



UNIVERSIDADE FEDERAL DE OURO PRETO
ESCOLA DE MINAS
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO



JULIA PEREIRA BONILHO

LIMITES E POTENCIALIDADES DA IMPLEMENTAÇÃO DE SOLUÇÕES
BASEADAS EM IA: UM CASO NO SETOR DE PROCESSAMENTO
DOCUMENTAL

OURO PRETO - MG

2026

Julia Pereira Bonilho

**LIMITES E POTENCIALIDADES DA IMPLEMENTAÇÃO DE SOLUÇÕES
BASEADAS EM IA: UM CASO NO SETOR DE PROCESSAMENTO
DOCUMENTAL**

Monografia apresentada ao Curso de Graduação
em Engenharia de Produção da Universidade
Federal de Ouro Preto como requisito parcial para
a obtenção do título de Engenheiro de Produção.

Orientador: Dr. Yã Grossi Andrade

OURO PRETO – MG

2026



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE OURO PRETO
REITORIA
ESCOLA DE MINAS
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO,
ADMINISTRAÇÃO E ECON



FOLHA DE APROVAÇÃO

Julia Pereira Bonilho

Limites e potencialidades da implementação de soluções baseadas em IA: um caso no setor de processamento documental

Monografia apresentada ao Curso de Engenharia de Produção da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Engenharia de Produção.

Aprovada em 26 de fevereiro de 2026

Membros da banca

Dr. Yã Grossi Andrade - Orientador(a) - Universidade Federal de Ouro Preto
Dr. Aloisio De Castro Gomes Junior - Universidade Federal de Ouro Preto
Dra. Tays Torres Ribeiro Das Chagas - Universidade Federal de Ouro Preto

Yã Grossi Andrade, orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 26/02/2026



Documento assinado eletronicamente por **Yã Grossi Andrade, PROFESSOR DE MAGISTERIO SUPERIOR**, em 26/02/2026, às 11:25, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **1065491** e o código CRC **C521DFA0**.

Gosto de pensar que somos construções feitas de todas as
pessoas que passaram por nossas vidas. E que a sorte a minha
ter dividido essa jornada com pessoas tão especiais.

AGRADECIMENTOS

Agradeço a Deus e aos meus guias, que me protegem e renovam minha força a cada passo.

À minha mãe, Ana, mulher guerreira que sempre colocou meus sonhos acima de tudo. Ao meu pai, Renato Jr, que, sob muito sol, trilhou a sombra em que pude caminhar. Ao meu avô, Renato, que cuidou de mim com o coração inteiro e nunca soltou minha mão. Aos meus padrinhos, Reinaldo e Renata, por me acolherem em todas as fases da vida e serem pilares inabaláveis. Aos meus tios, Eduardo e Fernanda, por mostrarem que os laços de família se constroem com cuidado e presença. E aos meus primos, Guilherme e Murilo, por me lembrarem, sempre, da leveza da infância.

Ao Caio, meu amor, companheiro e melhor amigo, agradeço pela parceria de sempre e, em especial, pelo apoio paciente e constante durante a construção deste TCC, pela escuta, pelos incentivos nos momentos de dúvida e por tornar o processo mais leve.

Ao meu orientador, Prof. Dr. Yã Grossi, agradeço por me acompanhar ao longo de toda a graduação, com generosidade, seriedade e incentivo constante. Sua orientação foi essencial não apenas para a construção deste TCC, mas para a minha formação como um todo, pela confiança depositada em mim, pelas conversas que ampliaram minha forma de pensar e pelo cuidado em conduzir cada etapa com rigor acadêmico e humanidade.

À Escola de Minas, à Universidade Federal de Ouro Preto e ao DEPRO, pelo ensino público e de qualidade que sustentou minha formação e por todas as oportunidades que fortaleceram minha escolha pela engenharia. Estendo meu reconhecimento a todos os professores e funcionários que, com dedicação e compromisso, contribuíram para minha construção acadêmica e profissional. Um agradecimento especial à professora Prof. Dra. Tays Torres, pelo acompanhamento ao longo de diversos projetos e pela influência marcante na forma como passei a enxergar a engenharia. Sua orientação me incentivou a ir além do óbvio, a pensar com mais criticidade e a compreender a profissão com maior responsabilidade e sensibilidade.

À Fundação Gorceix, pelo incentivo constante à excelência acadêmica.

À ASA, pela parceria e pelos saberes compartilhados.

À Dory, à MP3 e ao Vilharba, pela amizade e por me ensinarem, na prática, o significado de irmandade.

E, por fim, à República Namoradeiras, meu lar, onde aprendi que família também se constrói nas escolhas feitas pelo caminho.

“A verdadeira questão não é se as máquinas pensam, e sim se os homens pensam. O mistério que cerca uma máquina pensante já cerca o homem pensante”.

(B. F. Skinner)

RESUMO

Embora a adoção de IA seja frequentemente justificada pela promessa de ganhos de eficiência e previsibilidade, parte dos limites observados na prática decorre do fato de que o desempenho não se estabiliza apenas por capacidade técnica, mas pelas escolhas organizacionais que definem como pessoas, tarefas e sistemas inteligentes passam a operar em conjunto. Diante desse problema, este estudo investiga, por meio de um estudo de caso, como escolhas de desenho operacional e governança condicionam a estabilização do desempenho e a sustentabilidade de ganhos na adoção de IA, tomando como eixo interpretativo a tensão entre automação e aprimoramento do trabalho humano, entendidos como formas distintas de organizar a interação contínua entre humanos e tecnologia (Raisch; Krakowski, 2021). A pesquisa é qualitativa e aplicada, delineada como estudo de caso único, com base em documentos institucionais e registros internos do projeto, complementados por entrevistas exploratórias com participantes da operação e da implementação, de modo a reconstituir critérios de validação, decisões por fase e ajustes executados. Os achados indicam que expectativas de automação plena e imediata tendem a ampliar fricções e desalinhamentos entre desempenho esperado e desempenho observado, sobretudo quando a variabilidade documental e a pressão de prazo intensificam erros percebidos e ciclos de retrabalho. Em contraste, a estabilização se mostrou viável quando a IA passou a operar como mecanismo de aprimoramento incremental, com revisão humana estruturada por exceções, rastreabilidade e retroalimentação contínua, deslocando o esforço humano para casos ambíguos e decisões de maior responsabilidade organizacional. No recorte estabilizado, observou-se redução de 50% no tempo médio de processamento, conclusão de 91% das ordens em até cinco minutos e acurácia global de 99%. Conclui-se que a integração efetiva da IA depende menos da promessa de automação total e mais da capacidade organizacional de governar limites, produzir confiança e sustentar ciclos curtos de aprendizagem no trabalho real, de forma que a automação robusta emerge como consequência de um regime de aprimoramento continuamente operado.

Palavras-chave: Inteligência Artificial; gestão humano-IA; gestão de processos documentais; automação.

ABSTRACT

Although AI adoption is often justified by the promise of efficiency and predictability gains, some of the limitations observed in practice stem from the fact that performance does not stabilize solely due to technical capability, but rather due to organizational choices that shape how people, tasks, and intelligent systems operate together. In response to this problem, this study investigates, through a case study, how operational design and governance choices condition performance stabilization and the sustainability of gains in AI adoption, using as an interpretive lens the tension between automation and augmentation of human work, understood as distinct ways of organizing continuous interaction between humans and technology (Raisch; Krakowski, 2021). The research is qualitative and applied, designed as a single case study, based on institutional documents and internal project records, complemented by exploratory interview with participants involved in operations and implementation, in order to reconstruct validation criteria, phase-level decisions, and executed adjustments. The findings indicate that expectations of full and immediate automation tend to increase frictions and misalignments between expected and observed performance, especially when document variability and time pressure intensify perceived errors and rework cycles. By contrast, stabilization proved feasible when AI operated as a mechanism for incremental augmentation, with human review structured through exceptions, traceability, and continuous feedback, shifting human effort toward ambiguous cases and decisions with higher organizational responsibility. In the stabilized scope, a 50% reduction in average processing time was observed, with 91% of orders completed within five minutes and an overall accuracy of 99%. The study concludes that effective AI integration depends less on the promise of total automation and more on the organizational capability to govern boundaries, build trust, and sustain short learning cycles in real work, such that robust automation emerges as a consequence of a continuously operated augmentation regime.

Keywords: Artificial Intelligence; human–AI management; documentary process management; automation.

LISTA DE FIGURAS

Figura 1 – Fluxograma sintético do processo analisado.....	27
Figura 2 – Matriz do dilema sociotécnico: volume de pedidos versus ambiguidade da decisão no processo analisado	29
Figura 3 – Fase 5.1: pré-implementação do sistema de IA e definição do modelo por exceções	32
Figura 4 – Fase 5.2: piloto do sistema de IA e calibração inicial de regras	35
Figura 5 – Fase 5.3: operação do sistema de IA com revisão humana e governança de exceções	37
Figura 6 – Fase 5.4: pivô de escopo e ampliação controlada do sistema de IA	38
Figura 7 - Síntese da trajetória de implementação do sistema de IA (Fases 5.1 a 5.4)	42

LISTA DE TABELAS

Tabela 1 - Síntese das etapas de implementação e do tratamento dos dois desafios	31
Tabela 2 - Síntese dos indicadores de desempenho no recorte estabilizado do processo.....	41

SUMÁRIO

1	INTRODUÇÃO	12
1.1	OBJETIVOS	13
1.1.1	Objetivo geral	13
1.1.2	Objetivos específicos	13
2	REFERENCIAL TEÓRICO	14
2.1	Inteligência Artificial: conceitos e panorama contemporâneo	14
2.2	Inteligência Artificial como solução corporativa: aplicações e benefícios.....	16
2.3	Barreiras e limitações do uso corporativo da Inteligência Artificial	18
2.4	Centralidade da colaboração humano-IA: o dilema entre automação e aprimoramento.....	20
3	METODOLOGIA	24
4	ESTUDO DE CASO.....	26
4.1	Caracterização da empresa.....	26
4.2	Descrição do processo analisado	26
4.3	Descrição do problema	28
4.4	Estrutura de implementação e modo de trabalho	29
5	RESULTADOS E DISCUSSÃO	32
5.1	Pré-implementação: delimitação do problema, preparação do sistema e arranjo de trabalho	32
5.1.1	Preparação técnica do sistema e do fluxo de validação	32
5.1.2	Preparação organizacional e governança do projeto	33
5.1.3	Desafios iniciais e encaminhamentos	34
5.2	Implementação e piloto: ciclos curtos, validação com usuários e correções orientadas pelo uso real.....	34
5.2.1	Execução técnica do piloto e funcionamento prático das exceções	35
5.2.2	Dimensão organizacional: recepção do sistema e qualidade do feedback	35
5.2.3	Principais desafios e soluções adotadas durante o piloto	36
5.3	Estabilização em produção: revisão humana, disciplina de medição e previsibilidade do fluxo	36
5.3.1	Operação com revisão humana e trilha auditável	37
5.3.2	Resultados intermediários e validação por indicadores operacionais	37

