

Доверие к ИИ- агентам: Российский бизнес оценивает ИИ



Технологии
Доверия



Исследование ТеДо «Российский бизнес оценивает ИИ», декабрь 2025



Цель исследования:

Оценка уровня доверия и готовности бизнеса к взаимодействию с ИИ-агентами

Формирование подхода для российских компаний, позволяющего безопасно и эффективно интегрировать ИИ-технологии в свои процессы.



Участники опроса:

1000 + 1 руководителей компаний и ИТ-директоров*, включая 270 представителей среднего и крупного бизнеса



Участники глубинных интервью:

Крупные игроки финансового рынка



Задачи:

1. Выявить текущий уровень ИИ в основных видах деятельности и внутренних процессах
2. Оценить уровень доверия при передаче процесса принятия решений на сторону ИИ
3. Оценить готовность бизнеса к взаимодействию с ИИ-агентами клиентов, ИИ-агентов партнеров и ИИ-сотрудниками
4. Проверить гипотезу, что доверие к ИИ-агентам является значимым барьером, замедляющим внедрение ИИ в бизнесе

Исследование по Оценке уровня доверия и готовности бизнеса к взаимодействию с ИИ-агентами проводилось совместно с аналитическим центром НАФИ

Выступление представляет результаты исследования



Технологии
Доверия



НАФИ
АНАЛИТИЧЕСКИЙ ЦЕНТР

ИИ-агенты: дань моде или новый стандарт рынка?

ИИ в научной среде определяется через рациональных агентов на протяжении последних 70 лет. Повышенное внимание к теме ИИ-агентов в 2025 году в российской и международной бизнес-среде связано с ростом автономности решений на базе ИИ и с переходом к платформенному подходу.

Волны развития ИИ

Рациональный агент

1950г.

01 ИИ интернета

Рекомендательные алгоритмы ИИ в маркетинге

ИИ-агент

2025г.

02 ИИ для бизнеса

Повсеместное внедрение ИИ в бизнес-процессы за счет инвестиций в инфраструктуру

03 ИИ восприятия

Умные колонки, камеры, распознавание лиц, дополненная реальность Стирание грани онлайн и офлайна.

04 Автономный ИИ

Беспилотные авто, дроны, роботы. Автономные ИИ-агенты

Участник глубинного интервью

“

Революция, которая сейчас происходит в ИИ-агентах, в большей степени связана с изменениями в архитектуре и сервисах, чем со значимым прорывом в агентности.

Чтобы стать настоящим ИИ-агентом, система должна уметь самостоятельно обучаться, взаимодействовать со средой, делать выводы и находить свои ошибки в реальном времени.

То есть ключевой критерий для ИИ-агента – это автономность. На данный момент он не достигнут в полной мере.

Эволюционный подход к определению ИИ-агентов

ИИ-агент – это программа или система, способная самостоятельно выполнять задачи, принимать решения и взаимодействовать с окружающей средой на основе искусственного интеллекта.

— Эволюция агентных систем



Источник: Сбер, Разработка и применение мультиагентных систем в корпоративной среде

Отсутствие надежного планирования у ИИ-агентов подтверждается результатами бенчмарков (PlanBench): при решении задач **сложного логического планирования** качество результата LLM **снижается на 50%-95%**.

На **горизонте 2-3 лет** ожидается реализация ключевых задач для повышения автономности работы ИИ-агента:

- Внедрение детальных подходов в части обучения с подкреплением
- Создание фундаментальных агентов
- Разработка мультиагентных архитектур

Источники: Stanford University Human-Centered Artificial Intelligence (HAI), The 2025 AI Index Report Subbarao Kambhampati, PlanBench: An Extensible Benchmark for Evaluating Large Language Models on Planning and Reasoning about Change, Альянс в сфере ИИ, Горизонты искусственного интеллекта: Какими будут технологии ИИ через 10 лет

