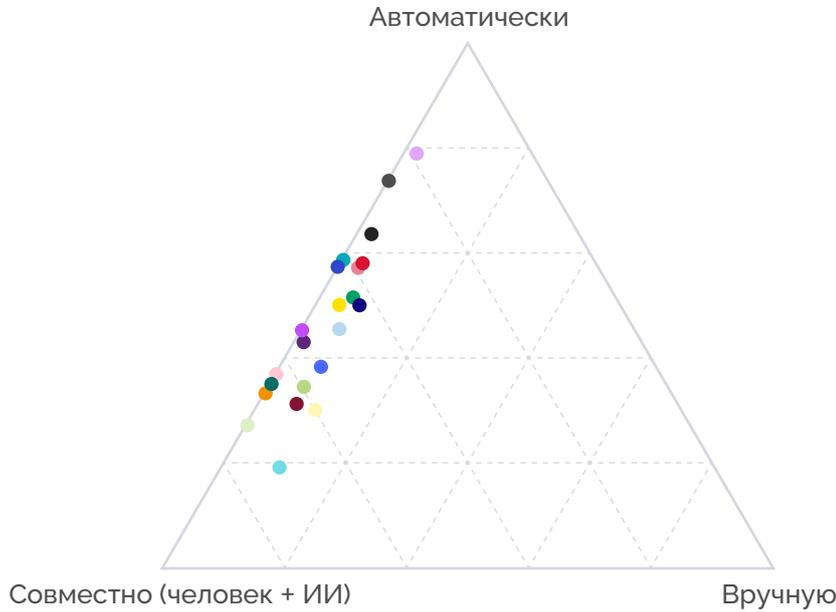
График 2.2

Распределение типов Распознавания



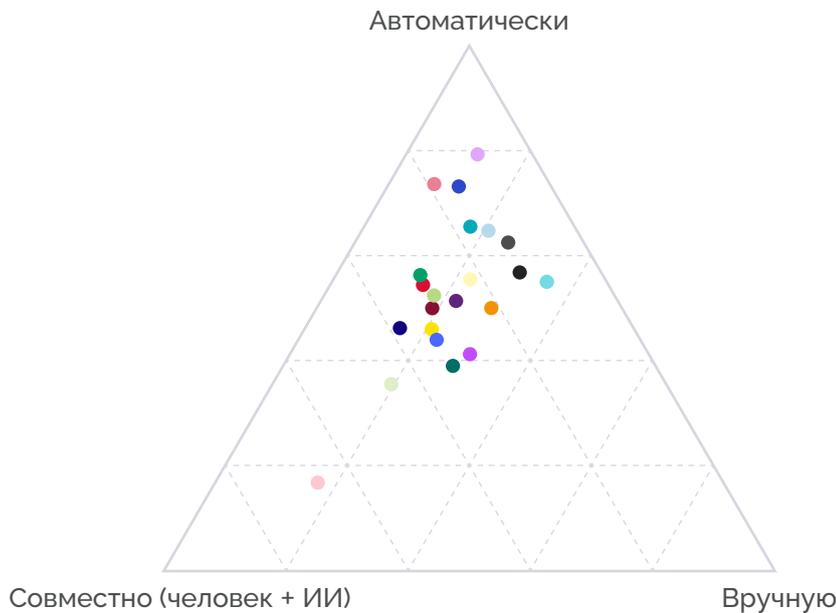


График 2.3
Распределение типов Принятия Решений



Принятие решений (Decision-making):
точки смещаются к линии между Auto и Augmented. Это значит, что хотя часть решений принимается автоматически, значительная доля проектов строится на совместной работе человека и ИИ.

График 2.4
Распределение типов Исполнения



Исполнение (Execution): разброс максимален. Многие отрасли опираются на «человека в контуре», а в ряде случаев процесс невозможно завершить без полностью ручного действия.

- Автомобили и комплектующие
- Многоотраслевые финансы
- СМИ и развлечения
- Телекоммуникационные услуги
- Продукты питания, напитки и табачные изделия
- Страхование
- Бытовые изделия и предметы личного пользования
- Розничная торговля продуктами питания и товарами повседневного спроса
- Программное обеспечение и услуги
- Потребительские услуги
- Банки
- Розничная торговля
- Фармацевтика, биотехнология и науки о жизни
- Недвижимость
- Потребительские товары длительного пользования и одежда
- Коммерческие и профессиональные услуги
- Средства производства
- Медицинское оборудование и услуги
- Коммунальные услуги
- Транспорт
- Материалы
- Энергетика
- Сельское хозяйство

Таким образом, диаграммы показывают не только режимы работы, но и отраслевые различия в том, как именно распределяются роли между человеком и машиной. Подробные эффекты и цифры мы разберем далее.

Самый распространенный профиль — это полностью автоматический («Auto–Auto–Auto»), он встречается примерно в 28% случаев

(см. иллюстрацию ниже)

Анализ этих кейсов показывает: полная автоматизация работает там, где процесс полностью цифровой и стандартизован. Это значит:

- на входе есть данные, которые трактуются однозначно;
- на выходе фиксируются четко измеримые результаты;
- логика решений формализована: правила стабильны, модели обучены на проверенной базе, уровень ошибок заранее задан и контролируем.

Исполнение в таких процессах идет через стандартные цифровые каналы — например, API или транзакции в информационных системах. Машина работает с четко структурированными объектами, и ей не требуется вмешательство человека для интерпретации, этической оценки или юридического одобрения.

При этом есть и организационные условия:

- сама среда стабильна,
- процессы повторяются массово,
- риски ошибок управляемы через мониторинг, аудит, автотесты или механизмы отката.

Редкие исключения заранее перенаправляются человеку.

Многие проекты реализуются в гибридном формате. Второй по распространенности профиль — «Auto–Augment–Auto» (11% случаев): система автоматически распознает данные, человек при поддержке ИИ принимает решение, а дальше исполнение снова автоматизировано.

Иными словами:
полностью автоматический режим «Auto–Auto–Auto» возможен там, где входные данные однозначны, решения поддаются формализации, действия стандартны, а риски можно контролировать.



Зачем здесь нужен человек? Потому что есть задачи, где модель не может учесть всю сложность контекста и рисков. Это происходит, например, когда:

- у процесса несколько целей, и их приходится балансировать (доход против риска, краткосрочный результат против долгосрочной ценности);
- данные редкие или быстро меняются, и модель не успевает переобучиться;
- цена ошибки слишком высока, а последствия необратимы — и решение требует «человеческого вето»;
- правила диктуют регуляторы или репутационные риски, где нужна объяснимость и персональная ответственность;
- часть сигналов или экспертного знания нельзя формализовать в фичи модели;
- есть противодействующий игрок (например, мошенники), который адаптируется быстрее алгоритмов.

В режиме «Auto-Augment-Auto» ИИ работает как фильтр и «подсказчик» — быстро анализирует большие массивы и предлагает варианты. Но финальное слово остается за человеком, который разбирает спорные случаи и несет ответственность. Это сочетание сохраняет масштабируемость, но снижает риск ошибок там, где полная автоматизация неосуществима.

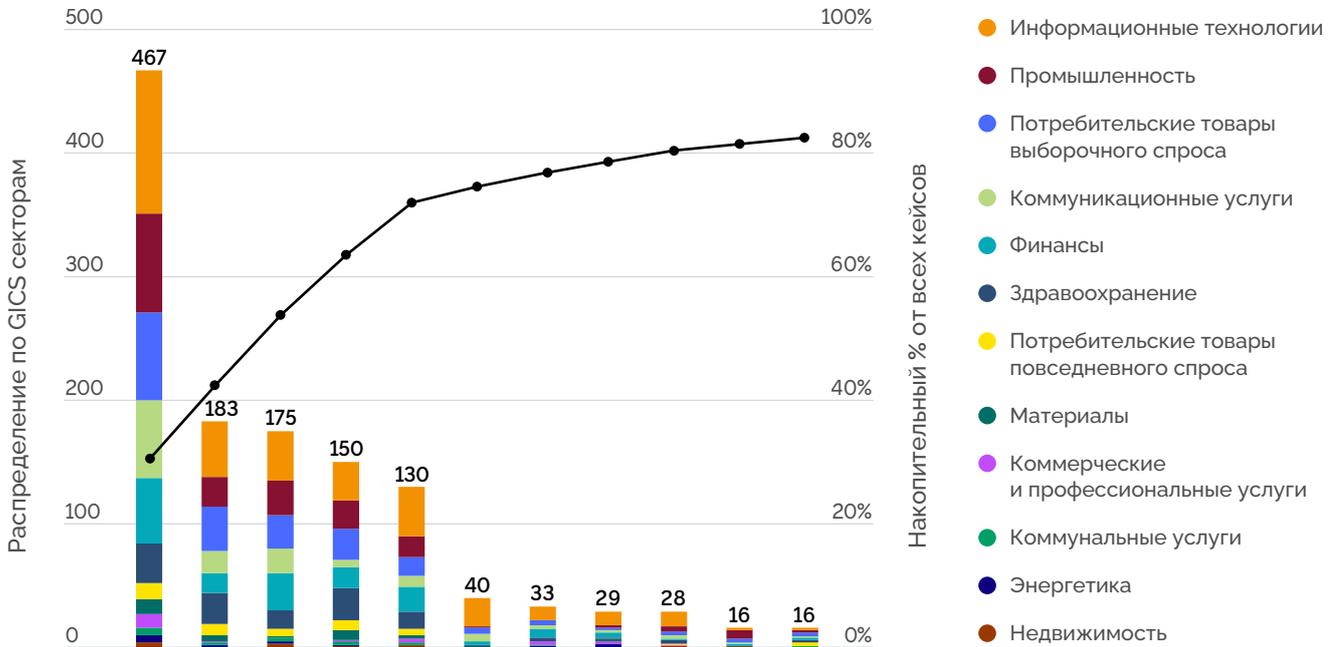
Два следующих по частоте профиля — «Auto-Augment-Augment» (10%) и «Auto-Auto-Augment» (8%). В обоих случаях распознавание выполняется автоматически, но на этапе исполнения остается значимая роль человека.

Это характерно для творческих или полуструктурированных задач. Например: система может автоматически распознать данные, подготовить черновик письма, оформить заказ, сгенерировать маршрут, выставить счет или собрать комплект документов. Но финальный шаг требует участия человека — чтобы адаптировать тон под конкретного клиента, согласовать исключение, подтвердить лимит, проверить соответствие политике бренда или требованиям регулятора.

Причина в том, что цена ошибки на этапе исполнения выше, чем на распознавании: здесь решение напрямую воздействует на людей или внешние системы. Кроме того, интерфейсы часто неоднородны — разные каналы связи, нестандартные документы, специфичные ситуации.

Оптимальная схема такова: машина автоматизирует массовые повседневные задачи, а человек подключается там, где нужны интерпретация, гибкость и ответственность.

График 2.5
Распределение секторов GICS по Шамаю



Наконец, распространенный профиль — «Auto-Augment-Manual» (9,5%). Здесь система автоматически распознает данные, человек принимает решение при поддержке ИИ, но само действие выполняется вручную.