5.4	Ajuste de escopo e ampliação: pivô guiado por evidências e expansão com controle de risco	38
5.4.1	Evidências que motivaram o pivô e reorientação do recorte inicial.....	38
5.4.2	Ampliação progressiva e automação avançada em piloto controlado	39
5.5	Discussão integrativa: da automação ao aprimoramento na trajetória de implementação.....	39
6	CONSIDERAÇÕES FINAIS	43
	REFERÊNCIAS BIBLIOGRÁFICAS	46

1 INTRODUÇÃO

A difusão recente de aplicações corporativas de Inteligência Artificial, em especial aquelas voltadas ao processamento de linguagem natural e ao tratamento de documentos não estruturados, vem sendo acompanhada pela expectativa de ganhos de eficiência, redução de retrabalho e maior previsibilidade operacional. A literatura, contudo, tem ressaltado que os resultados organizacionais não decorrem exclusivamente da capacidade técnica do sistema, mas do modo como a tecnologia é incorporada ao processo de trabalho, às rotinas decisórias e às estruturas de governança que sustentam a operação, sobretudo quando há variabilidade de entrada, pressão temporal e risco operacional elevado (Davenport; Kirby, 2016; Daugherty; Wilson, 2018). Em termos conceituais, esse enquadramento se conecta ao dilema entre automação e aprimoramento, uma vez que a adoção de IA pode ser orientada tanto à transferência de tarefas para a máquina quanto à reorganização do trabalho em interação contínua com o sistema. Raisch e Krakowski (2021) sintetizam essa distinção ao registrarem que “enquanto a automação implica que as máquinas assumem uma tarefa humana, o aprimoramento significa que humanos colaboram estreitamente com máquinas para realizar uma tarefa” (Raisch; Krakowski, 2021, p. 2, tradução nossa).¹

É nessa problemática que se insere o estudo de caso desenvolvido neste trabalho, que acompanha a implementação de um sistema de IA aplicado ao processamento e validação de documentos em um fluxo corporativo sensível a picos, prazos e retrabalho. Além do desenho operacional, a literatura também aponta que confiança e aceitação organizacional condicionam a qualidade do uso, a consistência do *feedback* e, por consequência, a própria evolução do desempenho ao longo do tempo, enquanto revisões sobre aceitação de IA sistematizam que a disposição de indivíduos e grupos para utilizar essas tecnologias é influenciada por fatores psicossociais, normas, percepções de utilidade e facilidade de uso, além de elementos contextuais que atravessam níveis individuais e organizacionais (Kelly; Kaye, 2023).

Dessa forma, este trabalho se justifica por contribuir para a compreensão aplicada de como escolhas de governança, desenho de processo e gestão da interação humano-IA explicam a passagem de uma promessa de automação para um arranjo de aprimoramento que sustenta previsibilidade e controle. Ao situar os resultados do estudo de caso no debate entre automação e aprimoramento, busca-se oferecer uma leitura crítica e realista da implementação de IA em

¹ “Whereas automation implies that machines take over a human task, augmentation means that humans collaborate closely with machines to perform a task”.

processos corporativos, com implicações para escalonamento, estabilidade e sustentabilidade de ganhos.

1.1 OBJETIVOS

1.1.1 Objetivo geral

No contexto de processos com alta variabilidade documental, o objetivo geral é compreender os limites e as potencialidades da implementação de soluções baseadas em IA, de modo a equilibrar a automação seletiva e o aprimoramento incremental.

1.1.2 Objetivos específicos

Como objetivos específicos, pretende-se:

- Descrever o funcionamento do fluxo antes e depois da implementação, explicitando pontos de decisão, lógica de validação e natureza das exceções;
- Reconstruir a trajetória de implementação do sistema de IA, mapeando as fases de Pré-Implementação, Piloto, Produção com Revisão Humana e Pivô e Ampliação, e em cada etapa identificar o diagnóstico do processo, as decisões de desenho, a relevância da fase para o desempenho, as implementações realizadas e os efeitos observados;
- Analisar os impactos operacionais reportados no estudo, com foco na eficiência proporcionada pela redução do tempo médio de processamento, na fluidez do fluxo de trabalho e na acurácia global.

2 REFERENCIAL TEÓRICO

2.1 Inteligência Artificial: conceitos e panorama contemporâneo

O termo Inteligência Artificial (IA) foi introduzido formalmente por John McCarthy em 1955, no contexto da *Dartmouth Summer Research Project on Artificial Intelligence*, realizada em 1956, iniciativa que marcou a consolidação da área enquanto campo científico autônomo (McCarthy *et al.*, 1955, p. 1). Na proposta original do projeto, McCarthy e seus colaboradores afirmavam que “todo aspecto da aprendizagem, ou qualquer outra característica da inteligência, pode, em princípio, ser descrito com tanta precisão que uma máquina possa ser construída para simulá-lo” (McCarthy *et al.*, 1955, p. 2, tradução nossa).² Essa formulação inicial revela que a inteligência artificial, desde sua origem, foi concebida como um esforço abrangente de modelagem computacional de capacidades cognitivas, e não como um conjunto restrito de aplicações específicas.

No debate contemporâneo, a delimitação conceitual da inteligência artificial tem sido objeto de esforços institucionais e acadêmicos no sentido de conferir maior precisão analítica ao termo. Conforme o *Explanatory Memorandum on the Updated OECD Definition of an AI System*, um sistema de IA é caracterizado por sua capacidade de inferir, a partir de entradas, saídas que podem influenciar ambientes físicos ou virtuais, deslocando a discussão da IA como um rótulo genérico para a noção operacional de sistemas dotados de funções específicas (OECD, 2024, p. 4). O memorando (OECD, 2024, p. 4, tradução nossa), explicita que “um sistema de IA é um sistema baseado em máquina que pode, para um determinado conjunto de objetivos definidos por humanos, fazer previsões, recomendações ou tomar decisões que influenciam ambientes reais ou virtuais”.³

Na formulação adotada pela OCDE (2024, p. 4), a inferência é apresentada como elemento central para a caracterização dos sistemas de IA, associada às categorias de saídas produzidas, como predições, recomendações, conteúdos ou decisões, bem como ao potencial dessas saídas de afetar o ambiente no qual o sistema está inserido. O documento ressalta ainda que os sistemas de IA variam significativamente quanto aos níveis de autonomia e adaptabilidade após a implantação, o que reforça a necessidade de compreender a IA no âmbito de sistemas específicos, e não como uma tecnologia homogênea ou monolítica.

² “every aspect of learning or any other feature of intelligence can in principle be so precisely described that a machine can be made to simulate it”.

³ “an AI system is a machine-based system that can, for a given set of human-defined objectives, make predictions, recommendations or decisions influencing real or virtual environments”.

O memorando complementa essa delimitação ao diferenciar os conceitos de autonomia e adaptabilidade. Embora os objetivos e o desenvolvimento inicial dos sistemas de IA sejam rastreáveis a decisões humanas, a autonomia refere-se ao grau em que o sistema aprende ou atua sem envolvimento humano direto após a delegação de tarefas e processos. A adaptabilidade, por sua vez, é associada principalmente a sistemas baseados em *machine learning*, que podem continuar a evoluir após o desenvolvimento inicial, ajustando seu comportamento por meio da interação com dados e entradas antes ou depois da implantação. Nesse sentido, o documento afirma que “adaptabilidade refere-se à capacidade de um sistema de IA de atualizar automaticamente seus parâmetros internos com base em novos dados ou experiências” (OECD, 2024, p. 6, tradução nossa).⁴

No campo acadêmico, Borges (2023) recupera a trajetória histórica do conceito de inteligência artificial e destaca a coexistência de múltiplas definições na literatura, o que contribui para a adoção de definições institucionais contemporâneas como forma de garantir maior consistência analítica em pesquisas aplicadas. A autora enfatiza que a IA constitui um campo no qual abordagens, técnicas e escopos variam amplamente, o que implica que diferentes recortes conceituais são mobilizados conforme o problema investigado e o contexto de aplicação. Essa diversidade conceitual reforça a importância de explicitar o conceito operacional adotado em cada estudo, evitando generalizações que obscureçam as especificidades dos sistemas analisados.

No panorama internacional recente, o *AI Index Report 2025*, elaborado pelo Stanford HAI (2025), consolida evidências empíricas que caracterizam a aceleração do uso empresarial de IA e a expansão do investimento privado associado. No conjunto de destaques do relatório, o documento registra que “em 2024, a proporção de respondentes da pesquisa que relataram o uso de IA por suas organizações saltou de 55%, em 2023, para 78%” (Stanford HAI, 2025, p. 17, tradução nossa)⁵, e associa essa disseminação à intensificação dos recursos alocados ao desenvolvimento e à incorporação dessas tecnologias, ao afirmar que “o investimento corporativo em IA alcançou US\$ 252,3 bilhões em 2024, com o investimento privado registrando um aumento de 44,5% e as operações de fusões e aquisições crescendo 12,1% em relação ao ano anterior” (Stanford HAI, 2025, p. 17, tradução nossa).⁶

⁴ “adaptivity refers to the ability of an AI system to automatically update its internal parameters based on new data or experiences”.

⁵ “in 2024, the proportion of survey respondents reporting AI use by their organizations jumped to 78% from 55% in 2023”.

⁶ “Corporate AI investment reached \$252.3 billion in 2024, with private investment climbing 44.5% and mergers and acquisitions up 12.1% from the previous year”.

No Brasil, a pesquisa TIC Empresas 2024, conduzida pelo Nic.br, oferece um panorama específico sobre a presença de aplicações de IA no ambiente corporativo, permitindo discutir a difusão dessas tecnologias a partir de uma base empírica recorrente e comparável. No resumo executivo do Nic.br (2025, p. 21), o relatório explicita que “em 2024, a pesquisa TIC Empresas apontou a estabilidade do uso de IA nas empresas brasileiras: 13% das empresas afirmaram que usaram aplicações de IA, mesma proporção de 2023”. No mesmo trecho, o documento assinala que a adoção é desigual entre perfis empresariais ao registrar que “a IA está mais concentrada nas grandes empresas e no setor de Informação e comunicação” (Nic.br, 2025, p. 21). Essa concentração por porte e setor indica que a difusão da IA não ocorre de forma homogênea no tecido empresarial brasileiro, o que reforça a relevância de compreender o fenômeno a partir de recortes organizacionais e estruturais.

