


A man with a beard and bald head, wearing a black t-shirt and a smartwatch, is speaking into a microphone on a stage. The background is dark with blue and purple stage lights.

POR QUE 73% DOS PROJETOS DE IA FALHAM

(E COMO ESTAR NOS 27%)

AUTÓPSIA DE PROJETOS REAIS
+ FRAMEWORK À PROVA DE FALHA

A ESTATÍSTICA QUE NINGUÉM QUER ACEITAR

Vou começar com uma verdade inconveniente: a maioria dos projetos de IA falha.

Não estou falando de startups aventureiras ou experimentos de garagem. Estou falando de projetos corporativos, com budget, com equipe, com fornecedores experientes. Projetos que tinham tudo para dar certo.

E mesmo assim, falham.

**73% DOS PROJETOS DE IA CORPORATIVOS
NÃO ATINGEM OS OBJETIVOS DE NEGÓCIO.**

Esse número não é chute meu. É o resultado de pesquisas extensas com centenas de empresas, conduzidas por consultorias como Gartner, McKinsey e MIT Sloan.

A boa notícia? Os 27% que funcionam não são mágica. Não são sorte. São padrão.

São empresas que entenderam — na maioria das vezes depois de fracassar — o que realmente faz um projeto de IA dar certo. Nos últimos 5 anos, implementei mais de 100 projetos de IA em 16 setores diferentes. Vi projetos fracassarem. Vi projetos que todo mundo apostava contra darem certo. E documentei tudo.

ESTE E-BOOK É A DESTILAÇÃO DESSE APRENDIZADO. VOU TE MOSTRAR:

- Os dados reais sobre falha em projetos de IA (e por que são tão altos)
- Autópsias de projetos que falharam — o que aconteceu por dentro
- As diferenças sistemáticas entre projetos que funcionam e os que não funcionam
- Um framework prático para blindar seu projeto contra os erros mais comuns

Se você está planejando investir em IA — ou já investiu e está preocupado — este material pode salvar centenas de milhares de reais. Ou milhões.

OS NÚMEROS QUE O MERCADO ESCONDE

Antes de entender por que projetos falham, precisamos concordar sobre o tamanho do problema. Os números são piores do que a maioria imagina

O QUE AS PESQUISAS MOSTRAM

Compilei dados das principais pesquisas globais sobre implementação de IA em empresas:

FONTE	TAXA DE FALHA	ANO
Gartner	85%	2022
MIT Sloan / BCG	70%	2023
McKinsey Global Survey	74%	2023
Deloitte State of AI	78%	2022
RAND Corporation	80%	2024

A média? Aproximadamente 73-77% de falha. Isso significa que de cada 4 projetos de IA iniciados, apenas 1 entrega o valor prometido.

O QUE SIGNIFICA "FALHAR"?

É importante definir. Nas pesquisas, "falha" inclui projetos que:

- Nunca saíram do piloto para produção
- Foram para produção mas não atingiram os KPIs esperados
- Foram descontinuados por falta de ROI
- Custaram significativamente mais que o previsto sem entregar mais valor
- Demoraram tanto que perderam relevância estratégica
- Funcionam tecnicamente mas não foram adotados pelos usuários

Ou seja: não basta o modelo funcionar em laboratório. O projeto precisa entregar valor real de negócio.

POR SETOR: ONDE A FALHA É PIOR

As taxas de falha variam significativamente por indústria:

87% SAÚDE – REGULAMENTAÇÃO PESADA, DADOS SENSÍVEIS, RESISTÊNCIA CULTURAL

82% GOVERNO – BUROCRACIA, CICLOS LONGOS, MÚLTIPLOS STAKEHOLDERS

79% MANUFATURA – INTEGRAÇÃO COM SISTEMAS LEGADOS, DADOS NÃO ESTRUTURADOS

71% VAREJO – EXPECTATIVAS INFLADAS, DADOS FRAGMENTADOS

65% FINANCEIRO – MAIS MADURO, MAS ALTA COMPLEXIDADE REGULATÓRIA

58% TECH – MAIS EXPERIÊNCIA, MAS TAMBÉM MAIS EXPERIMENTAÇÃO ARRISCADA



INSIGHT: Se você está em saúde ou governo, as chances jogam ainda mais contra você. Não é motivo para desistir — é motivo para ser ainda mais rigoroso