Такой профиль характерен для медицины и высокотехнологичного обслуживания оборудования. В этих сферах объект воздействия уникален — будь то человеческое тело, эмоциональное состояние клиента или сложная техническая система. Итоговое действие несет юридическую, этическую или репутационную нагрузку, поэтому его невозможно полностью делегировать алгоритму.



Полностью ручное исполнение остается необходимым в ситуациях, где:

- нет стандартного интерфейса,
- высокая вариативность и низкая обратимость действий,
- цена ошибки асимметрична и велика.

Это включает переговоры и убеждение, очную работу с жалобами и конфликтами, нестандартные физические манипуляции, а также операции, требующие подписи, согласия или идентифицируемого ответственного лица.

В сумме описанные паттерны охватывают около двух третей случаев использования ИИ. Остальные распределяются по множеству более редких комбинаций, что подчеркивает разнообразие реальных сценариев внедрения.

В режиме «Auto-Augment-Manual» ИИ играет вспомогательную роль: подсказывает варианты, структурирует информацию, помогает эксперту быстрее сориентироваться. Но исполнение остается за человеком, потому что только он может взять на себя ответственность и учесть социальные и правовые нормы.

Практическая процедура выбора целевого профиля оформлена в виде «Навигатора».

Это инструмент, созданный в рамках исследования, который помогает компаниям определить, какой уровень автоматизации подходит для конкретного процесса.

По сути, это пошаговый опросник с типовыми развилками: отвечая на вопросы о характере входных данных, логике принятия решений и среде исполнения, компания получает подсказку, какой режим оптимален — полный автомат, совместная работа человека и ИИ или ручное исполнение.

Логика навигатора основана на признаках, визуализированных в трех диаграммах приложения.

- **Распознавание.** Если входные данные цифровые и легко интерпретируемы, процесс можно автоматизировать. Пример — банковский скоринг: система получает цифровую анкету клиента и обрабатывает ее без участия человека. Но если данные неоднозначны, как в медицинской диагностике при анализе КТ-снимка с размытыми очагами, требуется вмешательство человека — алгоритм помогает, но окончательное заключение дает врач.
- **Принятие решения.** Автоматизация возможна там, где есть четкие правила и формализованные критерии. Например, при управлении запасами система сама инициирует дозаказ, когда остаток опускается ниже заданного уровня. Но если решение связано с ценностными, репутационными или юри-

дическими последствиями, как в венчурных инвестициях, необходим «совместный» режим: ИИ формирует варианты, но последнее слово остается за человеком.

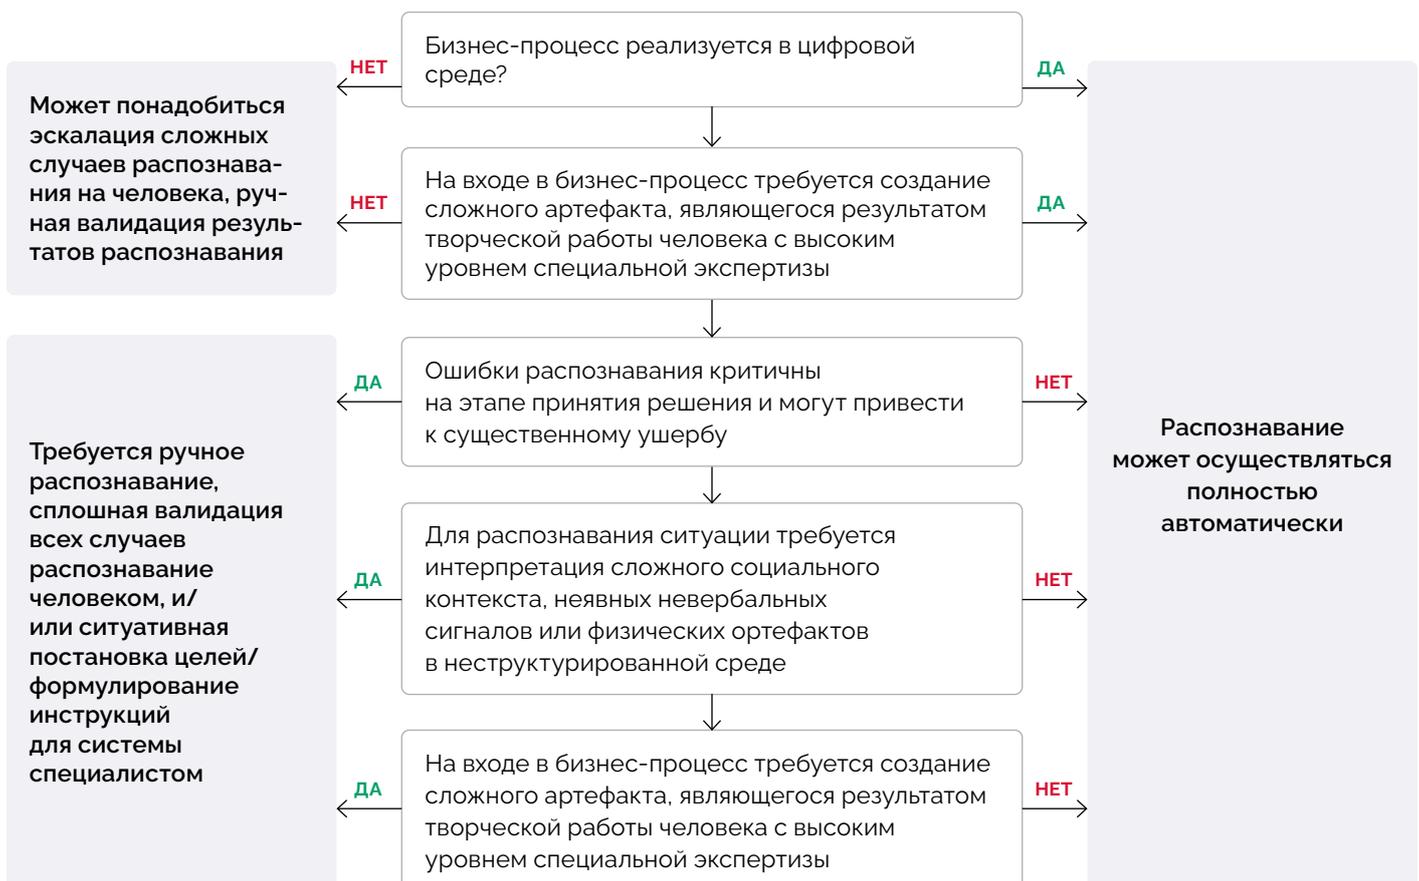
- **Исполнение.** Автоматический режим применим там, где среда стандартизована, а действия повторяемы — например, перевод средств в онлайн-банкинге. Однако, когда речь идет о вмешательстве в уникальные человеческие состояния (психотерапия), нестандартных физических действиях (ремонт сложного оборудования) или процедурах с персональной ответственностью (хирургия), участие человека обязательно.

Эта логика смещает акцент с идеи «автоматизировать все» на создание реалистичной конфигурации, где участие человека — не помеха, а необходимая часть системы.

Навигатор выбора режима: стадия Распознавание (Recognition)

На этапе распознавания все решает характер входного сигнала. Вопрос звучит так:

«Сможет ли система сама превратить его в ясные и однозначные данные?» Ответ определяется двумя факторами: является ли сигнал изначально цифровым и насколько он однозначен.



1. Путь к полностью автоматическому распознаванию (Auto)

Этот режим возможен, если на входе процесса есть цифровой сигнал, который система понимает однозначно.

Логика: Если данные уже машиночитаемы (файл, запись в базе, API-запрос) и не допускают разночтений, распознавание можно полностью доверить машине.

Примеры:

- **Медицина:** Система автоматически принимает на вход цифровой КТ-снимок и выделяет зоны для анализа. Сам факт распознавания файла не требует участия врача.
- **Финансы:** Автоматическая обработка входящей заявки на кредит — система получает цифровую анкету и сразу извлекает нужные параметры.
- **Маркетинг:** Система запускает рекламную кампанию на основе заранее заданных параметров (бюджет, аудитория, время показа), поступающих в цифровом виде.

2. Путь к аугментированному распознаванию (Augmented)

Такой режим нужен, когда входные данные хоть и цифровые, но неоднозначные или неполные. Машина справляется с основной частью, но передает человеку проблемные или редкие случаи.

Логика: Система выполняет основную работу по распознаванию, но сложные или нестандартные случаи передает человеку. В итоге ИИ закрывает большинство рутинных задач, а человек подключается только к тем фрагментам, где требуется интерпретация или проверка.

Примеры:

- **Клиентский сервис:** В колл-центре система распознает речь клиента. 95% текста транскрибируется автоматически, но при сильном акценте или шуме проблемные куски передаются оператору с пометкой «нужна проверка».
- **Юридическая практика:** При анализе апелляций ИИ автоматически извлекает типовые аргументы. Но если в тексте встречаются нестандартные формулировки или сложные рассуждения, система передает этот фрагмент юристу для проверки, потому что однозначно интерпретировать его она не может.

- **Финансовый сектор:** Банковская система обрабатывает поток транзакций и автоматически распознает большинство операций. Но подозрительные или пограничные платежи помечаются для сотрудника службы комплаенса, чтобы тот проверил их вручную.

3. Путь к ручному распознаванию (Manual)

Этот режим нужен там, где невозможно «оцифровать» исходный сигнал. Входом является живая ситуация: поведение людей, их эмоции, социальный контекст. Такие вещи нельзя подать системе в виде готовых данных — их должен заметить и интерпретировать человек.

Логика: Автоматизация здесь просто не стартует: нет цифрового артефакта, который можно обработать. Человек сам считывает ситуацию и формулирует задачу для последующих шагов.