Além disso, a própria pesquisa explicita a base metodológica utilizada para viabilizar leitura comparativa da adoção, ao afirmar que “o módulo de uso de IA da TIC Empresas tem como referencial a pesquisa sobre uso de TIC nas empresas europeias, conduzida pelo Eurostat, conferindo comparabilidade internacional aos resultados brasileiros” (Nic.br, 2025, p. 75). Essa vinculação metodológica é retomada por Kubota (2024) ao destacar que “a 14ª edição da pesquisa TIC Empresas 2024 ampliou o uso do arcabouço desenvolvido pelo Gabinete de Estatísticas da União Europeia (European Statistical System - Eurostat), possibilitando a comparação com países que se destacam em pesquisa” (Kubota, 2024, p. 10). Nesse mesmo segmento, Kubota (2024, p. 10) registra que, nessa métrica, “se comparado com países europeus, o Brasil não fica atrás da maioria deles, com 13% de suas empresas utilizando algum tipo de IA”, o que reforça a pertinência de interpretar os indicadores nacionais com base em referenciais comparáveis, sem perder de vista as diferenças estruturais e setoriais.

Ainda no âmbito do diagnóstico sobre adoção, a pesquisa TIC Empresas 2024 explicita barreiras organizacionais relevantes associadas ao não uso de IA. Ao discutir motivos declarados pelas empresas para não adotarem essas tecnologias, o relatório afirma que “o custo elevado continua sendo um dos principais obstáculos, sugerindo que o investimento necessário para implementar essas ferramentas ainda é limitado” e acrescenta que “a falta de pessoas capacitadas para operar as tecnologias de IA aumentou de forma notável (40,5% em 2021 para 46,5% em 2023)” (Nic.br, 2025, p. 106).

2.2 Inteligência Artificial como solução corporativa: aplicações e benefícios

Segundo Borges (2023), a adoção de Inteligência Artificial em organizações é discutida na literatura como um meio para ampliar a capacidade de geração de valor organizacional, indo

além de ganhos pontuais de eficiência operacional e alcançando dimensões estratégicas relacionadas à criação de novos produtos, serviços e formas de atuação no mercado. Essa agenda se aproxima do argumento de Daugherty e Wilson (2018, p. 146, tradução nossa), que registram resultados de desempenho quando a IA é mobilizada junto a mudanças organizacionais, ao afirmarem que “empresas que utilizam a IA para aprimorar seu talento humano, ao mesmo tempo em que reimaginam seus processos de negócios, alcançam saltos significativos de desempenho”.⁷

Ainda de acordo com Borges (2023), apesar do crescimento do interesse corporativo por iniciativas baseadas em dados e IA, permanece recorrente na literatura a dificuldade de converter esses esforços em resultados organizacionais sustentáveis, o que motiva estudos voltados a compreender como o valor associado à IA é efetivamente criado e apropriado pelas empresas.

Como explicam Mikalef e Gupta (2021), compreender a IA como solução corporativa implica reconhecer que ferramentas e algoritmos, de forma isolada, não são suficientes para explicar ganhos de desempenho, uma vez que a geração de valor depende da construção de capacidades organizacionais específicas. Ao definirem capacidade de IA, os autores registram que o estudo “define a capacidade de IA como a habilidade de uma firma em estruturar, combinar e alavancar seus recursos baseados em IA” (Mikalef; Gupta, 2021, p. 7, tradução nossa).⁸ Nesse enquadramento, os ganhos associados ao uso corporativo de IA são discutidos no âmbito da articulação entre recursos relacionados à IA e ativos complementares mobilizados pela organização (Mikalef; Gupta, 2021).

Segundo Enholm *et al.* (2021), a atribuição de valor organizacional da IA distingue diferentes níveis de impacto, apontando que efeitos observados em nível de processo antecedem e condicionam efeitos em nível organizacional mais amplo. Com isto, aplicações corporativas de IA são analisadas inicialmente a partir das mudanças promovidas em rotinas, fluxos de trabalho e processos, que, em um segundo momento, podem se refletir em resultados organizacionais, como desempenho e vantagem competitiva.

No campo da gestão de operações, Rocha e Kissimoto (2022) analisam benefícios associados à incorporação de IA e Internet das Coisas (*IoT*) em ambientes organizacionais, descrevendo resultados como maior automação de processos, ampliação da comunicação em tempo real e redução de custos operacionais. No mesmo estudo, os autores também registram

⁷ “companies that use AI to augment their human talent while reimagining their business processes achieve step gains in performance”.

⁸ “defines an AI capability as a firm’s ability to structure, bundle, and leverage its AI-based resources”.

efeitos relacionados à agilidade na gestão da informação e ao monitoramento contínuo das atividades, ao mesmo tempo em que destacam dificuldades ligadas à qualidade dos dados e à complexidade operacional dos sistemas adotados (Rocha; Kissimoto, 2022, p. 20).

Retomando Enholm *et al.* (2021), a discussão sobre aplicações e benefícios da Inteligência Artificial nas organizações é acompanhada pela identificação de fatores tecnológicos, organizacionais e ambientais que condicionam seu uso. No recorte organizacional, os autores discutem conflitos entre atores, estruturas corporativas e dinâmicas internas como elementos associados à adoção e ao uso efetivo de IA em operações. Em convergência com a literatura sobre aceitação, Kelly e Kaye (2023), ao sistematizarem estudos sobre antecedentes da aceitação de IA, registram que “a utilidade percebida, a expectativa de desempenho, as atitudes, a confiança e a expectativa de esforço predizem de forma significativa e positiva a intenção comportamental” (Kelly; Kaye, 2023, p. 1, tradução nossa)⁹, indicando que fatores psicossociais, bem como percepções de utilidade e esforço, aparecem associados ao uso em contextos nos quais a adoção depende da interação humana com sistemas inteligentes.

2.3 Barreiras e limitações do uso corporativo da Inteligência Artificial

De acordo com Glikson e Woolley (2020), a confiança humana em sistemas de Inteligência Artificial é apontada como fator central para sua integração em organizações. No resumo do estudo, os autores afirmam que “o sucesso da integração da IA nas organizações depende criticamente da confiança dos trabalhadores na tecnologia de IA” (Glikson; Woolley, 2020, p. 2, tradução nossa).¹⁰ No mesmo trecho, Glikson e Woolley (2020, p. 2, tradução nossa) descrevem elementos associados à formação dessa confiança ao registrarem “comportamentos de tangibilidade, transparência, confiabilidade e imediatidade da IA”¹¹ como aspectos vinculados ao desenvolvimento da confiança cognitiva, bem como ao destacarem a presença de fatores associados à confiança emocional.

A confiança em sistemas de Inteligência Artificial também é apresentada por Glikson e Woolley (2020) como sensível à ocorrência e à percepção de erros durante o uso. Ao sintetizarem evidências experimentais, os autores registram que “a visibilidade de um erro afeta a confiança de uma forma que é difícil de reparar” (Glikson; Woolley, 2020, p. 36, tradução nossa).¹² No mesmo segmento, o texto descreve uma dinâmica de rejeição do apoio algorítmico

⁹ “perceived usefulness, performance expectancy, attitudes, trust, and effort expectancy significantly and positively predicted behavioural intention”.

¹⁰ “the success of integrating AI into organizations critically depends on workers’ trust in AI technology”.

¹¹ “AI’s tangibility, transparency, reliability and immediacy behaviors”.

¹² “the visibility of an error effects trust in a way that is difficult to repair”.

após falhas observadas, afirmando que “os participantes se recusaram a confiar em um modelo de previsão após observarem que ele cometeu um erro”¹³ e que “os participantes preferiram confiar em uma previsão humana, e não em um algoritmo, mesmo quando os erros humanos eram mais severos do que os erros algorítmicos” (Glikson; Woolley, 2020, p. 36, tradução nossa).¹⁴

Segundo Kelly e Kaye (2023), a aceitação organizacional da Inteligência Artificial e o preparo das organizações para seu uso constituem dimensões interdependentes amplamente discutidas na literatura recente. Com base em uma revisão sistemática que compila e analisa um conjunto extenso de estudos empíricos e conceituais, os autores organizam os achados em categorias que abrangem fatores psicossociais, organizacionais e institucionais, examinando métricas, variáveis explicativas e resultados associados à adoção da IA em ambientes de trabalho. A partir dessa síntese, os autores indicam que atitudes individuais, normas sociais, percepção de utilidade e facilidade de uso, bem como preocupações éticas e de privacidade, aparecem de forma recorrente associadas à disposição de indivíduos e grupos em utilizar sistemas inteligentes. Ao mesmo tempo, lacunas em competências técnicas, práticas de governança de dados e definição clara de papéis e responsabilidades organizacionais são identificadas como elementos centrais do conceito de *readiness*, frequentemente relacionados a dificuldades tanto na implementação quanto no uso contínuo da IA, mesmo em contextos nos quais o potencial técnico dessas tecnologias é reconhecido.

No campo da segurança e da privacidade, Elliott e Soifer (2022) discutem riscos associados ao uso de IA em organizações, destacando preocupações relacionadas à coleta, armazenamento e uso de dados sensíveis. Segundo os autores, sistemas de IA frequentemente dependem de grandes volumes de dados, o que amplia a exposição a riscos de vazamento, uso indevido de informações e violações de privacidade, especialmente quando práticas de governança e proteção de dados não estão adequadamente estabelecidas. Os mesmos também indicam que a complexidade técnica dos sistemas de IA dificulta a identificação de responsabilidades em caso de falhas, o que reforça a necessidade de mecanismos claros de governança e controle. Na ausência desses mecanismos, os autores apontam que organizações tendem a enfrentar resistência interna e cautela excessiva no uso da IA limitando seu alcance e aplicação prática (Elliott; Soifer, 2022, p. 4).

¹³ “participants refused to rely on a forecasting model after seeing it err”;

¹⁴ “participants preferred to rely on a human forecast and not on an algorithm, even when human errors were more severe than algorithm errors”.

2.4 Centralidade da colaboração humano-IA: o dilema entre automação e aprimoramento

Raisch e Krakowski (2021) retomam o debate sobre os efeitos organizacionais da inteligência artificial a partir de dois conceitos recorrentes, automação e aprimoramento. No enquadramento proposto pelos autores, “enquanto a automação implica que as máquinas assumem uma tarefa humana, o aprimoramento significa que humanos colaboram estreitamente com máquinas para realizar uma tarefa” (Raisch; Krakowski, 2021, p. 2, tradução nossa)¹⁵. Em linha com a tradução empregada em estudo nacional, Borges (2023, p. 57) registra o “papel assistencial de aprimoramento (do inglês *augmenting*)” ao distinguir usos de IA voltados ao apoio humano, em contraste com a automação.