O CUSTO INVISÍVEL DA FALHA

Quando um projeto de IA falha, o custo vai muito além do investimento direto:

- Custo direto: O que foi pago ao fornecedor, infraestrutura, equipe
- Custo de oportunidade: Outros projetos que não foram feitos
- Custo de tempo: Meses ou anos perdidos
- Custo político: Credibilidade da área de inovação queimada
- Custo cultural: "Tentamos IA e não funcionou" vira mantra

Esse último é o mais perigoso. Uma falha mal gerenciada pode atrasar a adoção de IA na empresa por anos.

O objetivo deste e-book é garantir que, se você for falhar, falhe rápido, barato e aprendendo — não devagar, caro e queimando pontes.



AUTÓPSIA: 7 PROJETOS QUE FALHARAM

Teoria é importante, mas nada ensina mais que analisar falhas reais. Vou compartilhar 7 casos que acompanhei de perto ou que foram documentados publicamente, com detalhes suficientes para você aprender sem expor as empresas desnecessariamente.

AUTÓPSIA: A previsão de demanda de R\$ 400 mil

Contexto: Rede de varejo com 50 lojas contratou sistema de IA para previsão de demanda.

Promessa: reduzir estoque parado em 30% e rupturas em 25%. Budget: R\$ 400 mil.

O que deu errado: O fornecedor treinou o modelo com dados históricos de vendas, mas ignorou três fatores críticos: sazonalidade regional (lojas no Nordeste vs Sul têm padrões completamente diferentes), promoções (que distorciam os dados históricos), e o fato de que 40% dos SKUs tinham menos de 6 meses de histórico. O modelo funcionava bem no backtest, mas em produção errava sistematicamente.

Resultado: Após 8 meses, o sistema foi desligado. Estoque parado aumentou 12% no período de teste. Custo total com correções e adaptações: R\$ 580 mil.

✓**Lição:** Dados históricos não são suficientes. É preciso entender o contexto de negócio que gerou aqueles dados. Modelo que não considera promoções, sazonalidade e mix de produtos está fadado a falhar no varejo

AUTÓPSIA: O chatbot que ninguém usava

Contexto: Empresa de telecom implementou chatbot de atendimento com IA generativa. Meta: reduzir 40% do volume do call center. Investimento: R\$ 250 mil.

O que deu errado: O chatbot foi desenvolvido em 4 meses e tecnicamente funcionava bem — respondia perguntas com 85% de precisão. Mas foi lançado sem considerar que: (1) o público da empresa era majoritariamente 50+, menos confortável com chat; (2) as perguntas mais frequentes exigiam acesso a sistemas legados que não foram integrados; (3) não havia fallback claro para atendente humano quando o bot não resolvia.

Resultado: Após 18 meses (prazo original: 8), o sistema conseguia prever apenas 2 dos 7 tipos de falha crítica. ROI projetado: 300%. ROI real: 40%. Projeto considerado "parcialmente bem-sucedido" para salvar a face.

✓**Lição:** IA de atendimento não é só sobre o modelo. É sobre a jornada do cliente. Se o bot não resolve E não transfere bem, você está piorando a experiência, não melhorando.

AUTÓPSIA: A manutenção preditiva que nunca previu

Contexto: Indústria de papel e celulose investiu R\$ 1,2 milhão em sistema de manutenção preditiva com IA. Objetivo: prever falhas em equipamentos críticos com 48h de antecedência

O que deu errado: O projeto começou sem um inventário claro dos sensores existentes. Descobriram no mês 3 que 60% das máquinas críticas não tinham sensores adequados. Instalação de novos sensores adicionou R\$ 300 mil e 6 meses ao projeto. Quando finalmente tinham dados, perceberam que a maioria das falhas históricas não tinha sido registrada corretamente — a manutenção anotava "problema elétrico" sem especificar qual.

Resultado: Adoção de 8% após 6 meses. Call center não reduziu — aumentou, porque clientes frustrados ligavam depois de tentar o bot. Projeto descontinuado.