Примеры:

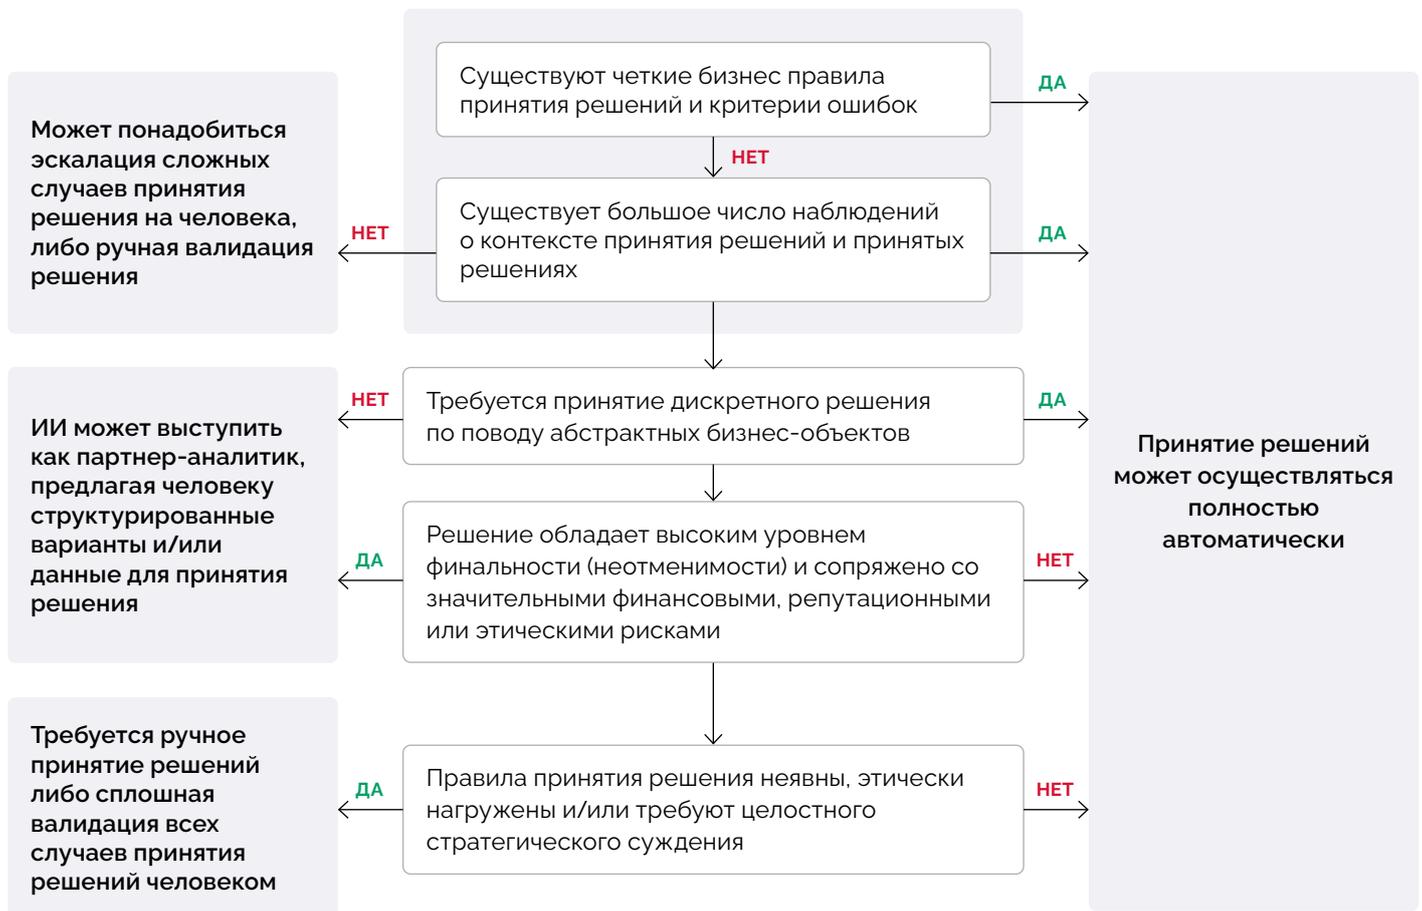
- **Туризм:** При проведении экскурсии исходными сигналами являются поведение и реакции группы туристов — усталость, вопросы, настроение. Гид сам считывает эти признаки и принимает решение перестроить маршрут или изменить подачу материала. Система может помочь уже позже (например, подсказать альтернативные локации), но распознавание ситуации на входе целиком остается за человеком.
- **Маркетинг:** Запуск поста в соцсетях может начаться не с формальной заявки, а с того, что специалист замечает тренд или изменение настроений в комментариях. Он вручную формулирует задачу («нужен пост на тему X»), которую потом можно поручить ИИ на этапе генерации.
- **Медицина:** Врач на приеме замечает, что пациент нервничает или скрывает детали болезни. Эти сигналы — выражение лица, паузы, интонации — не фиксируются системой и не оцифрованы. Врач сам должен «распознать» проблему, чтобы затем назначить анализы или исследования.

Навигатор выбора режима: стадия Принятия решений (Decision-making)

Когда данные уже распознаны и превращены в структурированную информацию, встает следующий вопрос: что с ними делать? На этом этапе организация выбирает план действий.

Ключевой вопрос на этой стадии формулируется так:

«Можно ли принять решение по заранее заданным правилам, или ситуация настолько сложна и неоднозначна, что без участия человека не обойтись?»»



1. Путь к полностью автоматическому принятию решений (Auto)

Этот режим возможен там, где решение можно свести к четким правилам, а риски заранее известны и контролируемы.

Логика: Если после распознавания данные однозначно указывают на один вариант действия по принципу «если X, то Y», то выбор можно полностью доверить машине. Такие решения обычно операционные, а не стратегические: они не требуют интерпретации, ценностных оценок или дополнительной ответственности.

Примеры:

- **Маркетинг:** Система сама решает, как именно настроить рекламную кампанию (бюджет X, таргетинг Y, креативы Z), опираясь на заранее заданные KPI. Человеческое вмешательство не нужно — это алгоритмический выбор.
- **Инженерия:** Решение о способе обработки сейсмических данных принимается автоматически: система применяет стандартный технический протокол без участия человека.
- **Логистика:** Алгоритм управления складом автоматически запускает дозаказ товара, если уровень запасов падает ниже установленного порога. Решение строго следует правилу и не требует дополнительных интерпретаций.

2. Путь к augmented принятию решений (Augmented)

Этот режим становится основным там, где решение связано с высокой сложностью или значимыми рисками — финансовыми, юридическими, репутационными. Здесь невозможно все свести к формальным правилам: нужна комбинация машинного анализа и человеческого суждения.

Логика: ИИ берет на себя роль аналитического партнера: он быстро обрабатывает данные, предлагает сценарии, прогнозирует последствия и подсвечивает риски. Но финальное слово остается за человеком, который выступает в роли стратега и носителя ответственности. Машина усиливает экспертизу, но не заменяет ее.

Примеры:

- **Медицина:** Система анализирует КТ-снимок и сообщает врачу: «вероятность злокачественного образования — 85%». Однако именно врач ставит диагноз и назначает лечение. Это решение несет юридическую и этическую ответственность, которую нельзя переложить на алгоритм.
- **Маркетинг:** ИИ собирает данные о трендах и предлагает варианты постов. Но окончательный выбор концепции и ключевого сообщения делает маркетолог, так как это влияет на бренд и требует творческого видения.
- **Финансы:** Алгоритм оценивает заявку на кредит и выдает скоринговую оценку риска. Но решение о выдаче крупного займа принимает кредитный комитет: оно учитывает не только цифры, но и репутационные, юридические и стратегические факторы.



3. Путь к ручному принятию решений (Manual)

Этот режим необходим там, где выбор напрямую связан с персональной ответственностью и не может быть формализован. Решение требует опыта, интуиции или эмпатии, которые алгоритмы воспроизвести не способны.

Логика: В таких ситуациях решение принимает только человек. Алгоритмы могут дать справочные данные (например, цифры в дашборде), но они не участвуют в процессе выбора и не берут на себя ответственность.

Примеры:

- **Правосудие:** судья решает, какое наказание назначить обвиняемому. Финальное решение включает интерпретацию уникальных обстоятельств дела и предполагает полную юридическую и этическую ответственность.
- **Креативные индустрии:** театральный режиссер выбирает концепцию постановки или визуальный стиль спектакля. Это решение основано на художественном замысле и видении автора, которое невозможно формализовать и предсказать алгоритмом. Даже если система знает тренды посещаемости, она не способна подсказать уникальную творческую идею.
- **Медицина (психотерапия):** терапевт в ходе сессии определяет, как вести диалог с пациентом, реагируя на невербальные сигналы и эмоциональное состояние. Этот выбор невозможно переложить на алгоритм.

Навигатор выбора режима: стадия Исполнения (Execution)

Финальный шаг — это реализация принятого решения. Здесь выбор режима определяется уже не сложностью самого решения, а свойствами объекта и среды, на которые направлено воздействие.

Ключевой вопрос навигатора:

«Может ли действие быть исполнено как простая цифровая операция, или оно требует выхода в сложный физический, социальный или юридический мир?»



1. Путь к полностью автоматическому исполнению (Auto)

Этот режим работает только там, где все происходит в цифровой среде, а действие сводится к простой машинной команде.

Логика: если принятое решение можно однозначно перевести в инструкцию («записать в базу», «отправить API-запрос», «списать сумму со счета»), система выполняет его сама. Участие человека не требуется, потому что среда предсказуема, а результат однозначен.

Примеры:

- **Финансовая сфера:** автоматическое списание платежа или проведение транзакции в онлайн-банке после срабатывания условия («остаток < N»).
- **ИТ-инфраструктура:** маршрутизация сетевого трафика или автоматическое масштабирование серверов под нагрузку.
- **E-commerce:** подтверждение заказа и отправка клиенту электронного чека сразу после оплаты.
- **Алгоритмический трейдинг:** система самостоятельно исполняет сделку, как только рынок достигает заданного значения.

В собранных нами кейсах такой режим встречался редко, потому что исследование было сосредоточено на более сложных сценариях внедрения, где человеку все же приходится участвовать.



2. Путь к augmented исполнению (Augmented)

Такой режим возникает, когда действие происходит в цифровой среде, но машина не может довести его до конца сама. В этих случаях человек и ИИ работают как партнеры: система берет на себя основную часть работы, а человек завершает задачу.

Сценарий 1: Совместное творчество. Машина генерирует черновик — текста, кода, дизайна, — а человек его редактирует и финализирует.

Пример: ИИ создает черновик апелляции или поста в соцсетях, а маркетолог доводит его до нужного качества, добавляя тональность и нюансы.

Сценарий 2: Человек как оператор. Решение принято автоматически, но у системы нет «короткого пути» к его исполнению. Тогда человек выполняет действия вручную в сложном интерфейсе.

Пример: ИИ определяет параметры рекламной кампании, но специалист должен сам зайти в рекламный кабинет и нажать нужные кнопки, следуя плану системы.

3. Путь к ручному исполнению (Manual)

Этот режим неизбежен, когда задача выходит за пределы цифрового мира и требует человеческого участия: физического действия, живой коммуникации или персональной ответственности.

Логика: есть области, которые невозможно полностью описать правилами. Это тонкая моторика, уникальные физические ситуации, эмоциональное взаимодействие или юридическая ответственность. Машина может подсказать или подготовить план, но выполнить его должен человек.

Примеры:

Физический мир: После постановки диагноза врач сам проводит операцию. Пациент уникален, каждое вмешательство требует гибкости и опыта.

Социальный мир: Оператор отвечает клиенту голосом. Здесь важны тон, эмпатия и умение уловить настроение собеседника.

Ответственность: Даже при существовании робота-хирурга финальную подпись и ответственность за результат несет человек — таковы требования общества и закона.



Управленческие рекомендации

Разложите бизнес-процессы на «кирпичики»

Перед внедрением ИИ полезно разделить каждую бизнес-задачу на этапы: распознавание (что поступает на вход), принятие решения (как выбрать действие) и исполнение (как оно реализуется). Это позволит сразу понять, где автоматизация достижима, а где потребуются участие человека.