No âmbito dessa discussão, Daugherty e Wilson (2018) registram que parte relevante do debate público e corporativo se organiza em torno da expectativa de substituição progressiva do trabalho humano. Os autores sintetizam essa leitura ao afirmarem que “uma concepção equivocada amplamente difundida é a de que os sistemas de IA, incluindo robótica avançada e bots digitais, irão gradualmente substituir os seres humanos de um setor após outro” (Daugherty; Wilson, 2018, p. 14, tradução nossa).¹⁶ Ao mesmo tempo, ao descreverem o que consideram um equívoco recorrente de interpretação, os autores registram que “a simples verdade é que as máquinas não estão assumindo o controle do mundo, nem eliminando a necessidade de seres humanos no ambiente de trabalho” (Daugherty; Wilson, 2018, p. 16, tradução nossa).¹⁷ Mikalef e Gupta (2021) também registram, no debate organizacional, a coexistência entre automação e aplicações voltadas ao aprimoramento, ao afirmarem que “o raciocínio subjacente a tais argumentos é que, ao automatizar muitas tarefas manuais, os seres humanos passam a dispor de mais tempo para se engajar em atividades criativas. Além disso, por meio de determinadas aplicações de IA, as capacidades humanas podem ser aprimoradas, no que se denomina inteligência aumentada” (Mikalef; Gupta, 2021, p. 3, tradução nossa).¹⁸

Brynjolfsson e McAfee (2016) situam parte dessas tensões em um contexto de ampliação das capacidades computacionais aplicadas a atividades antes tratadas como domínio humano. Ao descreverem o alcance contemporâneo das tecnologias digitais, os autores afirmam

¹⁵ “whereas automation implies that machines take over a human task, augmentation means that humans collaborate closely with machines to perform a task”.

¹⁶ “a widespread misconception is that AI systems, including advanced robotics and digital bots, will gradually replace humans in one industry after another”.

¹⁷ “the simple truth is that machines are not taking over the world, nor are they obviating the need for humans in the workplace”.

¹⁸ “the reasoning in such claims is that by automating many manual tasks, humans will have more time on their hands to engage in creative activities. Also, through certain applications of AI, human capabilities can be augmented, through what is termed augmented intelligence”.

que “nossas máquinas digitais escaparam de seus limites restritos e passaram a demonstrar amplas capacidades de reconhecimento de padrões, comunicação complexa e outros domínios que antes eram exclusivamente humanos” (Brynjolfsson; McAfee, 2016, p. 68, tradução nossa).¹⁹ Glikson e Woolley (2020) registram a centralidade da colaboração humano-IA na agenda organizacional ao afirmarem que “isso abre espaço para um diálogo aberto e multidisciplinar, voltado à exploração da colaboração entre humanos e IA”²⁰ e, no mesmo trecho, que “a confiança que os usuários desenvolvem na tecnologia de IA será central para determinar seu papel nas organizações daqui em diante” (Glikson; Woolley, 2020, p. 3, tradução nossa).²¹

Ao diferenciar com maior precisão os sentidos de automação e aprimoramento, Davenport e Kirby (2016) argumentam que a automação se orienta por subtrair tarefas humanas codificáveis, enquanto o aprimoramento se organiza pela colaboração entre pessoas e tecnologias. Os autores sintetizam essa distinção ao registrarem que “a automação parte de uma linha de base do que as pessoas fazem em um determinado trabalho e subtrai atividades desse conjunto, utilizando computadores para reduzir gradualmente as tarefas humanas à medida que elas podem ser codificadas”²² e que “o aprimoramento consiste em partir do que mentes humanas e máquinas realizam individualmente hoje e em identificar como esse trabalho pode ser aprofundado, e não diminuído, por meio da colaboração entre ambos” (Davenport; Kirby, 2016, p. 53, tradução nossa).²³ Em discussão recente sobre mudanças organizacionais associadas à implantação de IA, Mikalef e Gupta (2021) registram simultaneamente os dois movimentos ao afirmarem que “as aplicações de IA introduzem mudanças significativas na forma como as organizações realizam suas atividades-chave, seja substituindo tarefas tradicionalmente executadas por humanos, seja aprimorando processos existentes” (Mikalef; Gupta, 2021, p. 6, tradução nossa).²⁴

Em convergência com essa leitura, Daugherty e Wilson (2018) descrevem aplicações em que a IA sustenta tanto a automação quanto arranjos de trabalho associados ao aprimoramento, ao afirmarem que “a tecnologia de IA pode auxiliar na filtragem e análise de

¹⁹ “our digital machines have escaped their narrow confines and started to demonstrate broad abilities in pattern recognition, complex communication, and other domains that used to be exclusively human”.

²⁰ “this leaves room for an open, multidisciplinary dialogue that should explore human-AI collaboration”;

²¹ “the trust that users develop in AI technology will be central to determining its role in organizations moving forward”.

²² “automation starts with a baseline of what people do in a given job and subtracts from that. It deploys computers to chip away at the tasks humans perform as soon as they can be codified”;

²³ “augmentation means starting with what minds and machines do individually today and figuring out how that work could be deepened rather than diminished by a collaboration between the two”.

²⁴ “AI applications introduce significant changes to how organizations perform their key activities, either by replacing traditionally human-executed tasks, or by augmenting existing processes”.

fluxos de informação provenientes de diversas fontes e viabilizar a automação de tarefas tediosas e repetitivas, bem como o aprimoramento das habilidades e da expertise humanas” (Daugherty; Wilson, 2018, p. 17, tradução nossa).²⁵ No contexto brasileiro, a pesquisa TIC Empresas 2024 registra que “entre as empresas brasileiras que empregaram algum tipo de IA, a maioria informou usos relacionados à automatização de processos e fluxos de trabalho” (Nic.br, 2025, p. 77) e afirma que “o uso de IA mais frequente entre as empresas brasileiras diz respeito à automatização de fluxos de trabalho, visando otimizar processos internos e aspectos externos passíveis de rotinização (por exemplo, o atendimento ao cliente)” (Nic.br, 2025, p. 80). No mesmo relatório, ao descrever sistemas baseados em grandes modelos de linguagem, registra-se que “esses sistemas empregam técnicas sofisticadas de *machine learning* para responder a perguntas e executar tarefas, baseando-se em probabilidades estatísticas” (Nic.br, 2025, p. 123).

Raisch e Krakowski (2021, p. 2, tradução nossa), ao revisarem o debate no domínio da gestão, registram que as obras analisadas em sua pesquisa adotam orientação normativa ao afirmarem que “ao adotar uma postura normativa, os três livros aconselham as organizações a priorizarem o aprimoramento, o qual relacionam a um desempenho superior”.²⁶ No entanto, os autores afirmam que “o aprimoramento não pode ser nitidamente separado da automação”²⁷ e registram que “supervalorizar o aprimoramento ou a automação alimenta ciclos de reforço com resultados organizacionais e sociais negativos” (Raisch; Krakowski, 2021, p. 2, tradução nossa).²⁸ No mesmo resumo, afirmam que “se as organizações adotarem uma perspectiva mais ampla que compreenda tanto a automação quanto o aprimoramento, elas poderão lidar com essa tensão e alcançar complementaridades que beneficiem os negócios e a sociedade” (Raisch; Krakowski, 2021, p. 2, tradução nossa).²⁹

Ao descrever a forma como a literatura gerencial apresenta a decisão organizacional, Raisch e Krakowski (2021) registram que, “se optarem pela automação, os humanos transferem a tarefa para uma máquina, com pouca ou nenhuma participação posterior”³⁰ e, em contraste, que “o aprimoramento implica uma interação contínua e estreita entre humanos e máquinas”

²⁵ “AI technology can help filter and analyze streams of information from a variety of sources and enable the automation of tedious, repetitive tasks as well as the augmentation of human skills and expertise”.

²⁶ “taking a normative stance, the three books advise organizations to prioritize augmentation, which they relate to superior performance”;

²⁷ “augmentation cannot be neatly separated from automation”;

²⁸ “over-emphasizing either augmentation or automation fuels reinforcing cycles with negative organizational and societal outcomes”;

²⁹ “if organizations adopt a broader perspective comprising both automation and augmentation, they could deal with the tension and achieve complementarities that benefit business and society”.

³⁰ “If they opt for automation, humans hand over the task to a machine with little or no further involvement”;

(Raisch; Krakowski, 2021, p. 8, tradução nossa).³¹ Em continuidade, os autores descrevem o aprimoramento como um processo coevolutivo, no qual humanos e sistemas aprendem em interação ao longo do tempo (Raisch; Krakowski, 2021, p. 10).

³¹ “augmentation implies continued close interaction between humans and machines”.

3 METODOLOGIA

“Podemos definir método como caminho para chegarmos a um determinado fim” (Prodanov; Freitas, 2013, p. 24). A partir dessa base, esta pesquisa caracteriza-se como qualitativa, aplicada e delineada como estudo de caso único, pois busca compreender, em profundidade, como um processo organizacional se transformou ao longo da implementação de uma solução de Inteligência Artificial em seu contexto real. A escolha do estudo de caso é adequada porque permite investigar um fenômeno contemporâneo no ambiente em que ele ocorre, mantendo a análise vinculada às circunstâncias organizacionais que o moldam (Hollweck, 2015). Nesse sentido, a definição operacional apresentada por Hollweck (2015), ao discutir Yin (2014), sustenta a escolha metodológica ao registrar que o estudo de caso é “uma investigação empírica que examina um fenômeno contemporâneo (o ‘caso’) em profundidade e em seu contexto do mundo real” (Hollweck, 2015, p. 2, tradução nossa).³²

O projeto acompanhado pode ser descrito por um intervalo temporal claro: a fase de pré-implementação foi iniciada em outubro de 2024, o piloto teve início em fevereiro de 2025, a entrada em produção com revisão humana ocorreu entre março e maio de 2025 e a ampliação de escopo avançou a partir de junho de 2025. A coleta de dados foi estruturada para garantir rastreabilidade entre evidências e conclusões, evitando interpretações baseadas apenas em percepção individual. Foram utilizados predominantemente documentos institucionais e registros internos do projeto, tais como documentação do processo, materiais de acompanhamento, registros de testes e validações e relatórios operacionais gerados pelos sistemas envolvidos. Complementarmente, foram realizadas entrevistas exploratórias com participantes diretamente envolvidos na operação e na implementação, com o objetivo de esclarecer decisões, reconstituir critérios de validação adotados em cada fase e compreender como dificuldades técnicas e organizacionais influenciaram o avanço do projeto.

A análise dos dados foi conduzida de forma processual, longitudinal e comparativa, organizando as evidências por fases do projeto para descrever, em cada etapa, o que foi executado tecnicamente, quais dificuldades emergiram na prática e quais ajustes foram implementados na sequência para contorná-las. Essa organização buscou preservar a lógica de encadeamento entre expectativas iniciais, ocorrências observadas e medidas corretivas, permitindo comparar o comportamento do processo antes e depois da implementação e entre diferentes momentos de maturidade do sistema. Em respeito à confidencialidade da

³² “an empirical inquiry that investigates a contemporary phenomenon (the ‘case’) in depth and within its real-world context”.

organização, os resultados foram tratados exclusivamente em percentuais, sem explicitação de volumes absolutos, valores ou identificadores internos, de modo que a evidência empírica e a comparação entre fases sustentem os resultados e a discussão apresentados no capítulo subsequente.