✓**Lição:** IA de manutenção preditiva exige dados de falha de qualidade. Se a manutenção não registra falhas corretamente há anos, não existe mágica que compense. O projeto deveria ter começado pela qualidade dos dados, não pelo modelo.

AUTÓPSIA: O RH automatizado que gerou processo

Contexto: Empresa de tecnologia implementou IA para triagem automática de currículos. Promessa: reduzir tempo de triagem de 2 semanas para 2 dias. Investimento: R\$ 180 mil.

O que deu errado: O modelo foi treinado com dados históricos de contratações bem-sucedidas. Problema: o histórico refletia vieses da empresa — 80% dos contratados eram homens, de universidades específicas, de uma faixa etária. O modelo aprendeu esses padrões e passou a eliminar sistematicamente mulheres, pessoas de outras universidades e candidatos mais velhos.

Resultado: Uma candidata rejeitada identificou o padrão e processou a empresa por discriminação. Acordo judicial: R\$ 150 mil + compromisso público de revisão de práticas. Dano reputacional: inestimável. Sistema desligado.

✓**Lição:** IA reflete os vieses dos dados com que foi treinada. Em processos que afetam pessoas (RH, crédito, saúde), auditoria de viés não é opcional — é obrigatória. E precisa ser contínua, não pontual.

AUTÓPSIA: A personalização que despersonalizou

Contexto: Contexto: E-commerce de moda investiu R\$ 300 mil em sistema de recomendação com IA. Meta: aumentar ticket médio em 15% com recomendações personalizadas.

O que deu errado: O sistema foi treinado para maximizar probabilidade de clique, não de compra. Resultado: recomendava produtos baratos com alta taxa de clique, mas baixa margem. Além disso, a "personalização" era tão agressiva que clientes começaram a reclamar que só viam os mesmos tipos de produto – a IA criou uma bolha que limitava a descoberta.

Resultado: Ticket médio caiu 8% no grupo de teste. Reclamações de clientes subiram 25%. Taxa de recompra caiu 12%. Sistema revertido para recomendação baseada em regras simples.

✓**Lição:** A métrica que você otimiza é a métrica que você vai ter. Se otimiza cliques, vai ter cliques – não necessariamente vendas ou satisfação. Definir a métrica certa é tão importante quanto o modelo.

AUTÓPSIA: O projeto de 3 meses que durou 14

Contexto: Seguradora contratou automação de análise de sinistros com IA. Proposta: 3 meses de implementação, R\$ 500 mil de investimento, economia de R\$ 200 mil/mês.

O que deu errado: O fornecedor subestimou (ou omitiu) a complexidade de integração com o sistema legado de 15 anos. Cada sprint descobria uma nova dependência. A documentação do sistema legado estava desatualizada. O time interno que conhecia o sistema tinha apenas 2 pessoas, ambas sobrecarregadas com outras demandas.

Resultado: Projeto entregue em 14 meses. Custo final: R\$ 1,1 milhão. Economia mensal real: R\$ 80 mil (não R\$ 200 mil). Payback mudou de 2,5 meses para 14 meses.

✓**Lição:** Integração com sistemas legados é onde projetos de IA morrem. Se o fornecedor não dedicar tempo real para entender seu ambiente antes de propor prazo e preço, os números são fantasia.

AUTÓPSIA: A IA que ninguém queria usar

Contexto: Escritório de advocacia implementou IA para revisão de contratos. Tecnicamente excelente: 95% de precisão na identificação de cláusulas de risco. Investimento: R\$ 400 mil.

O que deu errado: O projeto foi liderado pela área de inovação, sem envolvimento real dos advogados que usariam a ferramenta. Quando lançado, os advogados resistiram: "Não vou confiar em máquina para algo que pode me dar problema de responsabilidade". A ferramenta exigia mudança de workflow que ninguém explicou ou treinou adequadamente. O parceiro sênior nunca usou, então os associados também não usavam.

Resultado: Após 12 meses, taxa de uso: 12%. Ferramenta processava 50 contratos/mês quando a meta era 500. ROI: negativo.