Стратегически делайте ставку на гибридные модели

В большинстве случаев наиболее устойчивы схемы «человек + ИИ» в той или иной компоновке. Машина обрабатывает данные и ускоряет рутину, а человек решает пограничные ситуации, управляет исключениями и несет юридическую и этическую ответственность.

Учитывайте специфику стадии исполнения

Финальный шаг часто требует живого участия: физического действия, коммуникации с клиентом или юридической подписи. Даже при высокой автоматизации на предыдущих стадиях оставляйте место для человека там, где без него результат не будет принят или легитимирован.

1

2

3

4

5

Подберите режим работы под каждый этап

Для распознавания, принятия решений и исполнения нужно отдельно определить: можно ли доверить функцию машине, лучше оставить ее человеку или построить совместный контур. Универсальных схем нет — каждый шаг требует своей логики.

Оцените риски ошибки

При выборе режима ключевым критерием выступает не техническая осуществимость, а бизнес-риски. Если ошибка легко поправима и не чревата трудно обратимыми юридическими, репутационными или финансовыми последствиями — автоматизация оправдана. В обратном случае решение, скорее, должно оставаться за человеком.



Глава 3

Как взаимное непонимание губит ИИ-проекты



3

«Они единый народ и у всех один язык; начав это, не откажутся от задуманного. Сойдем же, смешаем им языки, чтобы не понимали речи друг друга».

Бытие 11:6

Причина большинства провалов ИИ-инициатив не в технологиях как таковых — не в «железе» и не в моделях, — а в том, **как думают и разговаривают между собой участники проекта.**

Разработчики фокусируются на точности алгоритма, менеджеры — на стратегических KPI, продакт-менеджеры — на удобстве для пользователя. Когда этот разрыв слишком велик — или наоборот, его пытаются игнорировать, — проект начинает буксовать. Цена взаимного непонимания может оказаться равной бюджету всей инициативы. Вернуть команде общий ритм и сократить согласования позволяет управление когнитивной дистанцией.

Когнитивная дистанция описывает, какие вопросы люди считают важными, как формулируют задачи и по каким критериям оценивают успех — и насколько отличаются группы и отдельные индивиды друг от друга. Голландский исследователь Барт Нутебум, автор концепции, описывает когнитивную дистанцию как «различие в том, как люди видят и понимают мир», если их опыт, в том числе профессиональный, складывался в неодинаковых условиях [Nooteboom 2009].

Простой пример: технические команды оценивают качество модели по ее метрикам, а бизнес-подразделения — по показателям рентабельности [Piorkowski et al. 2021].

«Мы создаем дашборды и отдаем их заказчику, но он не понимает, что именно может в них увидеть: как читать график, к чему относятся цвета, какие выводы сделать. В итоге инструмент либо игнорируется, либо в компании начинают ждать появления недостающей компетенции»

BI-аналитик

Цитата из глубинного интервью,
проведенного в рамках исследования



Большая когнитивная дистанция делает проект похожим на Вавилонскую башню: каждый говорит на своем языке, ожидания не совпадают, информация замыкается внутри профессиональных «цехов». В такой ситуации плодотворная совместная работа едва ли возможна.

«Самые прочные стены строятся не из камня и бетона, а из непонимания - это полностью соответствует статистике по провальным проектам. В исследовании Rand Corporation взаимное непонимание, какую именно проблему должен решить проект, возглавляет пятерку основных причин провала проектов в сфере ИИ. И это приводит к тому, что до 80% ИИ-проектов не достигают результата - примерно в 2-4 раза чаще, чем обычные ИТ-проекты»^{1 2}



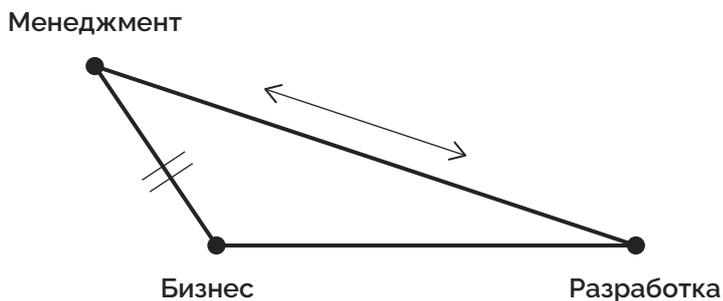
Павел Алферов

Профессор бизнес-практики Школы
управления СКОЛКОВО

На материале 30 глубинных интервью с представителями менеджмента, разработчиками, владельцами бизнес-процессов в российских компаниях, а также руководителями стартапов, был выявлен ряд типичных ловушек, связанных с неоптимальной когнитивной дистанцией.

Первая группа связана с чрезмерной когнитивной дистанцией между участниками: когда команды оказываются слишком отдалены в своем восприятии задач, что подрывает согласованность и в конечном счете эффективность работы.

Ловушка первая: болезнь блестящих игрушек



Часто ошибка начинается на старте: менеджмент объявляет новый ИИ-продукт стратегическим приоритетом, презентует эффектные слайды и запускает проект, не проверив базовые условия — есть ли нужные данные, совместимая архитектура, свободные люди и резерв бюджета.

1 [Rand.org. Why AI Projects Fail and How They Can Succeed.](#) ↗

2 [PMI's Pulse of the Profession, 9th Global Project Management Survey: "Success Rates Rise. Transforming the high cost of low performance", 2017](#) ↗



При этом ключевой участник — инженерная команда — оказывается вне контура принятия решения. Без ее оценки остаются скрытыми объем доработок инфраструктуры, риски и потребность в очистке данных. В итоге план оказывается невыполнимым: сроки срываются, расходы растут, технический долг копится, команда теряет мотивацию, а конкурентное преимущество исчезает вместе с доверием клиентов и инвесторов.

Как понять, что вы уже попали в эту ловушку?

Первый и главный признак — на обсуждениях нет разработчиков, способных оценить реализуемость идеи.

Второй — у команды нет четкого понимания, возможен ли проект технически: были ли проанализированы успешные аналоги, есть ли причина, почему конкуренты не пошли по этому пути.

И третий — ресурсы. Достаточно ли у компании данных, специалистов и бюджета, чтобы проект можно было воплотить в реальности, а не только на слайдах? Если у команды нет понимания, это повод крепко задуматься.

«Часто ИИ-инициативы начинаются с ослепления идеями, при этом нечто похожее на бизнес-план появляется или в конце, или вообще никогда. Хайп вокруг технологии оказывается важнее оценки осуществимости.

Участвуя в подобном проекте, я видел, как бизнес и C-suite настойчиво добивались декоративного внедрения генеративного ИИ в маркетинговый продукт. На функционал это не особенно повлияло бы. Цель заключалась в том чтобы получить заветный ярлык 'GenAI Powered'.

Проект был просто спущен разработчикам, которые должны найти способ, как прикрепить этот шильдик хотя бы где-то. В культуре компании была принята коммуникация только сверху вниз. Игнорирование мнения инженерной команды превратило проект в сизифов труд: в течение полугода были предприняты попытки прикрутить генеративный ИИ, хотя внутри продукта уже прекрасно работали "классические" ML-алгоритмы.

Многочисленные совещания до полуночи и бессмысленная работа привели к выгоранию и потере трети команды. Люди увольнялись, просто не понимая, что и зачем делают»



Артем Егоров

Руководитель Лаборатории иммерсивных технологий Школы управления СКОЛКОВО

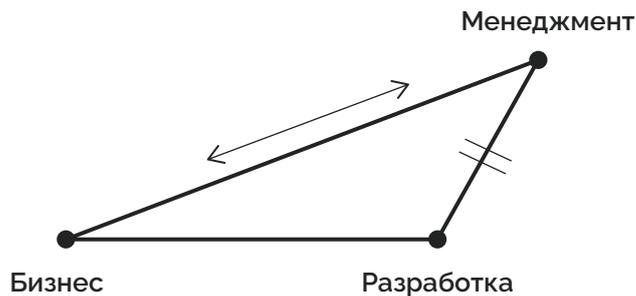


«Это технология в вакууме. Когда люди запускают стартап вроде бы про продукт, но на деле просто хотят развлечься, — это тревожный сигнал. Если проект заявлен как продуктовый, а команда вместо этого сосредоточена на написании научных статей — для меня это red flag. То же самое, если упор идет на патенты: скорее всего, там слишком много бюрократии и мало движения к рынку. Если люди строят решения вокруг GPT, но не могут объяснить, почему их идею нельзя скопировать за неделю, — я тоже не пойду работать. И, наконец, когда команда игнорирует мнение разработчиков и обещает волшебные вещи, это еще один red flag. Все это признаки работы в отрыве от реальности».

Специалист по Deep Learning

Цитата из глубинного интервью,
проведенного в рамках исследования

Ловушка вторая: внедрение ради внедрения



На пике популярности искусственного интеллекта многие компании запускают ИИ-проекты скорее ради статуса, чем ради результата. Топ-менеджменту важно показать — «мы тоже в тренде», разработчикам интересно протестировать новые модели. Пилот оказывается в плане в рекордные сроки, но ключевые бизнес-подразделения в процесс не вовлечены: их не спрашивают, какую задачу стоит решать, как измерять эффект и что будет считаться успехом.

Дальше проект живет своей технической жизнью. Есть прототип, серверы работают, расходы учтены. Но поскольку бизнес-логика и пользовательский опыт остались без внимания, процессы внутри компании не меняются, клиенты не видят ценности и могут даже не пользоваться новым решением.

Итог предсказуем: галочку «ИИ внедрен» поставить можно, но бизнес-пользы нет. Проект превращается в «технологическую витрину» — эффектную, но бесполезную.



«Работа любой организации может быть представлена в виде комплекса взаимодополняющих активов – большой пазл, в котором каждый элемент связан с другим и влияет на него. Когда мы меняем компанию, мы, по сути, добавляем новые элементы, замещаем старые или избавляемся от ненужных. То, что считалось идеальным устройством организации до проекта изменений, ей больше не подходит. С помощью нужных механизмов регуляции нужно привести организацию в соответствие с новыми условиями ведения бизнеса. Ученые называют такой подход аллостатическим – аллостаза подразумевает постоянство через изменения.

Чтобы перевести компанию в состояние аллостаза, нужно научить ее постоянно работать с шестью основными элементами (активами), образующими базу системы управления бизнесом.

Чтобы изменение технологии привело к значимым изменениям в бизнесе, чаще всего необходимо вложиться во все комплементарные (связанные) активы – поменять оргструктуру, методологию работы бизнеса, поменять людей и их КПЭ. Если же, как в примере выше, “накачать” только одну колонну, то эффекта не будет»³

Как понять, что вы уже попали в эту ловушку?

Если проектная документация ограничивается общей фразой «внедрить ИИ», а не конкретной бизнес-задачей, это тревожный сигнал. Если у проекта нет четко назначенного бизнес-спонсора, а «успех» измеряется красивой демо-презентацией вместо реального показателя, значит, вы уже платите за витрину.

Финальный маркер еще очевиднее: после релиза сотрудники продолжают работать по-старому, а активных пользователей системы недостаточно даже для статистически значимой выборки. В таком случае «галочка» в отчете лишь фиксирует факт расходов, но не факт созданной ценности.