4 ESTUDO DE CASO

4.1 Caracterização da empresa


A empresa estudada é uma organização global de base tecnológica que opera em ambiente *Business-to-Business* (B2B), com elevada dependência de sistemas corporativos para registrar, validar e executar transações associadas ao ciclo comercial e ao faturamento. A operação analisada integra um fluxo ponta a ponta no qual documentos externos do cliente e registros internos precisam convergir, sob prazos rígidos e forte sensibilidade a variações sazonais de demanda, especialmente em períodos de fechamento trimestral. Trata-se de um contexto típico de operações distribuídas, com múltiplas interfaces entre áreas e sistemas, no qual a qualidade do desempenho não decorre apenas de padronização formal, mas também da capacidade de absorver picos sem perda de controle do processo e sem acumular verificações ao final do fluxo.

Do ponto de vista organizacional, a natureza do trabalho envolve interação contínua entre operação, gestão de processo, tecnologia e dados, pois o problema central não é exclusivamente documental, mas de coordenação entre fontes de informação, regras de negócio e tomada de decisão em condições de pressão de prazo. Essa caracterização dialoga com a literatura que enfatiza que valor e desempenho associados à inteligência artificial dependem de capacidades organizacionais complementares, isto é, arranjos de trabalho, governança e integração entre recursos técnicos e não técnicos, e não apenas da ferramenta em si (Mikalef; Gupta, 2021; Enholm *et al.*, 2021).

4.2 Descrição do processo analisado

O processo analisado e sintetizado na Figura 1 integra o trecho final do ciclo comercial, no qual uma proposta formalizada e aceita pelo cliente é convertida em pedido executável no ambiente corporativo e, em seguida, habilita a emissão de fatura. Na prática, trata-se de um fluxo de convergência entre documentação externa e registros internos. De um lado, entram documentos encaminhados pelo cliente, como pedido de compra, cotação associada e anexos complementares e de outro, existem cadastros, regras e parâmetros internos necessários para que o pedido seja registrado corretamente e para que a etapa de faturamento ocorra sem inconsistências. A operacionalização desse processo exige que informações contidas em documentos não estruturados sejam interpretadas e comparadas com registros internos, de modo a confirmar aderência e completude antes do avanço.

Figura 1 – Fluxograma sintético do processo analisado



Fonte: Elaborado pela autora (2026).

A etapa inicial ocorre com o recebimento e organização do conjunto de documentos por parte da equipe de operação. Em seguida, realiza-se a triagem e conferência de completude, onde o objetivo é identificar se o conjunto de documentos recebido contém os elementos mínimos para prosseguimento e se há correspondência entre o que foi acordado na cotação e o que foi efetivamente formalizado pelo cliente. Essa fase inclui verificação de campos essenciais para conformidade e faturamento, como referências ao documento de origem, entidade legal, endereços, termos de pagamento, datas e elementos cadastrais, além da identificação de anexos mandatórios conforme a natureza do pedido. Em operação predominantemente manual, essa conferência depende de leitura do documento, extração de informações relevantes e comparação com os registros existentes no ambiente transacional, tudo realizado por um dos membros da equipe de operação. Quando a informação está ausente, ambígua ou inconsistente, o fluxo não avança de forma contínua, neste caso, ele retorna a etapas anteriores, com solicitação de correção e posterior retomada, o que cria ciclos de retrabalho.

A característica crítica do processo não está apenas na quantidade de validações, mas na forma como elas se distribuem ao longo do tempo e na sensibilidade do fluxo a variações sazonais, em especial no fechamento trimestral. Em períodos regulares, as checagens tendem a se diluir, e as correções necessárias são absorvidas com menor efeito sistêmico, já que não há concentração aguda de casos. No fechamento trimestral, entretanto, há compressão do volume em uma janela curta, aproximando, em poucos dias, um patamar que em condições usuais se

distribui ao longo do mês. Essa compressão altera a dinâmica operacional por dois mecanismos complementares. Primeiro, aumenta filas e tempos de espera nas etapas de triagem e conferência, porque a capacidade humana de leitura e comparação tem limite. Segundo, desloca o risco para o fim do percurso, porque inconsistências identificadas tardiamente implicam retomadas sucessivas quando o sistema já está sob pressão, ampliando o custo operacional e elevando a exposição a atrasos. Nesse cenário, o processo deixa de ser apenas um encadeamento de tarefas e passa a ser um sistema com retroalimentações, onde exceções e retornos, quando multiplicados, podem comprometer previsibilidade.

4.3 Descrição do problema

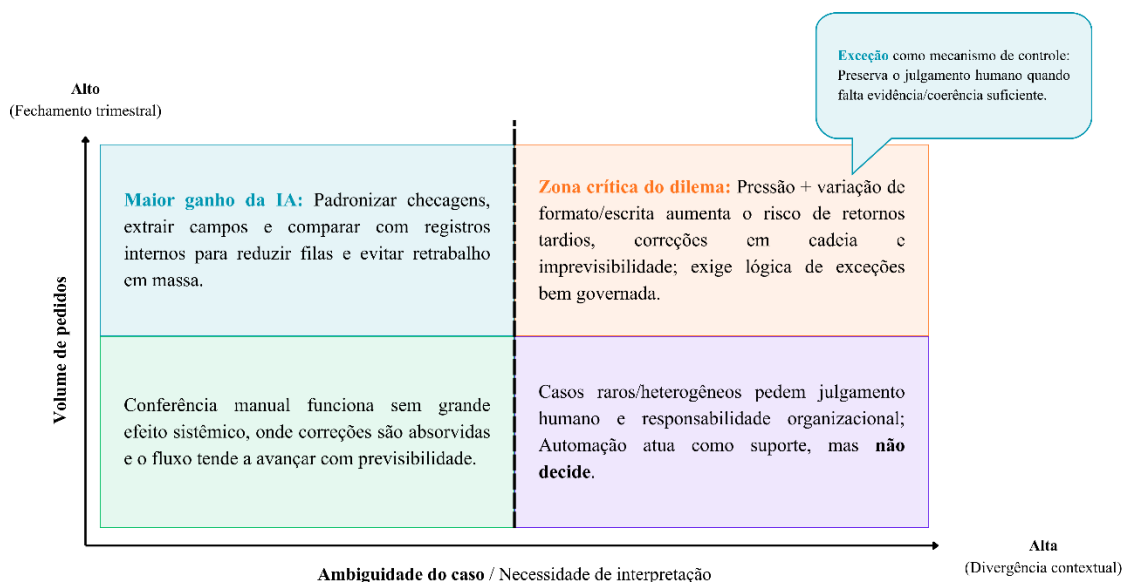
A motivação para a implementação do sistema de inteligência artificial emerge, portanto, de um problema que combina pressão por prazo, variabilidade de volume e dependência de validações manuais em um ambiente de múltiplas interfaces entre áreas e sistemas. O ponto central não é a inexistência de regras, mas a dificuldade prática de aplicá-las com consistência e velocidade quando a operação é obrigada a ler documentos não estruturados, extrair campos e comparar informações com registros internos em grande escala. Em períodos de pico, a operação não enfrenta somente o aumento da demanda, ela enfrenta um tipo de trabalho mais vulnerável a acúmulos e ciclos de retrabalho, pois cada inconsistência identificada pode gerar retorno, nova leitura, nova conferência e nova tentativa de avanço. Assim, o custo do erro e o custo da ausência de informação aumentam, não apenas pelo esforço direto, mas pelo efeito de encadeamento em filas e retomadas.

O problema também é organizacional porque envolve coordenação entre fontes de informação, distribuição de responsabilidades e delimitação da fronteira entre decisão automatizável e decisão que exige julgamento humano. Parte das divergências é objetiva, como ausência de campos obrigatórios, anexos incompletos ou inconsistências cadastrais, já a outra parte é contextual, porque depende de interpretar como regras internas devem ser aplicadas diante de variações de formato, diferenças de escrita e casos em que o documento do cliente expressa a mesma informação de maneira distinta. Quando essas situações são tratadas apenas como conferência manual, o conhecimento necessário tende a ficar disperso em pessoas e rotinas, e o controle do processo se fragiliza em cenários de alta variabilidade. Além disso, quanto mais tarde uma inconsistência é percebida, maior é a probabilidade de que o caso retorne com urgência, produzindo correções em cadeia e aumentando a percepção de imprevisibilidade do fluxo.

Nesse enquadramento, a implementação do sistema de IA não é apresentada como substituição de trabalho humano, mas como tentativa de deslocar o esforço operacional do tratamento massivo e repetitivo para uma lógica de exceções, na qual a automação organiza informação, antecipa checagens e sinaliza divergências, enquanto a decisão humana se concentra nos casos em que o contexto e a interpretação permanecem indispensáveis. A problemática do estudo de caso, portanto, é compreender de que modo um arranjo sociotécnico desse tipo altera o comportamento do processo sob pressão, especialmente no fechamento trimestral, e quais condições organizacionais são necessárias para que a adoção seja efetiva, confiável e sustentável.

Para sintetizar o dilema qualitativo descrito, a Figura 2 apresenta a tensão entre o volume de pedidos (especialmente no fechamento trimestral) e a ambiguidade do caso, evidenciando a fronteira entre decisões automatizáveis e decisões que exigem julgamento humano.

Figura 2 – Matriz do dilema sociotécnico: volume de pedidos versus ambiguidade da decisão no processo analisado



Fonte: Elaborado pela autora (2026).

4.4 Estrutura de implementação e modo de trabalho

A estrutura de implementação foi concebida para responder simultaneamente a dois desafios interdependentes: transformar documentos não estruturados em informação operacionalmente utilizável e incorporar automação sem perda de governança sobre o fluxo.

Para tratar esses desafios de forma verificável, a iniciativa foi organizada em três etapas encadeadas. Na etapa (i), de pré-implementação, o fluxo efetivamente praticado foi mapeado, os campos essenciais foram definidos e critérios mínimos de completude e coerência foram formalizados, tornando observável aquilo que, na operação manual, frequentemente se apoia em conhecimento tácito. Na etapa (ii), de implementação e piloto, a solução foi ajustada em ciclos curtos com base em casos reais, com registro das exceções e revisão de regras e tolerâncias para reduzir classificações incorretas e fricções operacionais. Na etapa (iii), de estabilização e ampliação progressiva, o escopo foi expandido com controle de risco e com rastreabilidade das decisões, de modo a consolidar previsibilidade justamente no período em que o fechamento trimestral comprime volume e eleva a sensibilidade do processo a retornos e retrabalho.

A síntese dessas três etapas, com seus focos e resultados esperados no processo, é apresentada na Tabela 1.

Na fase de implementação, a solução foi desenvolvida e ajustada em ciclos curtos de validação, nos quais casos reais foram utilizados para identificar falhas, classificar origens de divergência e aprimorar regras e tolerâncias, com o objetivo de reduzir classificações incorretas e exceções desnecessárias. Em termos operacionais, a solução passa a executar leitura documental, extração de campos específicos nos documentos recebidos e cruzamento com registros internos, produzindo um resultado que reorganiza o fluxo. Quando há coerência suficiente, o pedido avança, já quando há divergência ou insuficiência de evidência, o caso é direcionado como exceção para revisão humana. A exceção, nesse desenho, não é um desvio residual, mas um mecanismo de controle, pois preserva o julgamento humano exatamente nos casos em que a decisão demanda contexto, interpretação e responsabilidade organizacional.