✓**Lição:** Tecnologia que funciona mas ninguém usa não entrega valor. Change management não é opcional em projetos de IA – é pré-requisito. E o patrocínio precisa vir de quem realmente vai usar, não só de quem aprova o budget.



INSIGHT: EM 6 DOS 7 CASOS, O PROBLEMA NÃO FOI TECNOLÓGICO. FOI DE NEGÓCIO: DADOS RUINS, MÉTRICA ERRADA, FALTA DE ADOÇÃO, INTEGRAÇÃO SUBESTIMADA. A TECNOLOGIA ERA A PARTE FÁCIL.

O QUE SEPARA OS 27% DOS 73%

Depois de analisar dezenas de projetos, os padrões ficam claros. As diferenças entre projetos que funcionam e os que falham não são sutis — são sistemáticas.

COMPARAÇÃO DIRETA: FALHA VS SUCESSO

ASPECTO	PROJETOS QUE FALHAM	PROJETOS QUE FUNCIONAM
Origem	Começa pela tecnologia: "Vamos usar IA"	Começa pelo problema: "Precisamos resolver X"
Sponsor	Área de inovação/TI isolada	Dono do processo de negócio envolvido
Escopo inicial	Ambicioso: transformar tudo	Focado: resolver um problema específico
Dados	"Temos muitos dados" (sem validar qualidade)	Auditoria de dados antes de começar
Métrica	Vaga: "melhorar eficiência"	Específica: "reduzir X de Y para Z"
Timeline	Agressivo: "precisa ser rápido"	Realista: inclui descoberta e interação
Equipe interna	Terceiriza tudo para fornecedor	Capacita time interno para sustentar
Change mgmt	"Depois a gente treina"	Plano de adoção desde o dia 1
Expectativa	ROI no primeiro ano	Aprendizado no ano 1, ROI no ano 2
Piloto	Pula direto para escala	POC → Piloto → Escala gradual
Falha	Vista como fracasso a esconder	Vista como aprendizado a documentar

OS 5 PADRÕES DE SUCESSO

PADRÃO 1: Problema antes de solução

Projetos bem-sucedidos começam com um problema de negócio real e doloroso, não com vontade de usar tecnologia. A pergunta não é "onde podemos usar IA?" mas "qual problema vale a pena resolver e IA pode ajudar?"
Teste rápido: Se você remover a palavra "IA" do projeto, ele ainda faz sentido? Se a resposta for não, o projeto está começando pelo lado errado.

PADRÃO 2: Dados validados antes de modelo

Projetos que funcionam dedicam 30-40% do tempo inicial só para entender e preparar dados. Não assumem que "temos muitos dados" significa "temos dados úteis". Fazem perguntas como:

- Os dados existem? Estão acessíveis? Em que formato?
- Qual a qualidade? Completude? Consistência?
- Os dados refletem o que queremos prever/classificar/otimizar?
- Existem vieses históricos que o modelo vai aprender?

PADRÃO 3: Patrocínio de quem usa, não só de quem paga

O CFO pode aprovar o budget, mas se o gerente de operações que vai usar o sistema não estiver envolvido e comprometido, a adoção não vai acontecer. Projetos bem-sucedidos têm:

- Sponsor executivo com poder de decisão
- Product owner do lado do negócio dedicado
- Usuários finais envolvidos desde a especificação
- Change management como workstream, não afterthought

PADRÃO 4: Escala progressiva com pontos de saída

Projetos bem-sucedidos não apostam tudo de uma vez. Seguem progressão:

- **POC (2-4 semanas):** Validar que o problema é solucionável com IA
- **Piloto (2-3 meses):** Testar em ambiente controlado com usuários reais
- **Escala (3-6 meses):** Expandir gradualmente, aprendendo com cada fase

Cada fase tem critérios claros de go/no-go. Se a POC não funcionar, você perdeu semanas, não anos.

PADRÃO 5: Mentalidade de produto, não de projeto

Projetos tradicionais têm começo, meio e fim. IA é diferente. Modelos precisam de manutenção contínua, retreinamento, monitoramento. Dados mudam. Comportamentos mudam.

Projetos bem-sucedidos tratam a solução de IA como produto que precisa ser sustentado, não como projeto que termina na entrega. Isso significa budget operacional, não só CAPEX de implementação.