«Кстати, тут хороший вопрос, потому что к нам заказчики приходили, и мы выяснили, что они нам никаких критериев не ставят. То есть внедрите ради того, чтобы внедрить – а как мы потом будем оценивать, успешно мы внедрили или нет? Как будто бы для них само слово “внедрить” и “ИИ” уже был успех. А как его потом измерять?»



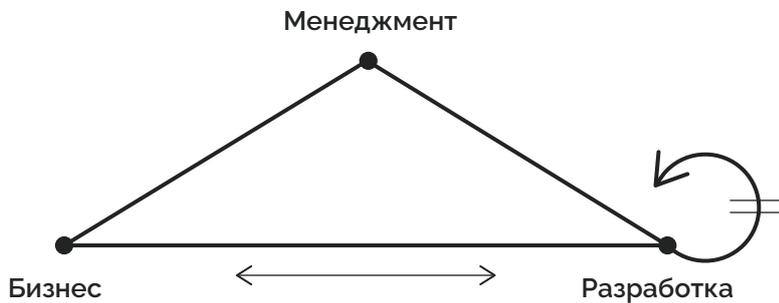
Павел Алферов

Профессор бизнес-практики Школы
управления СКОЛКОВО

Цитата из глубинного интервью,
проведенного в рамках исследования



Ловушка третья: улучшения ради улучшения



Команда разработчиков часто увлекается технической стороной внедрения, и проект превращается в марафон экспериментов. Сначала все выглядит как нормальная работа: рефакторинг кода, обновление пайплайна, тренировка модели на новых данных. Но шаг за шагом приоритет смещается — вместо решения бизнес-задач команда работает ради самой разработки.

Внутри все кипит: обсуждаются новые фреймворки, тестируются «экзотические» датасеты, пишутся технические отчеты. Однако во всем этом нет главного — ответа на вопрос, какую пользу получит компания. Пользовательские сценарии остаются на месте, продуктовая дорожная карта не меняется, а менеджменту все сложнее объяснить, зачем выделять новые GPU и деньги, если сервисы и так работают стабильно.

Для бизнеса со стороны это похоже на «R&D-шоу»: разработчики растут профессионально, улучшают внутренние метрики, но клиент не замечает разницы. Нет сэкономленных часов работы, нет новых пользователей, нет дополнительной выручки.

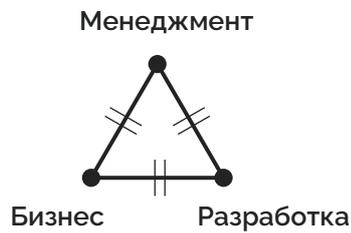
Как понять, что вы уже попали в эту ловушку?

Если команда сосредоточена на тестировании «узких технических интересностей» и не работает над задачами, которые реально нужны бизнесу, проект уходит в сторону. Проверить это можно, задав простой вопрос команде: **какую конкретную бизнес-проблему решает каждая задача из вашего бэклога?**

Когда разработка работает в отрыве от бизнеса и менеджмента, она превращается в эхо-камеру: инженеры придумывают задачи для самих себя, сами их решают и сами оценивают результат. Для компании же ценность при этом остается нулевой



Ловушка четвертая: один за всех, и все за одного



Однако и обратная ситуация — когда между участниками практически нет различий в опыте и подходах — также опасна. При минимальной когнитивной дистанции команда попадает в ловушку «группового мышления»: критические замечания игнорируются, обсуждения становятся формальностью, а энергия направляется на поддержание самой идеи, а не на решение конкретной бизнес-проблемы.

В такой ситуации все участники проекта — менеджмент, владельцы процессов и разработчики — образуют единую «эхо-камеру». Она исключает сомнения и критику, что ведет к близорукости и ошибочным решениям, особенно при масштабных инициативах.

Подобный эффект зафиксирован и в академической среде. Например, исследования научных коллабораций (Tamburri et al., 2018) показали: когда ученые с одинаковым уровнем экспертизы работают вместе, число публикаций растет, но их реальное влияние — измеряемое цитируемостью и значимостью результатов — оказывается ниже, чем у более разнородных команд.

Но как найти правильный баланс? Слишком большая когнитивная дистанция изолирует участников внутри своих департаментов: бизнес говорит на одном языке, разработка — на другом, и проект разваливается. Слишком малая дистанция, напротив, ведет к групповому мышлению.

Наиболее продуктивной оказывается **средняя когнитивная дистанция**. Это ситуация, когда различий достаточно, чтобы учиться друг у друга, но сходства хватает, чтобы понимать и интегрировать знания.



В такой конфигурации стратегический менеджмент, владельцы процессов и разработчики смотрят на проект под разными углами, но при этом сходятся в ответе на ключевой вопрос: «Зачем мы делаем этот проект и какую пользу он приносит каждому из нас?».



«Было недопонимание: заказчики до конца не понимали, как работает искусственный интеллект. Для нас это технология не новая, но для многих обывателей — пока еще в новинку. Мы постарались выровнять ожидания: объяснили коллегам, что реально может сделать ИИ, а что нет. Чтобы все понимали границы возможностей и не ждали от него невозможного».

Цитата из глубинного интервью,
проведенного в рамках исследования

Средства оптимизации когнитивной дистанции

На основе анализа исследований о взаимодействии специалистов с разным уровнем знаний, а также наших глубинных интервью, мы выделили три ключевых практики, которые помогают управлять когнитивной дистанцией в проектах:

- **«Торговые зоны»** — пространства, где команды договариваются о смыслах и целях, используя язык, понятный всем участникам.
- **«Граничные объекты»** — артефакты (документы, прототипы, модели), которые служат общей точкой отсчета для людей с разной экспертизой.
- **«Брокеры знаний»** — специалисты, которые переводят идеи между профессиональными группами и помогают наладить взаимопонимание.

Системное применение этих инструментов позволяет удерживать когнитивную дистанцию на продуктивном уровне: различия между языками и подходами не исчезают, но начинают работать не как барьер, а как источник новых идей и инноваций.

Торговая зона (trading zone) — это формат работы, в котором специалисты из разных областей (например, бизнес, разработка, комплаенс) договариваются о «рабочем языке» и правилах взаимодействия, чтобы решать общие задачи. Этот термин предложил историк науки Питер Галисон.

Такая зона работает, только если она встроена в регулярный процесс — со своими встречами, регламентами и понятными метриками. В ней участники постепенно учатся понимать друг друга, оставаясь в рамках своей профессии.

Главный принцип здесь — признание, что никто не знает всего и что каждый участник проекта зависит от знаний и опыта других. Это создает основу для общего понимания целей, ограничений и допущений проекта, которое разделяют все стороны.

Что может быть торговой зоной на практике?

Это могут быть стратегические сессии, планирование спринтов, воркшопы на стыке функций (например, совместная работа ML-инженеров, дизайнеров и владельцев продукта над customer journey), или cross-review встреча по итогам A/B-теста.

Ключевое условие — чтобы это был **устойчивый ритуал, а не разовая акция**. В таких форматах должны участвовать представители разных ролей, а в центре обсуждения обязательно должен быть **конкретный объект** (результаты теста, прототип, карта пути клиента и т. п.), вокруг которого все стороны могут на равных обсуждать выводы, допущения и сценарии.

«Бывало, что результаты ML-группы вызывали вопросы у экспертов. Данные показывают одно, а на практике, например, определенный инвестиционный объект должен быть в топе по показателям — но этого не происходит. Такие несостыковки становились поводом для споров в хорошем смысле слова: они подталкивали команду к новым вопросам и гипотезам».

Цитата из глубинного интервью,
проведенного в рамках исследования

В этом интервью владелец продукта рассказал об интеграции ML-инженеров и отраслевых экспертов в проекте по предсказанию стоимости инвестиционных объектов. Его реплика хорошо иллюстрирует суть торговой зоны: на кросс-функциональных встречах рождались новые гипотезы, которых не могло появиться без обмена «скрытым знанием» и проверки разных профессиональных логик. Различия переставали быть барьером и превращались в источник идей и конструктивного диалога.

При этом важно понимать: **формальное присутствие разных ролей еще не означает, что торговая зона реально работает**. Если встреча превращается в односторонний доклад без обсуждения, когнитивная дистанция никуда не девается.

Сердцем любой «торговой зоны» является **граничный объект** (boundary object) — общий рабочий артефакт, вокруг которого строится сотрудничество разных команд. Он нужен для того, чтобы люди с разным профессиональным языком могли обсуждать одно и то же, оставаясь в общем контексте.

В исследовании проектирования систем Human-AI Interaction (Ewenstein & Whyte, 2009; Carlile, 2002) таким объектом выступал кликабельный прототип интерфейса: для дизайнеров он показывал сценарии пользовательского опыта, для инженеров — структуру API и ограничения бэкенда. Такой объект позволял всем участникам работать согласованно и видеть прогресс.

В практике ИИ-проектов граничным объектом могут выступать **дашборды, рабочие прототипы (MVP), графики, User Story или трекеры задач**. Важно, чтобы объект обладал четырьмя свойствами:

- 1 Интерпретационная гибкость — каждый участник может читать его на своем языке.
- 2 Пластичность — объект можно дорабатывать по мере уточнения требований или появления новых данных.
- 3 Прозрачность — изменения видны всем, что укрепляет доверие.
- 4 Документация — через объект фиксируются договоренности, снижая издержки на согласования.

Так, например, User Story становится полноценным граничным объектом, когда она действительно объединяет разные роли. В ней фиксируется целевой результат — например, в проекте рекомендательной системы:

«**Как покупатель, я хочу** получать рекомендации сразу после открытия страницы, **чтобы** быстрее находить нужный товар».

Эта формулировка сразу считывается по-разному для участников команды:

- **для бизнеса** — как задача по росту конверсии,
- **для ML-инженеров** — как техническое требование (отклик системы не более 300 мс),
- **для дизайнеров** — как описание блока интерфейса и ожидаемого поведения пользователя.

История остается открытой и редактируемой. На общих встречах в нее вносятся уточнения: «Есть ли у нас подходящие данные?», «Это реально для MVP?», «Что считать готовым результатом?». Все вопросы фиксируются понятным для всех языком в виде критериев приемки, подзадач или комментариев.

Если на этапе демо возникает разрыв между ожиданиями и результатом, именно User Story становится местом разбора и поиска ответа на вопрос «Что именно мы упустили?». Такая «прозрачная эволюция» превращает ее в общий якорь — гибкий для доработок, но удерживающий все роли в одном смысловом поле и не позволяющий забыть о целях проекта.



User Story (как и любой другой артефакт) перестает быть граничным объектом, если используется односторонне — например, только как документ «для галочки» или если в нее никто не вносит изменений. Важно помнить: работа с такими артефактами выполняет двойную функцию. С одной стороны, она помогает команде находить общий язык. С другой — позволяет выявлять разрывы в понимании, то есть подсвечивать когнитивную дистанцию.