A governança foi fortalecida pelo registro sistemático de decisões automatizadas e intervenções humanas, viabilizando rastreabilidade e aprendizagem acumulada, na medida em que cada exceção analisada se converte em insumo para refinar regras, ampliar cobertura e reduzir ambiguidade. Como estratégia de redução de risco, a adoção foi conduzida por escopo progressivo, priorizando classes de casos mais previsíveis do ponto de vista documental e postergando, para etapas posteriores, situações de maior variabilidade de formato e evidência, de modo a estabilizar o comportamento do processo antes de expandir cobertura.

Tabela 1 – Síntese das etapas de implementação e do tratamento dos dois desafios

Etapas	Foco da etapa	O que foi feito (síntese)	Resultado esperado no processo
(i) Pré-implementação	Transformar documentos não estruturados em informação operacionalmente utilizável	Mapeamento do fluxo efetivamente praticado; definição de campos essenciais; formalização de critérios mínimos de completude e coerência	Tornar observável o que era tácito e reduzir ambiguidades na aplicação de regras
(ii) Implementação e piloto	Ajustar a automação sem perda de governança sobre o fluxo	Ciclos curtos com casos reais; registro de exceções; revisão de regras e tolerâncias para reduzir classificações incorretas e fricções; leitura documental, extração de campos e cruzamento com registros internos; direcionamento de divergências como exceção para revisão humana	Reorganizar o fluxo com avanço quando há coerência suficiente e controle por exceções quando há divergência ou evidência insuficiente
(iii) Estabilização e ampliação progressiva	Consolidar previsibilidade e controlar risco na expansão	Fortalecimento de governança por registro sistemático de decisões automatizadas e intervenções humanas (rastreadabilidade e aprendizagem); adoção por escopo progressivo, priorizando casos mais previsíveis e postergando maior variabilidade	Estabilizar o comportamento do processo antes de ampliar cobertura, especialmente sob pressão do fechamento trimestral

Fonte: Elaborado pela autora (2026).

5 RESULTADOS E DISCUSSÃO

5.1 Pré-implementação: delimitação do problema, preparação do sistema e arranjo de trabalho

Na fase de pré-implementação, o foco do trabalho esteve na compreensão do fluxo de validação existente e na identificação dos principais gargalos associados ao fechamento operacional. Conforme sintetizado na Figura 3, essa etapa teve caráter fundamentalmente analítico e estrutural, buscando explicitar como a leitura de documentos não estruturados, a extração manual de informações e a checagem em múltiplos registros contribuíam para retrabalho, variabilidade e acúmulo de demandas em períodos críticos. A figura organiza, de forma integrada, a etapa do processo, as decisões de desenho adotadas, sua relevância para a lógica do projeto e os primeiros resultados obtidos, servindo como base para as fases subsequentes de implementação.

Figura 3 – Fase 5.1: pré-implementação do sistema de IA e definição do modelo por exceções



Fonte: Elaborado pela autora (2026).

5.1.1 Preparação técnica do sistema e do fluxo de validação

O ponto de partida da implementação foi o reconhecimento de que o gargalo não derivava de ausência de padrão formal, mas da compressão de volume no fechamento

trimestral, que concentrava, em uma janela curta, um volume equivalente ao período regular, gerando filas e retomadas na triagem e na conferência de aderência entre documentos do cliente e registros internos. As ocorrências recorrentes estavam associadas à ausência de campos obrigatórios, inconsistências cadastrais e anexos incompletos, o que produzia correções manuais em sequência e intensificava o retrabalho justamente quando a pressão de prazo se elevava. A solução foi estruturada para atuar nos pontos de maior impacto sem alterar a padronização já consolidada nos meses regulares, reposicionando o esforço humano para onde havia maior incerteza e maior necessidade de julgamento.

A preparação técnica consolidou a lógica operacional do sistema: leitura dos documentos recebidos, extração de campos essenciais e cruzamento dessas informações com registros existentes; quando havia coerência, o fluxo avançava e, quando surgiam divergências, abria-se exceção para revisão humana. Essa arquitetura foi desenhada para preservar rastreabilidade, mantendo registro de decisões com data, hora e responsável, de modo que o avanço da automação não reduzisse controle, mas ampliasse transparência do processo e viabilizasse auditoria e aprendizado a partir do uso real. Ainda nessa fase, as decisões sobre qualidade de leitura e tolerância de validação se mostraram determinantes para a operação. Para lidar com variabilidade de formatos, houve atualização do Reconhecimento Óptico de Caracteres (*OCR*) e incorporação de regras de tolerância por *loose matching*, aceitando variações como abreviações e pequenas diferenças de formatação sem comprometer a integridade documental. Essa mudança reduziu bloqueios indevidos e criou base técnica para que a fila de exceções representasse, de fato, situações ambíguas, e não ruído de leitura ou rigidez artificial de comparação.

5.1.2 Preparação organizacional e governança do projeto

A organização do trabalho foi tratada como parte do escopo desde a origem. A formação do time multidisciplinar ocorreu antes da estabilização da solução, reunindo operação, donos de processo, analistas do sistema transacional, desenvolvimento e ciência de dados, além de representantes de áreas afetadas, para assegurar que regras e exceções refletissem o trabalho real, e não apenas o desenho formal do fluxo. Na prática, essa decisão definiu o modo como o conhecimento tácito do processo foi convertido em critérios explícitos de validação, e estabeleceu a fronteira de responsabilidade entre automação e revisão humana, reduzindo ambiguidades sobre quem decide, em que momento e com base em quais evidências.

5.1.3 Desafios iniciais e encaminhamentos

Mesmo com arranjo formal de governança, o projeto enfrentou um desafio típico de iniciativas de IA em processos administrativos: expectativa implícita de que a ferramenta chegaria “pronta” e que falhas iniciais deveriam ser exceção rara. Esse entendimento elevou a sensibilidade a falsos positivos e, por consequência, aumentou a carga simbólica de cada erro percebido. Como efeito, surgiram sinais de resistência e cautela no engajamento por parte da equipe de implementação e teste, especialmente no reporte de falhas, o que atrasou correções e prolongou a presença de erros recorrentes. A contenção dessa dinâmica exigiu reposicionamento institucional do projeto como iniciativa de aprimoramento do trabalho, e não de substituição do time, de modo a reduzir insegurança, ampliar confiança no processo de validação e qualificar o *feedback* como insumo estruturado de melhoria contínua.

5.2 Implementação e piloto: ciclos curtos, validação com usuários e correções orientadas pelo uso real

Na fase de piloto, o sistema passou do desenho conceitual para o uso em ambiente real, permitindo observar seu desempenho sob condições operacionais efetivas. Conforme apresentado na Figura 4, essa etapa teve como objetivo testar a aderência do fluxo automatizado, a qualidade da captura de dados e o comportamento das filas de exceções em períodos de maior pressão. A figura sintetiza as principais decisões de calibração adotadas durante o piloto, a lógica de ajustes incrementais baseada em casos reais e os efeitos dessas escolhas sobre a fluidez do processo e a percepção de confiabilidade do sistema.

Figura 4 – Fase 5.2: piloto do sistema de IA e calibração inicial de regras



Fonte: Elaborado pela autora (2026).

5.2.1 Execução técnica do piloto e funcionamento prático das exceções

A fase de implementação foi conduzida por ciclos curtos de entrega e validação com usuários, com ajustes imediatos sempre que apareciam falsos positivos ou lacunas de regra, seguindo a lógica de experimentar cedo, aprender rápido e corrigir com baixo custo. Na prática, o piloto materializou o desenho do fluxo como triagem automatizada com revisão humana nas divergências: a automação realizava extração e comparação, e a equipe atuava sobre exceções geradas por inconsistência documental ou por casos que o sistema ainda não cobria com robustez. Essa etapa foi essencial porque deslocou o desenvolvimento de regras de um exercício abstrato para um processo empírico, no qual os casos reais revelavam variações não previstas e exigiam ajustes finos nas tolerâncias e nos critérios de validação.

5.2.2 Dimensão organizacional: recepção do sistema e qualidade do *feedback*

O desempenho técnico do piloto foi condicionado pela dinâmica organizacional de adoção. No início, a confiança na plataforma ainda era baixa, em parte pela presença natural de falhas iniciais, em parte pela compreensão incompleta do propósito e dos limites do sistema. Esse contexto favoreceu receio difuso em relação à automação e reforçou uma postura defensiva, na qual erros percebidos nem sempre eram reportados de forma consistente, o que reduzia a velocidade de aprendizado. A mudança de patamar ocorreu quando a governança

passou a priorizar comunicação estruturada e alinhamento institucional, esclarecendo finalidade, fronteira de decisão e benefícios operacionais para a equipe. Essa ação reconfigurou o papel dos usuários na implementação, deslocando-os de “avaliadores finais” para co-construtores do processo de validação, com efeito direto na densidade e na qualidade do *feedback*.

5.2.3 Principais desafios e soluções adotadas durante o piloto

O desafio técnico mais recorrente nessa etapa foi a combinação entre variabilidade documental e rigidez inicial de regra, que se manifestava como falso positivo, bloqueando casos válidos e empurrando trabalho para a fila de exceções. A solução foi operacionalizar uma rotina de correção incremental, na qual cada bloqueio indevido se convertia em caso de teste, motivava ajuste de tolerância, regra ou mapeamento de campo e retornava rapidamente ao uso real, sem paralisar o restante do fluxo. Esse mecanismo estabilizou o sistema por aprendizagem cumulativa, e evitou que o retrabalho retornasse ao formato anterior, no qual correções se acumulavam no fim do mês e se agravavam no fechamento trimestral.

5.3 Estabilização em produção: revisão humana, disciplina de medição e previsibilidade do fluxo

Na fase de produção com revisão humana, o sistema passou a operar de forma contínua em ambiente produtivo, mantendo a intervenção humana concentrada exclusivamente nos casos classificados como exceções. Conforme sintetizado na Figura 5, essa etapa consolidou o fluxo automatizado ao incorporar mecanismos formais de governança e rastreabilidade das decisões, permitindo que cada divergência identificada fosse registrada, analisada e utilizada como insumo para ajustes incrementais. A figura evidencia como a institucionalização da revisão humana e da trilha auditável contribuiu para reduzir reprocessamentos repetidos, encurtar o ciclo entre erro e correção e conferir maior previsibilidade ao fechamento operacional, mesmo sob pressão de prazo e volume.

Figura 5 – Fase 5.3: operação do sistema de IA com revisão humana e governança de exceções



Fonte: Elaborado pela autora (2026).