CASE DE SUCESSO: A AUTOMAÇÃO QUE ECONOMIZA R\$ 2M/ANO

Contexto: Distribuidora de medicamentos queria automatizar a classificação de pedidos de reembolso. Volume: 50.000 pedidos/mês. Processo manual: 3 dias em média.

O que funcionou: Começaram pequeno: um tipo de pedido (devolução por avaria), que representava 15% do volume mas 40% do tempo. Fizeram POC de 3 semanas só com esse tipo. Funcionou. Expandiram para segundo tipo. Depois terceiro. Levaram 8 meses para cobrir 100% dos tipos, mas cada expansão foi validada antes de avançar.

Resultado: Tempo de processamento: de 3 dias para 4 horas. Economia: R\$ 2,1 milhões/ano. Taxa de erro: caiu de 8% para 1,2%. Equipe realocada para atividades de maior valor.



INSIGHT: A DIFERENÇA ENTRE OS 27% E OS 73% NÃO É SORTE OU TECNOLOGIA SUPERIOR. É DISCIPLINA, REALISMO E FOCO OBSESSIVO EM VALOR DE NEGÓCIO.

FRAMEWORK: PROJETO À PROVA DE FALHA

Baseado nos padrões de sucesso e nas autópsias de fracasso, desenvolvi um framework prático que uso em todos os projetos. São 7 passos que maximizam as chances de estar nos 27%.

O FRAMEWORK F.A.I.L.S.A.F.E.

PASSO F: FOCUS — Defina o problema com precisão cirúrgica

Antes de qualquer coisa: qual problema específico de negócio você está resolvendo? Não "melhorar atendimento" — mas "reduzir tempo de primeira resposta de 4h para 30min para tickets de prioridade alta". Quanto mais específico, melhor. Se você não consegue medir o problema hoje, não vai conseguir medir a melhoria amanhã.

- **Exercício:** Complete a frase "Saberemos que o projeto foi bem-sucedido quando _____ mudar de _____ para _____".
- Se não conseguir completar, você não tem problema definido — tem desejo vago.

PASSO A: AUDIT — Audite seus dados antes de sonhar

Antes de escolher fornecedor ou tecnologia, faça uma auditoria honesta dos dados disponíveis. Responda: Os dados existem? Estão acessíveis? Qual a qualidade? Existem vieses? Quanto esforço para preparar?

- **Regra de ouro:** Se a auditoria de dados revelar problemas sérios, o projeto deveria ser de qualidade de dados, não de IA.
- 80% do esforço de IA bem-sucedida está nos dados. Modelo é commodity.

PASSO I: INVOLVE — Envolver quem vai usar desde o dia 1

Identifique os stakeholders reais: quem vai usar a solução no dia a dia? Quem precisa mudar comportamento? Quem pode sabotar (consciente ou inconscientemente)? Envolver essas pessoas desde a definição, não só no treinamento final.

- Crie um "comitê de usuários" que participa de decisões de design.
- Os maiores céticos, se convencidos, viram os maiores defensores.

PASSO L: LIMIT — Limite o escopo inicial ao mínimo viável

Resista à tentação de fazer tudo de uma vez. Identifique o menor escopo possível que ainda entrega valor e prova a tese. É melhor ter um caso de uso funcionando bem do que dez funcionando mal.

- **Pergunte:** Qual é a versão mais simples deste projeto que ainda valida se IA pode resolver o problema?
- Se essa versão simples não funcionar, a complexa também não vai.

PASSO S: STAGE — Estruture em fases com gates de decisão

Divida o projeto em fases com critérios claros de sucesso. Cada fase é uma oportunidade de aprender, ajustar ou parar. Não trate as fases como formalidade — trate como decisões reais de continuar ou não.