Создавать и поддерживать граничные объекты — задача не из простых, но пренебрегать ею нельзя. Со временем они складываются в основу инфраструктуры знаний команды, то есть в ту среду, где участники обмениваются информацией, согласуют решения и двигают проект вперед.

«Раньше у нас информация была разбросана кто где. Потом команда сама решила собрать общую базу знаний в Confluence, чтобы все лежало в одном месте: и менеджеры могли использовать для продаж, и остальные находили нужные материалы. Сейчас база есть, но структура пока неидеальная: встречаются противоречия, сложные перекрестные ссылки, где-то файлы, где-то Excel-таблицы».

Представитель сектора продаж

Цитата из глубинного интервью,
проведенного в рамках исследования

Чтобы граничные объекты реально помогали сокращать когнитивную дистанцию в торговой зоне, ИИ-проекту нужен брокер знаний (knowledge broker) — человек, который одинаково уверенно чувствует себя и в бизнес-среде, и в мире технологий. Его признают обе стороны, и он умеет «переводить» их язык друг для друга.

В чем функции брокера знаний в проектах внедрения ИИ и кто может им стать?

Бизнес-аналитик:

- Берет общую бизнес-цель (например, увеличить среднюю выручку на пользователя на 5%) и раскладывает ее на понятные измеримые элементы: сегменты клиентов, прогноз прироста, параметры работы модели. Эти элементы превращаются в конкретные артефакты (User stories, технические требования), которыми одинаково могут пользоваться и владелец продукта, и ML-инженер.
- Сводит к одному знаменателю разные трактовки целей. Для руководства «удержание пользователей» — это рост активности через месяц после установки, а для команды разработки — конкретный показатель работы модели. Такой перевод предотвращает путаницу и сохраняет общий фокус.

Продуктовый менеджер с опытом в разработке:

- Собирает воедино разрозненные ожидания бизнеса, требования регуляторов и технические ограничения команды. Все это превращается в артефакт — например, Lean Canvas. Для топ-менеджеров это карта ценности, для ML-команды — критерии качества модели, для UX-дизайнеров — сценарии поведения пользователей. Один документ работает для всех.
- Удерживает баланс между скоростью релиза и качеством алгоритма. Продакт решает, какие улучшения модели действительно принесут прирост бизнес-метрик, а какие лишь задержат запуск. Благодаря праву на такие промежуточные решения он выступает «живым» брокером, а не формальной фигурой.
- Публично вскрывает зоны незнания. Формулируя уточняющие вопросы вроде «Как увеличение точности модели скажется на оттоке пользователей сегмента В?», продакт показывает, что ни бизнес, ни разработка не владеют всей картиной в одиночку, и переводит экспертное знание обеих сторон в общий актив команды.

Наконец, эффективными брокерами могут выступать **технический тимлид с инженерным бэкграундом и управленческой подготовкой или системный аналитик**. Тимлид способен поддерживать доверие обеих сторон, так как одновременно разделяет профессиональные ценности разработчиков и понимает язык продуктовых и бизнес-метрик.

Системный аналитик играет роль связующего звена: он одновременно работает с кодом и с бизнес-метриками. По сути, он переводит технические ограничения в язык бизнеса и наоборот. Например, аналитик может объяснить, как часто можно обновлять данные в модели и к чему приведут задержки. Это позволяет бизнесу заранее учитывать технические риски, а разработчикам — понимать, какие параметры критически важны для выручки и клиентов.

Исследование DiBenigno & Kellogg (2014) показывают, что **брокер эффективен**, когда:

- владеет профессиональным словарем обеих сторон;
- имеет кредит доверия и право принимать промежуточные решения;
- присутствует в торговой зоне постоянно, а не эпизодически.

В том же исследовании эмпирические данные подтверждают: как только нарушается хотя бы одно из этих условий, посредник теряет свою функцию. Он может превратиться в «декоративную фигуру», которая числится в проекте, но реально не влияет на работу.

Наконец, потеря доверия хотя бы одной из сторон делает брокера знаний «чужим» [Levina & Vaast, 2005], а нерегулярное участие ведет к накоплению скрытых конфликтов, которые потом обостряются [Haas, 2015].

Эффект достигается системно

«Исследование очень точно описывает функции брокера знаний, которые являются краеугольными камнями успешных ИИ-проектов. Роли бизнес-аналитика и продуктового менеджера жизненно важны. Однако мой опыт показывает, что даже при идеальной дискуссии между менеджментом, бизнесом и разработкой существует критический риск.

Этот риск — отложенная реальность, которая возникает, когда системный аналитик, выполняющий роль фильтра применимости, подключается к процессу периодически, а не постоянно. Команда, не имея полного представления об архитектурных ограничениях, тратит драгоценное время на разработку «идеального» на бумаге решения. Месяц за месяцем, после долгих обсуждений и правок, внезапное появление системного аналитика и его вердикт приводит к отмене 20% планов, что вызывает агрессивную реакцию и, как следствие, потерю интереса и еще более редкое участие.

Таким образом, системный аналитик превращается из «стража осуществимости» в катализатор конфликта. Роль брокера знаний — это не декоративная функция, а критически важный фактор успеха. Его постоянная вовлеченность и проактивная работа на опережение позволяют превратить потенциальные тупики в управляемые риски»



Артем Егоров

Руководитель Лаборатории
иммерсивных технологий Школы
управления СКОЛКОВО

Через тернии к звездам: системные управленческие рекомендации

В этом разделе мы предлагаем целостную методологию, которая сопровождает ИИ-проект от первого вопроса о его бизнес-ценности до долгосрочной эксплуатации модели. В ее основе лежат проверенные временем подходы — CRISP-DM и его отраслевые продолжения (DataPro, CRISP-ML(Q), MAISTRO). Эти методы задали высокие стандарты работы с данными, но почти не учитывали управленческие и культурные барьеры. Из-за этого даже технически безупречные решения нередко оказывались невостребованными в компаниях. Наши рекомендации восполняют этот пробел: они сохраняют лучшие практики CRISP-DM, но дополняют их этапами, которые помогают адаптировать и внедрять ИИ-решения так, чтобы они естественно «приживались» в организации и приносили реальную пользу.

Метод включает пять взаимосвязанных фаз:

- 1 **Определение целей и возможностей.** Проект обсуждается сразу с тремя ключевыми группами — стратегическим менеджментом, владельцами бизнес-процессов и разработчиками. Формируется общее понимание ценности и реалистичности инициативы.
- 2 **Работа с данными.** Проверяется, есть ли в компании необходимые данные для реализации проекта и достаточно ли высокого качества.
- 3 **Разработка и прототипирование.** Создаются и тестируются первые версии решения, идет постоянная коммуникация всех участников, люди и процессы готовятся к запуску.
- 4 **Внедрение и адаптация.** Решение интегрируется в работу, корректируются процессы, оценивается успешность.
- 5 **Мониторинг и улучшения.** После релиза проект не оставляют «на автопилоте»: результаты регулярно отслеживаются, а система дорабатывается на основе фактических эффектов.

Такое построение позволяет избежать типичных причин провалов, выявленных нами в двух десятках глубинных интервью: проект стартует с реалистичных целей, роли и задачи участников понятны, а после внедрения управление сохраняется в режиме постоянного мониторинга и доработки. Предусмотренная методологией «границная инфраструктура» делает каждый шаг прозрачным и дает возможность вовремя отказаться от невостребованных инициатив, прежде чем они превратятся в долгострой.



Этап первый: Определение целей и возможностей



Старт проекта, увы, нередко становится его финалом. Поэтому в этом фреймворке мы делаем особый акцент на первом этапе: нужно четко понять бизнес-задачи, определить ценность проекта и трезво оценить ресурсы разработки. От качества этой работы зависит, получит ли ИИ-решение прочный фундамент или начнет рассыпаться сразу.

Мы сознательно соединяем три перспективы — стратегическую, операционную и техническую. Если упустить хотя бы одну, резко растет риск взаимного непонимания: со стороны менеджмента и бизнеса — ценности проекта для компании и конечного пользователя; со стороны разработки — целей продукта, реалистичности задумки и наличия ресурсов. Без такой синхронизации дальнейшие шаги превращаются в «испорченный телефон»: команда может месяцами улучшать метрики, которые не помогают бизнесу, и наоборот.

Ключевое условие успеха на этом этапе — распознать, скорректировать и поддерживать оптимальную когнитивную дистанцию между менеджментом, бизнес-экспертами и разработчиками. Для этого используются инструменты, о которых говорилось ранее: торговые зоны, граничные объекты и брокеры знаний. В рамках первого этапа они играют решающую роль; далее разберем каждый по порядку.

На этом этапе важно сразу создать «торговую зону» — формат встреч, где представители трех сторон проекта (стратегический менеджмент, владельцы процессов и разработка) обсуждают цели и задачи на одном языке. Здесь особенно нужны участники, которые могут «переводить» между технической и управленческой логикой, снимая риск взаимного непонимания.

Наш фреймворк предлагает уже в начале проекта сразу оценить, насколько легко ключевые участники понимают друг друга.

- Если взаимопонимание высокое, можно распределить ответственность равномерно и наладить быстрый цикл обратной связи, чтобы сохранять темп работы.
- Если разрыв велик, сначала нужно обсудить базовые вопросы: какие цели ставятся, какие ресурсы доступны и зачем компании это ИИ-решение. Такой разговор помогает выровнять ожидания и вовремя «заземлить» амбиции.

Только после этого имеет смысл закреплять зоны ответственности. А чтобы поддерживать диалог и не терять контакт между сторонами на протяжении всего проекта, стоит назначить **брокеров знаний** — посредников, которые помогают переводить идеи с одного «профессионального языка» на другой и удерживают баланс.

Чтобы договоренности не оставались на уровне устных обещаний, важно использовать **граничные объекты** — артефакты, которые понятны всем участникам и могут меняться вместе с проектом. Это могут быть:

- **User Story или техническое задание**, где фиксируются цели и ограничения на общем языке,
- **Data Story**, описывающая требования к данным,
- **Model Story**, задающая ожидаемое поведение алгоритма в продакшене.

Эти документы работают только в связке с регулярными «торговыми зонами» — устойчивыми форматами совместной работы (например, стратегические сессии или еженедельные проектные встречи), где артефакты обсуждаются, уточняются и при необходимости переписываются.

Исследования показывают: команды, которые уже в первые недели проекта согласовывают цели, оценивают когнитивную дистанцию и формализуют граничные объекты, проходят ключевые этапы внедрения ИИ быстрее и без лишних трат. У них ниже транзакционные издержки и реже приходится пересматривать решения (Knoben & Oerlemans, 2006). Если же эта работа откладывается «на потом» и начинается только после первых конфликтов, издержки резко растут, а доверие внутри команды падает.

Итак, договоренности есть, граничные объекты зафиксированы. Следующий шаг — разобраться с данными: что у заказчика уже есть, чего не хватает и можно ли на этой базе строить проект.

Этап второй: Подготовка данных

«Подготовка данных» — это первый тест на жизнеспособность проекта. Здесь команда проверяет, с чем она будет работать, и фиксирует правила игры.