5.3.1 Operação com revisão humana e trilha auditável

Com a entrada em produção com revisão humana, o projeto consolidou dois elementos que sustentaram a estabilização: rastreabilidade e governança de exceções. O registro de decisões com data, hora e responsável estruturou a trilha auditável e permitiu que divergências deixassem de ser tratadas como ruído operacional e passassem a ser evidência para melhoria. Ao mesmo tempo, o fluxo de exceções serviu como mecanismo de controle, preservando julgamento humano onde havia ambiguidade, sem interromper a automação nos casos de alta previsibilidade, o que aumentou a consistência do processo e reduziu a oscilação típica de picos de volume.

5.3.2 Resultados intermediários e validação por indicadores operacionais

Os resultados mais importantes desta fase não se limitaram ao ganho médio, mas à mudança de comportamento do sistema sob pressão de prazo. A redução de retrabalho e a maior previsibilidade do percurso foram atribuídas, no próprio registro do projeto, tanto à ferramenta quanto à forma como o trabalho foi organizado, com aproximação entre operação, processo, dados e desenvolvimento, encurtando o intervalo entre observar um problema e corrigir a regra que o provocava. Esse encurtamento foi o mecanismo que evitou que inconsistências

persistissem por longos períodos e que falhas se repetissem até o fechamento, quando o custo do erro é mais alto.

5.4 Ajuste de escopo e ampliação: pivô guiado por evidências e expansão com controle de risco

Na fase de pivô e ampliação, a lógica do projeto deixa de ser predominantemente operacional e passa a assumir caráter explicitamente gerencial. Conforme sintetizado na Figura 6, essa etapa foi marcada pela decisão de ampliar o uso do sistema de forma seletiva, com base no desempenho observado em produção, evitando a expansão indiscriminada para contextos de alta variabilidade documental. A figura evidencia como o pivô de escopo, associado a critérios claros de monitoramento e governança madura, permitiu consolidar o regime operacional no recorte estabilizado e criar condições para ganhos sustentáveis de desempenho, sem aumento proporcional de risco ou perda de controle.

Figura 6 – Fase 5.4: pivô de escopo e ampliação controlada do sistema de IA



Fonte: Elaborado pela autora (2026).

5.4.1 Evidências que motivaram o pivô e reorientação do recorte inicial

Na sequência da operação em produção, o projeto identificou, por evidências do uso real, que certos grupos de ordens apresentavam variabilidade elevada de *layout* e linguagem, incluindo idiomas e alfabetos não latinos, o que alongava o treinamento e dificultava

aprovações automáticas no início. Diante disso, foi conduzido um pivô de escopo, direcionando a automação para um recorte de ordens com maior volume e maior previsibilidade documental.

À medida que o sistema passou a operar em ambiente produtivo, tornou-se necessário explicitar a fronteira de decisão entre o que era tratável por automação e o que deveria permanecer sob julgamento humano, distinguindo tarefas de baixa variabilidade e alta previsibilidade, nas quais o sistema padroniza checagens e consolida campos com consistência, de situações em que a evidência documental é insuficiente, incoerente ou heterogênea, exigindo interpretação contextual e responsabilidade decisória. Nesse desenho, a revisão humana não se configura como retrocesso, mas como mecanismo de controle estruturado por exceções, preservando a intervenção humana nos casos ambíguos sem interromper o fluxo automatizado, além de viabilizar aprendizagem incremental por retroalimentação de erros e divergências.

Como exemplo de delimitação prática dessa fronteira, o conjunto de ordens associado a um tipo de produto específico foi tratado como exceção permanente e, portanto, fora do escopo do sistema, pois apresentou, ao longo das fases, variabilidade sistematicamente maior de layout e linguagem, elevando a taxa de ambiguidade e tornando o encaminhamento direto para verificação humana a alternativa mais robusta para preservar acurácia e previsibilidade operacional.

5.4.2 Ampliação progressiva e automação avançada em piloto controlado

Após o pivô, a ampliação ocorreu de forma progressiva e com meta explícita de evoluir para processamento sem intervenção humana, mantido em piloto com medições controladas e aguardando consolidação antes de novos recortes. Essa governança evitou expansão precipitada e preservou o vínculo entre decisão técnica e evidência operacional, o que é consistente com a lógica de avanço em incrementos com critérios claros para evoluir a automação sem ampliar risco em períodos de pico.

5.5 Discussão integrativa: da automação ao aprimoramento na trajetória de implementação

A trajetória do projeto evidenciou que os resultados não se sustentaram apenas pela capacidade técnica da plataforma, mas pelo modo como a organização passou a tratar a Inteligência Artificial como parte de um arranjo sociotécnico. Nas fases iniciais, prevaleceu uma expectativa de automação como entrega concluída, isto é, a suposição de que a extração e a validação automáticas, uma vez configuradas, seriam suficientes para estabilizar o fluxo mesmo sob pressão de volume e prazo. Na prática, essa leitura produziu dois efeitos

operacionais relevantes. O primeiro foi a subestimação do esforço de preparação do sistema, já que o desempenho depende de padrões, exemplos e regras explicitadas por pessoas, além de disciplina de registro e critérios compartilhados sobre o que é esperado em cada exceção. O segundo efeito foi a ampliação de fricções organizacionais quando as primeiras entregas não corresponderam à promessa percebida de automação total, o que tende a reduzir a qualidade do retorno operacional e aumentar o ruído de comunicação, especialmente quando erros deixam de ser reportados com precisão por baixa confiança, insegurança e receios difusos sobre substituição do trabalho humano. Nesses termos, eventuais falhas iniciais não se explicam como limitação abstrata da tecnologia, mas como inadequação temporária de incentivos, rotinas e mecanismos de aprendizagem para um sistema que melhora a partir de *feedback* estruturado.

A consolidação do projeto tornou-se visível quando o esforço deixou de ser conduzido como automação total e passou a ser conduzido como aprimoramento incremental do fluxo, com metas técnicas e organizacionais compatíveis com o tempo de aprendizagem necessário para estabilizar padrões. Essa transição pode ser descrita por um intervalo temporal claro: o piloto teve início em outubro de 2024, a entrada em produção com revisão humana ocorreu em fevereiro de 2025 e a ampliação de escopo avançou a partir de junho de 2025. Nesse encadeamento, o papel da revisão humana não aparece como retrocesso, mas como mecanismo de controle e estabilização, já que ao concentrar a intervenção em exceções relevantes, o processo cria condições para reduzir retrabalho recorrente, acelerar ajustes de regras e ampliar previsibilidade justamente onde a compressão do fechamento aumenta o custo de qualquer reprocessamento tardio.

Os resultados quantitativos reforçam essa leitura ao indicarem não apenas uma aceleração pontual, mas uma mudança de regime operacional no recorte estabilizado. Conforme sintetizado na Tabela 2, observou-se redução de 50% no tempo médio de processamento na etapa com revisão humana, sinalizando que parte expressiva do tempo anteriormente consumido por conferências repetitivas foi absorvida por validações antecipadas, regras mais estáveis e melhor direcionamento dos casos ambíguos. Em termos de fluidez, 91% das ordens passaram a ser concluídas em até cinco minutos na fila da plataforma, o que indica concentração do processamento em uma janela curta e previsível, condição crítica em contextos de pico. A acurácia global de 99% reforça o mesmo argumento ao sinalizar taxa residual de erro no recorte estabilizado, reposicionando o esforço humano para exceções substantivas, desempate de casos ambíguos e retroalimentação qualificada do sistema, em vez de correções repetidas por ruído de leitura, rigidez de regra ou desalinhamento de critérios. Assim, os indicadores finais conectam resultado e condução, dado que o salto de desempenho ocorreu quando a organização

passou a operar a IA como parte do trabalho, com aprendizagem orientada por *feedback* estruturado, refinamento contínuo de regras e tolerâncias e governança suficiente para sustentar previsibilidade e controle no cenário em que a pressão temporal torna o processo mais vulnerável.


Tabela 2 – Síntese dos indicadores de desempenho no recorte estabilizado do processo

Indicador	Resultado	Etapa/recorte de referência	Interpretação para a discussão
Tempo médio de processamento	Redução de 50%	Etapa com revisão humana, no recorte estabilizado	Indica mudança de regime: menos tempo gasto em conferências repetitivas e maior estabilidade de decisão
Fluidez do processamento	91% das ordens concluídas em até 5 minutos	Fila da plataforma, no recorte estabilizado	Mostra concentração do trabalho em janela curta e previsível, essencial sob pressão de fechamento
Acurácia global	99%	Recorte estabilizado	Sugere taxa residual de erro e reposiciona o humano para exceções substantivas e casos ambíguos

Fonte: Elaborado pela autora (2026)

Para integrar visualmente as evidências apresentadas nas Seções 5.1 a 5.4, a Figura 7 consolida, em um único fluxo, os principais marcos da implementação e as decisões associadas a cada fase, evidenciando a passagem de uma lógica de automação como fim para uma lógica de aprimoramento incremental e governado.

Figura 7 - Síntese da trajetória de implementação do sistema de IA (Fases 5.1 a 5.4)



Fonte: Elaborado pela autora (2026).

6 CONSIDERAÇÕES FINAIS

A literatura analisada ao longo deste trabalho apresentou a adoção da Inteligência Artificial no contexto organizacional como um processo marcado por tensões entre automação e aprimoramento do trabalho humano, frequentemente associado à promessa de ganhos de eficiência, redução de custos operacionais e reconfiguração das atividades profissionais. Autores clássicos e contemporâneos convergem ao indicar que os efeitos da IA não decorrem exclusivamente da tecnologia em si, mas do modo como ela é integrada aos processos, às rotinas decisórias e às estruturas de governança das organizações, especialmente em ambientes caracterizados por variabilidade, pressão temporal e risco operacional elevado.

O estudo de caso analisado confirma parcialmente essas proposições teóricas, ao evidenciar que a implementação de soluções baseadas em IA, quando orientada por expectativas de automação plena e imediata, tende a produzir desalinhamentos entre desempenho esperado e desempenho efetivo, além de tensionar a relação entre usuários humanos e o sistema. Esse achado dialoga com a literatura que aponta a limitação de abordagens centradas exclusivamente na substituição de tarefas, uma vez que processos organizacionais complexos raramente se sustentam apenas por regras estáticas ou modelos totalmente automatizados.

Ao mesmo tempo, os resultados empíricos permitem avançar na compreensão do fenômeno ao demonstrar que a estabilização do processo ocorreu quando a IA passou a ser operada como mecanismo de aprimoramento incremental, e não como solução finalizada. A incorporação de revisão humana estruturada por exceções, associada à rastreabilidade das decisões e à retroalimentação contínua do sistema, configurou um arranjo no qual a automação deixou de ser um objetivo em si e passou a emergir como consequência do aprendizado acumulado. No recorte estabilizado do processo, essa mudança se materializou em indicadores operacionais consistentes, com redução de 50% no tempo médio de processamento, concentração do fluxo em uma janela curta e previsível, na qual 91% das ordens foram concluídas em até cinco minutos, e acurácia global de 99%, sinalizando taxa residual de erro e reposicionamento do esforço humano para exceções substantivas e casos ambíguos. Esse movimento aproxima-se da concepção segundo a qual o valor organizacional da IA reside na interação contínua entre humanos e máquinas, e não na eliminação completa da intervenção humana.