ИИ-агенты: проблемы и риски

Сдерживающим фактором массового внедрения современных ИИ-агентов является **уровень безопасности и доверия**, которые объясняются следующими вызовами:

Вызовы

- **Отсутствие строгой формальной теории** (невозможность гарантировать безопасность без формализации устойчивости)
- **Выравнивание целей** (предотвращение генерации вредоносных или неэтичных результатов)
- **Объяснимость и прозрачность** (непонимание внутренней логики работы «черного ящика»)
- **Безопасная разработка и эксплуатация (MLSecOps)** (уязвимости в коде, данных и модели; новые угрозы для агентов)
- **Противодействие злоупотреблениям** (использование ИИ для взлома, дипфейков, дезинформации)

Ключевые исследовательские задачи

- Разработка методов снижения рисков от вредоносных данных и исследование фундаментальных математических границ **для гарантий безопасности**.
- Создание методов постфактум-объяснения сложных моделей, а также разработка **требований и протоколов тестирования систем на объяснимость**.
- Создание **инфраструктуры безопасной разработки**
- Разработка методов **обнаружения и защиты от дипфейков**, включая технологии цифровых водяных знаков.

Потенциальный эффект


- Переход от эмпирической безопасности к верифицируемой, создавая агентов с **доказуемыми границами безопасного поведения**
- Автономные агенты будут действовать в рамках заданных этических и социальных норм
- Визуализация принятия агентом решения
- **Защита от отравления наборов данных** и атак на модели, инструменты поиска уязвимостей в сторонних библиотеках
- Идентификация контента, созданного или модифицированного агентами, и **защита каналов коммуникации агентов** от подделки информации

Что значит доверять ИИ-агенту?

“

Доверенные технологии искусственного интеллекта –

технологии, отвечающие стандартам безопасности, разработанные с учетом принципов объективности, недискриминации, этичности, исключающие при их использовании возможность причинения вреда человеку и нарушения его основополагающих прав и свобод, нанесения ущерба интересам общества и государства.



Результаты исследования «Российский бизнес оценивает ИИ»



Технологии
Доверия



Применение ИИ в российском бизнесе носит фрагментарный характер и сосредоточено в области клиентского сервиса и HR. Причина – отсутствие инфраструктуры

1

Большинство кейсов применения генеративного ИИ на российском рынке связано с внедрением чат-ботов и голосовых помощников. Для прочих задач ИИ используется как co-pilot для поиска информации и генерации текста.

Фрагментарный характер применения связан с отсутствием ИТ-инфраструктуры и системных платформенных решений, необходимых для масштабного внедрения ИИ агентов повсеместно в широком круге процессов в российском бизнесе.

Участник глубинного интервью

“ ИИ-агенты хороши в тех задачах, где мы можем принять ошибки, которые они совершают. К таким задачам в первую очередь относятся поиск и анализ информации. ИИ-агенты подходят для сотрудника бэк-офиса как co-pilot.

1.1. В каких сферах деятельности компании используют ИИ?*, % от всех опрошенных



1.2. Для каких именно задач используют ИИ?*, в % от всех опрошенных



*Многовариантный вопрос, сумма ответов может быть не равна 100%.

Участник глубинного интервью

“ На практике бывает сложно провести грань между инвестициями в ИИ и инвестициями в инфраструктуру, которая позволяет разрабатывать ИИ. Инвестиции в определенные области ИТ будут оказывать значимый эффект на внедрение ИИ уже в 2026 году.



Бизнес не готов доверять ИИ-агентам выполнение задач без постоянного контроля

2

Несмотря на декларируемое доверие к системам ИИ и к ИИ-агентам, бизнес склонен **оставлять за собой контроль**.

Причина – в текущем уровне развития моделей, технологий и процессов:

- отсутствие платформенного подхода к разработке и внедрению ИИ и контрольной среды
- недостаточная точность LLM-моделей, склонность к галлюцинациям
- существенная зависимость результата работы ИИ-агента от качества данных и процессов. Отсутствие в компаниях доверенных источников данных и процессного подхода к управлению бизнесом
- накопление ошибок ИИ-агентами при реализации многошаговых процессов и прочие фундаментальные ограничения ИИ-агентов.