Сначала документируется происхождение данных. Проверяется, хватает ли их, насколько они полные и отражают ли реальность. Одновременно подтверждается, что обработка данных законна и не нарушает требования по безопасности. Это защищает проект от будущих проблем.

Этап может затянуться, и это нормально. Важно заранее понимать: если данных мало, они низкого качества или их использование ограничено регуляторами, проект может застопориться еще до разработки.

Команда также задает контрольные параметры: сколько пропусков допустимо, насколько данные должны быть стабильны, какие отклонения считаются критичными. Все это фиксируется в рабочем документе (Data Story), чтобы и бизнес, и разработчики видели риски в одном поле. Там же отмечаются права доступа и ведется журнал использования данных. Это снижает вероятность утечек и лишних споров о том, кто и что может использовать

Такой подход экономит ресурсы на следующих этапах. Команда переходит к разработке уже с проверенными и прозрачными данными, что повышает доверие всех участников проекта.

Этап третий: Разработка и прототипирование

Мы рекомендуем строить разработку как постоянный цикл обратной связи. Команда делает шаг вперед, показывает промежуточный результат, получает комментарии от бизнеса и дорабатывает продукт с их учетом. Такой ритм помогает держать участников «на одной волне» и превращает разницу в подходах в источник знаний, а не конфликтов.

Цикл работает так:

- Требования бизнеса переводятся в понятные всем рабочие документы (User Story, техническое задание и т.п.).
- Разработчики создают прототип, который регулярно показывают коллегам на встречах.
- Бизнес и другие участники дают обратную связь, она фиксируется и превращается в новые задачи.
- Команда улучшает продукт и снова демонстрирует результат.

Такой формат обеспечивает прозрачность и удерживает когнитивную дистанцию в продуктивных границах: никто не работает «в вакууме», а процесс становится управляемым и предсказуемым.

В работе над моделями мы опираемся на лучшие практики, которые выделяют исследователи ML-команд (Polyzotis et al., 2018). Эти практики помогают держать процесс под контролем и сохранять качество:

- **Документация.** Нужно фиксировать все: источники данных, настройки, зависимости, логи, результаты тестов. Единый стандарт документации упрощает масштабирование и передачу проекта другим специалистам.
- **Управление версиями.** Код, данные и настройки должны храниться с привязкой к конкретным версиям. Это позволяет отслеживать изменения и при ошибках быстро откатываться к рабочему варианту.
- **Воспроизводимость.** Эксперимент должен быть повторяемым: если заново пройти весь процесс — от подготовки данных до обучения модели — результат обязан совпадать с исходным. Это обеспечивает прозрачность и доверие к проекту.

В крупных внедрениях ИИ воспроизводимость становится обязательным условием. Она доказывает корректность результатов, исключает разночтения при передаче модели из разработки в эксплуатацию, обеспечивает единое качество данных на всех этапах ML-процесса и снижает вероятность случайных ошибок. Кроме того, воспроизводимые эксперименты делают работу прозрачной и дают бизнесу уверенность в том, что решение можно масштабировать.⁴

Ключевым «граничным объектом» этой фазы выступает минимально жизнеспособный прототип (MVP). Чем раньше появляется рабочая версия ИИ-решения, тем проще вести предметный разговор о проекте: корректировать требования, уточнять ожидания и согласовывать цели. Видимая скорость итераций повышает доверие менеджмента к команде. Опасный сигнал — если разработка уходит в изоляцию, общение с бизнесом сокращается, а сроки растут. Это прямой путь к провалу.

Тестирование

Перед полноценным запуском модель проверяют на реальном трафике в «скрытом» или ограниченном режиме. Критерии успеха, зафиксированные в Data Story, работают как светофор: если показатели в норме — модель идет дальше, если нет — начинается новая итерация (Rahman et al., 2025). QA-команда фиксирует все отклонения и превращает их в задачи для следующего цикла.

4 <https://census.ai/wiki/ml-reproducibility> ↗

Подготовка будущих пользователей

Параллельно важно готовить тех, кто будет работать с системой. Особенно это критично в people-driven культурах и там, где ИИ берет на себя часть привычных функций сотрудников. У людей может появиться страх: «машина отнимет мою работу, мои навыки больше не нужны». Чтобы этого не произошло, нужно показать выгоды для них самих — как ИИ облегчает рутину, расширяет возможности и помогает в сложных случаях. После этого переходить к обучению: как правильно использовать систему и встраивать ее в ежедневные процессы.

Приемка разработки

Когда тестирование завершено, команда заказчика и разработчики вместе проверяют: совпадает ли то, что получилось, с тем, что было прописано в User Story и критериях приемки. Если все соответствует, проект переходит к стадии внедрения.

Передается не только код и документация, но и «набор для эксплуатации»: дашборды с ключевыми показателями, система оповещений о критических сбоях и простые инструкции, как читать эти данные. Такой пакет помогает использовать модель не как «черный ящик», а как прозрачный инструмент, который можно контролировать и улучшать.

Важно сохранить быстрый канал связи с разработчиками — особенно в первые месяцы. Это позволяет быстро устранять проблемы и облегчает переход на новые процессы.

Этап четвертый: Внедрение и адаптация

Даже после того как система технически развернута, именно первые недели определяют ее судьбу: станет ли она частью рабочих процессов или «зависнет» из-за сопротивления сотрудников, старых регламентов и отсутствия изменений в операционной логике. Этот этап по уровню рисков не менее важен, чем разработка и тестирование, хотя во многих классических подходах (например, CRISP-DM) он почти не выделяется.

Ключевым инструментом здесь служит дорожная карта внедрения и адаптации — граничный объект, который еще на прошлом этапе формируют владельцы бизнес-процессов. В ней прописываются основные шаги, контрольные точки, ответственные, KPI и бюджет. Этот документ дает ответы на три главных вопроса:

- 1 **Интеграция в системы.** Где именно подключается модель, какие сервисы нужно перестроить, какие данные и мощности потребуются?

- 2 **Принятие сотрудниками.** Какие роли исчезают или меняются, кого нужно переобучить, какие новые навыки добавить? Сюда же входят планы коммуникаций и программы адаптации.
- 3 **Экономика процесса.** Как меняется структура затрат и доходов, какие KPI пересматриваются, какие статьи бюджета высвобождаются или перераспределяются?

Дорожная карта строится в три слоя.

- 1 **Подготовка людей.** Сотрудников переобучают, проводят менторские сессии и предоставляют поддержку. Цель — снизить тревожность и направить высвободившееся время на более важные задачи.
- 2 **Подготовка процессов.** Пересматриваются регламенты, убираются лишние ручные шаги, обновляются стандарты качества и вводятся новые показатели эффективности. Высвободившиеся ресурсы направляются на развитие продукта и инфраструктуры.
- 3 **Регулярный мониторинг.** Команда регулярно отслеживает, как новая система используется на практике: смотрит на поведение пользователей, оценивает бизнес-показатели и вносит корректировки.

Работа сопровождается четким управленческим ритмом: еженедельные встречи владельца процесса, аналитика и тимлида разработки позволяют сверять прогресс с планом, фиксировать отклонения и согласовывать изменения. В конце цикла проводится ретроспектива с отчетом, где отражены статус внедрения, динамика ключевых метрик и влияние на экономику подразделения.

Фаза «внедрение и адаптация» считается завершенной, когда проект выходит на стабильный режим работы: ключевые метрики (нагрузка, устойчивость, удовлетворенность пользователей) укладываются в заданные границы, сопротивление сотрудников сведено к минимуму, а экономический эффект подтвержден. После этого готовится финальный отчет, который утверждают стейкхолдеры. С этого момента решение включается в портфель цифровых инициатив компании: оно получает регулярное финансирование, закрепляется в операционных процессах и сопровождается в режиме постоянного мониторинга и доработок.

Этап пятый

Мониторинг и улучшения

После внедрения система не становится «готовой навсегда». Начинается ее эксплуатация — и вместе с ней новый цикл изменений. Обычно хочется улучшить точность, ускорить работу, поменять интерфейс или подключить новые данные. Без рамок это легко превращается в «бесконечный ремонт».

Чтобы избежать такой ситуации, мы заранее ввели рабочие документы — User Story, Data Story, Model Story, дорожную карту и протоколы сопровождения. Они стали опорой: любое новое предложение проверяется через них и превращается в понятное действие. Это позволяет улучшать систему постепенно и осознанно, не теряя фокус и не скатываясь в хаос бесконечных доработок.

На заключительном этапе основным инструментом становится единый дашборд с тремя контурами мониторинга:

- **Модель** — отслеживает качество работы: не изменились ли данные, не ухудшились ли прогнозы, требуется ли переобучение.
- **Бизнес** — показывает, достигаются ли KPI и есть ли экономический эффект от внедрения.
- **Пользователи** — отражает, как пользователи работают с системой: насколько глубоко ее применяют, как часто обращаются, какой уровень удовлетворенности и что они отмечают в отзывах.

Если хотя бы один из трех контуров выходит за рамки нормы, это автоматически запускает новый цикл улучшений. Мониторинг в таком случае работает не только как инструмент контроля, но и как сигнал к развитию. Со временем частота ретроспектив и встреч снижается: сначала они проводятся ежемесячно, затем только по мере необходимости. Проект считается завершенным, когда показатели всех трех контуров стабилизировались, а цели, зафиксированные в исходных документах, достигнуты в согласованный срок.

При этом работа не прекращается. На этапе эксплуатации рождаются идеи для новых инициатив: обратная связь от пользователей, данные мониторинга и новые бизнес-задачи становятся отправной точкой для следующего витка. Так цикл замыкается и тут же начинается снова — но уже на новом уровне зрелости.

Управленческие рекомендации

Вовлекайте всех участников с самого начала

Не запускайте проект только усилиями топ-менеджмента или разработчиков. Уже на старте за одним столом должны быть бизнес-владельцы, инженеры и менеджеры. Это поможет сразу выявить ограничения по данным, архитектуре и ресурсам.

Поддерживайте баланс между стейкхолдерами

Не стремитесь полностью стереть разницу в подходах между бизнесом, разработкой и другими стейкхолдерами. Разные взгляды полезны, если они не мешают понимать друг друга. Следите, чтобы команда сохраняла критический взгляд, но при этом могла находить общий язык.

Работайте через граничные объекты

User Story, Data Story, MVP-прототип, дашборд с метриками — любые артефакты, которые понятны и бизнесу, и разработчикам. Фиксируйте договоренности через такие объекты, чтобы все стороны видели одно и то же и могли отслеживать прогресс.

Не отпускайте проект «на автопилот».

Даже после релиза продолжайте поддерживать общий ритм: короткие циклы обратной связи, регулярный мониторинг и открытые обсуждения. Это убережет проект от вырождения в формальную «галочку» в отчетах.

1

2

Проверяйте, есть ли у проекта реальная цель

Формулировка цели как «внедрить ИИ» — тревожный сигнал. Настоящая цель звучит как конкретная бизнес-задача: «снизить коэффициент оттока на 10%» или «сократить время обработки заявки на 20%». Если такого фокуса нет, проект рискует превратиться в витрину.