Nesse sentido, a evidência empírica observada encontra respaldo em formulações teóricas que alertam para os riscos de uma oposição rígida entre automação e aprimoramento.

Raisch e Krakowski (2021) destacam que “a ênfase excessiva tanto no aprimoramento quanto na automação alimenta ciclos autorreforçadores com efeitos organizacionais e sociais negativos” (Raisch; Krakowski, 2021, p. 2, tradução nossa).³³ No caso analisado, a supervalorização inicial da automação contribuiu para fricções operacionais e expectativas irreais, enquanto a reorientação para um modelo híbrido, apoiado em aprendizagem contínua, favoreceu maior previsibilidade e controle do processo.

Os resultados também reforçam a importância da confiança como elemento mediador da integração entre IA e trabalho humano. A literatura sugere que a confiança não se constrói apenas pela performance técnica do sistema, mas pela clareza de seus limites, pela previsibilidade de seu comportamento e pela possibilidade de intervenção humana em situações ambíguas. Esse aspecto mostrou-se central no caso estudado, em que a consolidação do uso da IA esteve diretamente associada à capacidade da organização de tornar visíveis os critérios de decisão, registrar exceções e transformar erros em insumos para melhoria, reduzindo o retrabalho e o ruído operacional ao longo do tempo.

Do ponto de vista analítico, o estudo contribui ao demonstrar que a principal mudança não ocorreu apenas nos indicadores de eficiência, mas no próprio regime de funcionamento do processo. A redistribuição do esforço humano, antes concentrado em tarefas repetitivas e corretivas, passou a se orientar para atividades de maior valor analítico, como o tratamento de exceções, a validação de casos ambíguos e o refinamento progressivo das regras do sistema. Essa evidência dialoga com abordagens que defendem a IA como instrumento de ampliação das capacidades humanas, e não apenas como mecanismo de substituição, conforme sugerido por Daugherty e Wilson (2018) ao afirmarem que “as tecnologias de IA podem ser utilizadas para aprimorar as capacidades humanas, em vez de substituí-las” (Daugherty; Wilson, 2018, p. 9, tradução nossa).³⁴

A partir dessa articulação entre teoria e evidência empírica, este trabalho sustenta que o dilema entre automação e aprimoramento deve ser compreendido como uma escolha de projeto organizacional, e não como uma decisão puramente técnica. A forma como a IA é enquadrada, comunicada e governada condiciona não apenas seus resultados operacionais, mas também a adesão dos usuários, a qualidade do *feedback* e a sustentabilidade dos ganhos ao longo do tempo. Em processos críticos, marcados por elevada variabilidade documental e pressão por

³³ “overemphasizing either augmentation or automation fuels self-reinforcing cycles with negative organizational and societal outcomes”.

³⁴ “AI technologies can be used to enhance human capabilities rather than replace them”.

fechamento, a adoção de modelos híbridos, com automação seletiva e intervenção humana estruturada, mostrou-se mais consistente do que tentativas de automação total.

Como limitação, reconhece-se que o estudo se baseia em um único caso, porém, ainda assim, a análise oferece evidências relevantes sobre os mecanismos pelos quais a IA pode ser integrada de forma mais robusta a processos organizacionais complexos, abrindo espaço para investigações futuras que explorem comparativamente diferentes desenhos de governança, níveis de transparência e estratégias de escalonamento da automação.

Em síntese, a principal contribuição deste trabalho reside em demonstrar que o sucesso da IA em contextos corporativos não depende apenas de sua capacidade técnica, mas da forma como ela é incorporada ao trabalho real. Ao evidenciar que a automação emerge de processos de aprimoramento contínuo, e não o contrário, o estudo reforça a necessidade de abordagens críticas e realistas, capazes de alinhar tecnologia, organização e trabalho humano em trajetórias de aprendizado sustentáveis.

REFERÊNCIAS BIBLIOGRÁFICAS

BORGES, Aline de Fátima Soares. **Uso estratégico da inteligência artificial nas organizações**. 2023. 218 f. Tese (Doutorado) - Curso de Engenharia de Produção, Departamento de Engenharia de Produção, Escola Politécnica, Universidade de São Paulo, São Paulo, 2023. Disponível em: <https://doi.org/10.11606/T.3.2023.tde-12092023-074354>. Acesso em: 14 dez. 2025.

BRYNJOLFSSON, Erik; MCAFEE, Andrew. **The second machine age: work, progress, and prosperity in a time of brilliant technologies**. New York: W. W Norton, 2016. 336 p.

DAUGHERTY, Paul R.; WILSON, H. James. **Human + Machine: reimagining work in the age of ai**. Boston: Harvard Business Review Press, 2018. 264 p.

DAVENPORT, Thomas H.; KIRBY, Julia. **Only Humans Need Apply: winners and losers in the age of smart machines**. [S.L.]: Harper Business, 2016. 288 p.

ENHOLM, Ida Merete; PAPAGIANNIDIS, Emmanouil; MIKALEF, Patrick; KROGSTIE, John. Artificial Intelligence and Business Value: a literature review. **Information Systems Frontiers**, [S.L.], v. 24, n. 5, p. 1709-1734, 25 ago. 2021. Disponível em: <https://doi.org/10.1007/s10796-021-10186-w>. Acesso em: 23 dez. 2025.

GLIKSON, Ella; WOOLLEY, Anita Williams. Human Trust in Artificial Intelligence: review of empirical research. **Academy Of Management Annals**, [S.L.], v. 14, n. 2, p. 627-660, jul. 2020. Disponível em: <https://doi.org/10.5465/annals.2018.0057>. Acesso em: 27 dez. 2025.

HOLLWECK, Trista. Obert K. Yin. (2014). Case Study Research Design and Methods (5th ed.). **Canadian Journal Of Program Evaluation**, [S.L.], v. 30, n. 1, p. 108-110, mar. 2015. Disponível em: <https://doi.org/10.3138/cjpe.30.1.108>. Acesso em: 5 jan. 2026.

KELLY, Sage; KAYE, Sherrie-Anne; OVIEDO-TRESPALACIOS, Oscar. What factors contribute to the acceptance of artificial intelligence? A systematic review. **Telematics And Informatics**, [S.L.], v. 77, p. 101925, fev. 2023. Disponível em: <https://doi.org/10.1016/j.tele.2022.101925>. Acesso em: 27 dez. 2025.

KUBOTA, Luis Claudio (org.). **Digitalização e tecnologias da informação e comunicação: oportunidades e desafios para o brasil**. Rio de Janeiro: Instituto de Pesquisa Econômica Aplicada (Ipea), 2024. 441 p. Disponível em: <https://repositorio.ipea.gov.br/server/api/core/bitstreams/57e5ff82-4649-430c-9f05-bb9e9250290e/content>. Acesso em: 19 dez. 2025.

MCCARTHY, John et al. **A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence**. Hanover: Dartmouth College, 1955. 13 p. 27 v. Disponível em: <http://jmc.stanford.edu/articles/dartmouth/dartmouth.pdf>. Acesso em: 7 jan. 2026.

MIKALEF, Patrick; GUPTA, Manjul. **Artificial intelligence capability**: conceptualization, measurement calibration, and empirical study on its impact on organizational creativity and firm performance. *Information & Management*, [S.L.], v. 58, n. 3, p. 103434, abr. 2021. Disponível em: <https://doi.org/10.1016/j.im.2021.103434>. Acesso em: 23 dez. 2025.

NÚCLEO DE INFORMAÇÃO E COORDENAÇÃO DO PONTO BR (NIC.BR) (ed.). **TIC Empresas**: pesquisa sobre o uso das tecnologias de informação e comunicação nas empresas brasileiras 2024. São Paulo: Grappa Marketing Editorial, 2025. 136 p. Disponível em: https://Nic.br/media/docs/publicacoes/2/20250512122204/tic_empresas_2024_livro_eletronico.pdf. Acesso em: 17 dez. 2025.

ORGANISATION FOR ECONOMIC CO-OPERATION AND DEVELOPMENT (OECD). **Explanatory memorandum on the updated OECD definition of an AI system**. Paris: Oecd Publishing, 2024. Disponível em: <https://www.oecd.org/content/dam/oecd/en/publications/reports/2024/03/explanatory-memorandum-on-the->. Acesso em: 23 dez. 2025.

PRODANOV, Cleber Cristiano; FREITAS, Ernani Cesar de. **Metodologia do trabalho científico**: métodos e técnicas da pesquisa e do trabalho acadêmico. 2. ed. Novo Hamburgo: Feevale, 2013. 277 p. Disponível em: <https://www.feevale.br/Comum/midias/0163c988-1f5d-496f-b118-a6e009a7a2f9/E-book%20Metodologia%20do%20Trabalho%20Cientifico.pdf>. Acesso em: 5 jan. 2026.

RAISCH, Sebastian; KRAKOWSKI, Sebastian. Artificial Intelligence and Management: the automation-augmentation paradox. *Academy Of Management Review*, [S.L.], v. 46, n. 1, p. 192-210, jan. 2021. Disponível em: <https://doi.org/10.5465/amr.2018.0072>. Acesso em: 27 dez. 2025.

ROCHA, Isabela F.; KISSIMOTO, Kumiko O. Barreiras e benefícios na adoção de inteligência artificial e IoT na gestão da operação. **Ram. Revista de Administração Mackenzie**, [S.L.], v. 23, n. 4, p. 2-32, out. 2022. Disponível em: <https://doi.org/10.1590/1678-6971/eRAMR220119.pt>. Acesso em: 23 dez. 2025.

STANFORD HAI. **AI Index Report 2025**. Stanford: Stanford Institute For Human-Centered Artificial Intelligence (HAI), 2025. 457 p. Disponível em: <https://hai.stanford.edu/ai-index/2025-ai-index-report>. Acesso em: 17 dez. 2025.

DECLARAÇÃO DE ORIGINALIDADE E RESPONSABILIDADE

Eu, Julia Pereira Bonilho, declaro que este Trabalho de Conclusão de Curso (Monografia) foi elaborado em conformidade com as exigências do Regulamento do Curso de Engenharia de Produção da Escola de Minas da Universidade Federal de Ouro Preto e que não foi submetido a nenhum outro prêmio acadêmico. Exceto quando indicado por referência específica, este texto é de minha autoria, sendo as opiniões nele expressas de minha única e exclusiva responsabilidade. Recursos tecnológicos, incluindo ferramentas de inteligência artificial, caso tenham sido utilizados, tiveram único fim suporte técnico, sem comprometer a autoria e a integridade intelectual do trabalho.

Ouro Preto – MG, 26 de Fevereiro de 2026