73%

в целом доверяют системам ИИ


44%

считают, что ИИ-агентам нужен постоянный контроль


2.1-2.3. Доверие и контроль ИИ, в % от всех опрошенных



2.1. В целом я доверяю системам ИИ, %



2.2. Я доверяю/смогу доверить ИИ-агентам выполнять задачи без постоянного контроля, %



2.3. ИИ способен принимать обоснованные решения без участия человека, %

■ Скорее согласны ■ Скорее не согласны ■ Затруднились ответить

Готовность к взаимодействию с ИИ-агентами во внешнем контуре ниже из-за юридических рисков


3

Бизнес склонен больше доверять ИИ-агентам, выполняющим задачи вместо сотрудников, но не партнеров по бизнесу или ИИ-агентов, заключающих сделки от имени клиентов.


3.1-3.4. Готовность взаимодействия с ИИ-агентами, в % от всех опрошенных




Я готов делегировать ИИ-сотруднику задачи с минимальным риском




Я готов делегировать ИИ-сотруднику задачи, связанные с конфиденциальной информацией



Я готов взаимодействовать с ИИ-агентом клиента в процессе переговоров



ИИ-агент, выполняющий функции партнёра, может принять решения в рамках заранее заданных условий



■ Скорее согласны

■ Скорее не согласны

■ Затруднились ответить

- Высокий уровень доверия при взаимодействии с ИИ-сотрудниками объясняется относительно распространенным применением ИИ при решении ad-hoc задач в режиме co-pilot.
- В случае работы с конфиденциальной информацией уровень ответственности повышается, поэтому снижается доверие.
- Доверие при взаимодействии с ИИ-агентами во внешнем контуре (ИИ-клиенты, ИИ-партнеры) на порядок ниже, по причине наличия юридических барьеров в части незакрепленного правового статуса ИИ-агентов.

Отсутствие инфраструктуры для разработки – важный фактор снижения доверия к ИИ-агентам

4

Отсутствие платформенных решений по разработке ИИ приводит к повышению существенности барьеров развития ИИ-агентов в части обеспечения безопасности, надежности и качества моделей.

Бизнес не может доверять конфиденциальные данные иностранным LLM моделям, а российские модели пока не внедрены на уровне платформенного решения.

Дополнительным фактором к повышению доверия к ИИ становится обучение сотрудников, проведение сертификации ИИ-агентов.

4.1. Барьеры при внедрении ИИ*, в % от всех опрошенных



4.2. Факторы повышения доверия к ИИ-агентам*, в % от всех опрошенных




Ключевые наблюдения

01 Создание инфраструктуры для разработки технологий ИИ становится **ключевым драйвером** роста доверия российского бизнеса к ИИ-агентам, влияющее также на безопасность и качество используемых моделей

02 Основные барьеры при внедрении ИИ-агентов касаются **рисков безопасности данных**, неопределенного **правового статуса** ИИ-агентов, отсутствия **контрольной среды** и высоких требований к **качеству фундаментальных LLM моделей**

03 Для масштабного внедрения ИИ-агентов в бизнес необходимо совершенствование **методов процессного управления** и **управления данными**

Рекомендации по дальнейшим шагам



внедрение платформенной инфраструктуры для работы с ИИ агентами, включая обеспечение требований информационной безопасности и создание контрольной среды вокруг ИИ-агентов



тестирование качества ИИ-агентов в конкретных бизнес-процессах и выставление требований к уровню обоснованности принимаемых решений со стороны бизнеса для последующего роста автономности



Повышение качества процессного управления и внедрение методов управления данными, включая создание базы метаданных



Наталья Стрекаль

Директор практики нефинансовых рисков и
данных для финансового сектора

+7 (905) 272-76-44
natalia.strekal@tedo.ru



**Технологии
Доверия**