Estrutura recomendada:

- **Fase 0 — Discovery (2-4 semanas):** Entender o problema, auditar dados, definir métricas
- **Fase 1 — POC (3-6 semanas):** Provar que é tecnicamente viável
- **Fase 2 — Piloto (2-3 meses):** Testar com usuários reais em ambiente controlado
- **Fase 3 — Escala (3-6 meses):** Expandir gradualmente com monitoramento
- **Fase 4 — Operação:** Manutenção, retreinamento, evolução contínua

PASSO A: ALIGN — Alinhe expectativas obsessivamente

Desalinhamento de expectativas mata mais projetos que tecnologia ruim. Alinhe com todos os stakeholders: O que é sucesso? Em quanto tempo? Com que investimento? Quais os riscos? O que acontece se não funcionar?

- Documente as expectativas por escrito. Revisem mensalmente.
- Expectativas irrealistas precisam ser corrigidas cedo, não descobertas tarde.

PASSO F: FALLBACK — Planeje o plano B

Todo projeto de IA deveria ter um plano B claro: se não funcionar, o que fazemos? Isso não é pessimismo — é prudência. O plano B reduz a pressão de "tem que funcionar" e permite decisões mais racionais.

- **Pergunte:** Se a IA não performar, como resolvemos o problema de outra forma?
- Às vezes, processo otimizado + regras simples resolve 80% do problema sem IA.

PASSO E: EVOLVE — Projete para evolução, não para entrega

O projeto de IA não termina no go-live. Modelos degradam. Dados mudam. Negócio evolui. Projete desde o início para sustentação de longo prazo.

- Quem vai monitorar performance em produção?
- Qual o processo de retreinamento? Com que frequência?
- Como novas necessidades serão incorporadas?
- Qual o budget operacional (não só de implementação)?



INSIGHT: USE ESTE FRAMEWORK COMO CHECKLIST EM CADA FASE DO PROJETO. SE VOCÊ NÃO CONSEGUIR RESPONDER BEM ÀS PERGUNTAS DE CADA PASSO, É SINAL DE QUE PRECISA TRABALHAR MAIS ANTES DE AVANÇAR.

CHECKLIST: ANTES, DURANTE E DEPOIS

Para facilitar a aplicação do framework, compilei checklists práticos para cada fase do projeto.

ANTES DE COMEÇAR (GATE 0)

CRITÉRIO	CHECK
Problema de negócio específico e mensurável definido	☐
Métrica de sucesso quantificada (de X para Y)	☐
Auditoria de dados realizada (qualidade, acesso, vieses)	☐
Sponsor executivo identificado e comprometido	☐
Usuários finais envolvidos na definição	☐
Escopo mínimo viável identificado	☐
Plano B definido se IA não funcionar	☐
Budget realista para POC, piloto E escala	☐
Expectativas alinhadas e documentadas com stakeholders	☐
Critérios de go/no-go para cada fase definidos	☐

Se mais de 2 itens estão sem check, você não está pronto para começar.

DURANTE A POC (GATE 1)

CRITÉRIO PARA AVANÇAR AO PILOTO	CHECK
Modelo atinge métrica mínima de performance técnica	☐
Dados de produção foram usados (não só dados limpos de teste)	☐
Limitações conhecidas estão documentadas	☐
Stakeholders viram demonstração e aprovaram	☐
Estimativa de esforço para piloto é realista	☐
Riscos de integração foram mapeados	☐
Plano de adoção/change management existe	☐

DURANTE O PILOTO (GATE 2)

CRITÉRIO

CHECK

Performance em produção confirma resultados da POC	☐
Usuários reais estão usando (não só testando)	☐
Feedback de usuários é positivo ou problemas são solucionáveis	☐
Integrações funcionam de forma estável	☐
Não há red flags de segurança ou compliance	☐
ROI projetado ainda faz sentido com dados reais	☐
Equipe interna tem capacidade de sustentar	☐
Plano de escala é claro e financiado	☐

EM OPERAÇÃO (CONTÍNUO)

MONITORAMENTO CONTÍNUO

FREQUÊNCIA

Métricas de performance do modelo estão estáveis	Diário
Taxa de adoção por usuários	Semanal
Feedback qualitativo de usuários	Semanal
Revisão de casos de erro/exceção	Semanal
Verificação de data drift	Mensal
Auditoria de viés (se aplicável)	Mensal
Avaliação de necessidade de retreinamento	Trimestral
Revisão de ROI realizado vs projetado	Trimestral