3

4

Организируйте «торговые зоны»

Повысить продуктивность могут различные форматы совместной работы: стратегические сессии, спринт-планирование, кросс-функциональные ревью. Это пространство, где стейкхолдеры синхронизируют ожидания и договариваются о следующих шагах.

5

6

Назначайте брокеров знаний

В команде должны быть люди «на стыке»: продукт-менеджеры с опытом разработки, бизнес-аналитики, системные аналитики. Их задача — переводить с языка бизнеса на язык технологий и обратно. Без таких посредников коммуникация быстро ломается.

7

Источники

- 1 Исследование The Economic Potential of Generative AI от McKinsey (2023) <https://www.mckinsey.de/-/media/mckinsey/locations/europe%20and%20middle%20east/deutschland/news/presse/2023/2023-06-14%20mgi%20genai%20report%202023/the-economic-potential-of-generative-ai-the-next-productivity-frontier-vf.pdf>
- 2 Оценки компании Statista на 2025 год. <https://www.statista.com/forecasts/1449844/ai-tool-Users-worldwide>
- 3 Исследование The State of AI: How Organizations are Rewiring to Capture Value от компании McKinsey (2025). <https://www.mckinsey.com/capabilities/quantumblack/our-insights/the-state-of-ai>
- 4 Исследование Trust, Attitudes and Use of Artificial Intelligence от KPMG (2025). <https://kpmg.com/xx/en/our-insights/ai-and-technology/trust-attitudes-and-use-of-ai.html>
- 5 Исследование Superagency in the Workplace: Empowering People to Unlock AI's Full Potential от McKinsey (2025) <https://www.mckinsey.com/capabilities/mckinsey-digital/our-insights/superagency-in-the-workplace-empowering-people-to-unlock-ais-full-potential-at-work>
- 6 Исследование The GenAI Divide State of AI in Business 2025 от MIT (2025). https://mlq.ai/media/quarterly_decks/v0.1_State_of_AI_in_Business_2025_Report.pdf
- 7 Amirian, E. (2024, March). Synergizing hybrid Agile-Scrum and CRISP-DM approaches in data-science project management for gas-oil projects (Paper No. SPE-218114-MS). Proceedings of the 24th Conference & Exhibition on Energy Technology. Society of Petroleum Engineers. <https://onepetro.org/specet/proceedings-abstract/24CET/24CET/543143>
- 8 Aoki, M. (2001). Toward a comparative institutional analysis: Implications for the theory of the firm. *Journal of Economic Perspectives*, 15(4), 3–22. <https://doi.org/10.1257/jep.15.4.3>
- 9 Bosua, R., Scheepers, R., & Lakomski, G. (2004). Distributed cognition and IT support for knowledge work in breakdowns: Match or mismatch? In Proceedings of the Australasian Conference on Information Systems (ACIS 2004) (Paper 44). AIS Electronic Library. <http://aisel.aisnet.org/acis2004/44>
- 10 Carlile, P. R. (2002). A pragmatic view of knowledge and boundaries: Boundary objects in new product development. *Organization Science*, 13(4), 442–455. <https://doi.org/10.1287/orsc.13.4.442.2953>
- 11 Chamayou, G. (2015). *A theory of the drone* (J. Lloyd, Trans.). The New Press. (Original work published 2013) <https://doi.org/10.2307/jj.26193307>
- 12 Cui, T., Tong, Y., Teo, H.-H., & Li, J. (2020). Managing knowledge distance: IT-enabled inter-firm knowledge capabilities in collaborative innovation. *Journal of Management Information Systems*, 37(1), 217–250. <https://doi.org/10.1080/07421222.2019.1705504>
- 13 DiBenigno, J., & Kellogg, K. C. (2014). Beyond occupational differences: The importance of cross-cutting demographics and dyadic toolkits for collaboration in a U.S. hospital. *Administrative Science Quarterly*, 59(3), 375–408. <https://doi.org/10.1177/0001839214538262>
- 14 Ewenstein, B., & Whyte, J. (2009). Knowledge practices in design: The role of visual representations as "epistemic objects." *Organization Studies*, 30(1), 7–30. <https://doi.org/10.1177/0170840608083014>
- 15 Fischer, G. (2000). Social creativity, symmetry of ignorance, and meta-design. *Knowledge-Based Systems*, 13(7–8), 527–537. [https://doi.org/10.1016/S0950-7051\(00\)00065-4](https://doi.org/10.1016/S0950-7051(00)00065-4)
- 16 Furniss, D. (2004). Codifying distributed cognition: A case study of emergency medical dispatch (Master's thesis, University College London). UCL Discovery. <https://discovery.ucl.ac.uk/id/eprint/5185/>
- 17 Haas, A. (2015). Crowding at the frontier: Knowledge brokers, gatekeepers, boundary spanners and marginal-intersecting individuals. *Journal of Knowledge Management*, 19(5), 1029–1047. <https://doi.org/10.1108/JKM-01-2015-0036>
- 18 Hayles, N. K. (2025). *Bacteria to AI: Human futures with our nonhuman symbionts*. University of Chicago Press.
- 19 He, V. F., von Krogh, G., & Sirén, C. (2022). Expertise diversity, informal leadership hierarchy, and team knowledge creation: A study of pharmaceutical research collaborations. *Organization Studies*, 43(6), 907–930. <https://doi.org/10.1177/01708406211026114>
- 20 Hutchins, E. (1995). *Cognition in the wild*. MIT Press.

- 21 Jablokow, K. W., & Booth, D. E. (2006). The impact and management of cognitive gap in high-performance product development organizations. *Journal of Engineering and Technology Management*, 23(4), 313–336. <https://doi.org/10.1016/j.jengtecman.2006.08.003>
- 22 Jensen, A., Secchi, D., & Jensen, T. W. (2022). A distributed framework for the study of organizational cognition in meetings. *Frontiers in Psychology*, 13, Article 769007. <https://doi.org/10.3389/fpsyg.2022.769007>
- 23 Kertcher, Z., & Coslor, E. (2020). Boundary objects and the technical culture divide: Successful practices for voluntary innovation teams crossing scientific and professional fields. *Journal of Management Inquiry*, 29(1), 76–91. <https://doi.org/10.1177/1056492618783875>
- 24 Dekker, H. C., Donada, C., & Nogatchewsky, G. (2024). Exploiting cognitive distance for enhanced innovative capabilities: The role of collaboration controls in incumbent–startup partnerships. *Technovation*, 134, Article 103047. <https://doi.org/10.1016/j.technovation.2024.103047>
- 25 Knoblen, J., & Oerlemans, L. A. G. (2006). Proximity and inter-organizational collaboration: A literature review. *International Journal of Management Reviews*, 8(2), 71–89. <https://doi.org/10.1111/j.1468-2370.2006.00121.x>
- 26 Knorr-Cetina, K. (1999). *Epistemic cultures: How the sciences make knowledge*. Harvard University Press. <https://doi.org/10.4159/9780674039681>
- 27 Levina, N., & Vaast, E. (2005). The emergence of boundary spanning competence in practice: Implications for implementation and use of information systems. *MIS Quarterly*, 29(2), 335–363. <https://doi.org/10.2307/25148682>
- 28 Ma, Z., Jørgensen, B. N., & Ma, Z. G. (2025, January 21). DataPro – A standardized data understanding and processing procedure: A case study of an eco-driving project (arXiv:2501.12176) [Preprint]. arXiv. <https://arxiv.org/abs/2501.12176>
- 29 Maglio, P. P., Kandogan, E., & Haber, E. (2003). Distributed cognition and joint activity in collaborative problem solving. In *Proceedings of the 25th Annual Conference of the Cognitive Science Society* (pp. 657–662). Cognitive Science Society.
- 30 Nonaka, I., & Takeuchi, H. (1995). *The knowledge-creating company: How Japanese companies create the dynamics of innovation*. Oxford University Press.
- 31 Nooteboom, B. (2000). Learning by interaction: Absorptive capacity, cognitive distance and governance. *Journal of Management and Governance*, 4(1), 69–92. <https://doi.org/10.1023/A:1009941416749>
- 32 Nooteboom, B. (2004). Innovation, learning and cluster dynamics (ERS-2004-006-ORG). Erasmus Research Institute of Management. <https://repub.eur.nl/pub/1125/ERS%202004%20006%20ORG.pdf>
- 33 Nooteboom, B. (2009). *A cognitive theory of the firm: Learning, governance and dynamic capabilities*. Edward Elgar Publishing. <https://doi.org/10.4337/9781848447424>
- 34 Polyzotis, N., Roy, S., Whang, S., & Zinkevich, M. (2018). Data lifecycle challenges in production machine learning: A survey. *ACM SIGMOD Record*, 47(2), 17–28. <https://doi.org/10.1145/3299887.3299891>
- 35 Rahman, A., Skjellum, A., & Zhang, Y. (2025). An exploratory study of security vulnerabilities in machine learning deployment projects. In *Proceedings of the 2025 IEEE/ACM 3rd International Workshop on Software Vulnerability Management (SVM)* (pp. 33–36). IEEE. <https://doi.org/10.1109/SVM66695.2025.00009>
- 36 Rodriguez-Ferradas, M. I., Sanjurjo-San Martin, E. L., & Alfaro-Tanco, J. A. (2023). Relevant factors influencing cognitive distance in the performance of collaborative research projects. *International Journal of Qualitative Methods*, 22, Article 16094069231174761. <https://doi.org/10.1177/16094069231174761>
- 37 Russo, D. (2023, July 12). Navigating the complexity of generative AI adoption in software engineering (arXiv:2307.06081) [Preprint]. arXiv. <https://arxiv.org/abs/2307.06081>
- 38 Schubert, C., & Kolb, A. (2021). Designing technology, developing theory: Toward a symmetrical approach. *Science, Technology, & Human Values*, 46(3), 528–554. <https://doi.org/10.1177/0162243920941581>
- 39 Stevens, M., Wehrens, R., & de Bont, A. (2020). Epistemic virtues and data-driven dreams: On sameness and difference in the epistemic cultures of data science and psychiatry. *Social Science & Medicine*, 258, 113116. <https://doi.org/10.1016/j.socscimed.2020.113116>
- 40 Studer, S., Bui, T. B., Drescher, C., Hanuschkin, A., Winkler, L., Peters, S., & Müller, K.-R. (2020, March 11). Towards CRISP-ML(Q): A machine learning process model with quality assurance methodology (arXiv:2003.05155) [Preprint]. arXiv. <https://arxiv.org/abs/2003.05155>
- 41 Wuyts, S. H. K., Colombo, M. G., Dutta, S., & Nooteboom, B. (2005). Empirical tests of optimal cognitive distance. *Journal of Economic Behavior & Organization*, 58(2), 277–302. <https://doi.org/10.1016/j.jebo.2004.03.019>

ailabskolkovo



Пишем о том, где место
ИИ в бизнесе.
Исследуем и изучаем —
подписывайтесь, чтобы быть
в точке инноваций