

EXPANDINDO FRONTEIRAS COGNITIVAS: A INTELIGÊNCIA ARTIFICIAL COMO FERRAMENTA DE APOIO À DECISÃO ESTRATÉGICA NAS ORGANIZAÇÕES

Bruno De Luca Piazza

brunopiazza002@gmail.com

Graduando em Administração de Empresas

Wilciney J. Villan

neyvillan@unesc.net

Graduado em Administração de Empresas e Mestre em Desenvolvimento Socioeconômico

Universidade do Extremo Sul Catarinense - UNESC

RESUMO

Este trabalho analisa de que forma o uso da inteligência artificial como suporte à decisão contribui para aprimorar a alocação de recursos estratégicos ou para comprometer a autonomia decisória em pequenas e médias empresas. O estudo demonstra que a literacia algorítmica do gestor é o fator determinante entre o uso da inteligência artificial como amplificador de capacidades ou como vetor de dependência organizacional. Para isso, conduziu-se uma revisão sistemática da literatura, com análise qualitativa aprofundada de oito artigos científicos publicados entre 2024 e 2026, selecionados por meio de protocolo estruturado na base Web of Science. Os resultados revelam uma dualidade central: de um lado, sistemas de inteligência artificial preditiva e generativa ampliam a capacidade analítica dos gestores, expandindo os limites da racionalidade limitada e gerando capacidades dinâmicas que compensam desvantagens estruturais das PMEs; de outro, a adoção desbalanceada da tecnologia produz heteronomia algorítmica, dependência de trajetória e descarga cognitiva, fenômenos que comprometem progressivamente a autonomia decisória e atrofiam as competências estratégicas internas. A síntese das evidências orienta o desenvolvimento de um modelo conceitual integrativo estruturado em três camadas interdependentes de *inputs*, processos e *outputs*, que representa o funcionamento sistêmico da decisão mediada pela inteligência artificial. Conclui-se que os efeitos da tecnologia são determinados não por suas características técnicas, mas pelo modelo de governança que orienta sua adoção.

Palavras-chave: Inteligência Artificial. Tomada de Decisão Estratégica. Racionalidade Limitada. Autonomia Decisória. Pequenas e Médias Empresas.

1 INTRODUÇÃO

Com o avanço da tecnologia, a tomada de decisão passou a ser cada vez mais apoiada por sistemas de informação e ferramentas computacionais. Como aponta Simon (1979), o princípio da racionalidade limitada, que se refere às restrições cognitivas que limitam o processamento de toda a informação disponível para encontrar a solução ótima, leva à necessidade de instrumentos que auxiliem na coleta, processamento e análise de dados, possibilitando escolhas mais consistentes diante de ambientes dinâmicos. Assim, o uso de tecnologias da informação oferece suporte não apenas para decisões operacionais, mas também para aquelas de caráter estratégico, permitindo a integração de dados, previsões e cenários que aumentam a precisão das escolhas organizacionais.

A tomada de decisão estratégica pode ser entendida como o processo de escolha de ações que afetam diretamente a posição competitiva da organização em longo prazo. Esse

processo envolve lidar com cenários incertos e complexos, demandando a capacidade de interpretar sinais do ambiente, avaliar alternativas e formular cursos de ação que assegurem a sustentabilidade organizacional (Maitlis; Christianson, 2014). Em síntese, a qualidade das decisões estratégicas influencia diretamente a capacidade da empresa de se adaptar, inovar e manter sua competitividade no mercado.

Nesse contexto de transformação digital, a Inteligência Artificial (IA) emerge como uma das tecnologias mais disruptivas e estratégicas. Segundo relatório da International Data Corporation (IDC), os investimentos globais em soluções de IA devem ultrapassar 300 bilhões de dólares até 2026, crescendo a uma taxa anual de 26,5% (IDC, 2023). Esse cenário demonstra não apenas a relevância econômica da tecnologia, mas também sua crescente incorporação em diferentes setores, incluindo finanças, saúde, varejo, educação e, especialmente, a administração de empresas (Santos; Jorge; Winkler, 2021). Um marco específico delimita esse processo: o lançamento do *ChatGPT* pela *OpenAI*, em novembro de 2022 (Aydin; Karaarslan, 2022), democratizou o acesso à IA generativa e colocou pela primeira vez gestores de PMEs diante de ferramentas antes restritas a grandes corporações, tornando urgente compreender os efeitos dessa ruptura sobre a autonomia decisória nesse segmento.

Esse movimento de adoção é uma realidade concreta. O cenário competitivo global em 2024 é marcado por um dinamismo notável, evidenciado por alianças estratégicas de alto investimento, como as parcerias da Microsoft com a OpenAI e da Amazon com a Anthropic (Gernone; Teece, 2024). Concorrentemente, empresas de tecnologia como a Apple têm recrutado ativamente dezenas de especialistas em IA de rivais como o Google para reorientar suas estratégias, e companhias de bens de consumo, como a PepsiCo, planejam expandir seus laboratórios de IA (Gernone; Teece, 2024).

Contudo, à medida que a IA se integra aos processos gerenciais, emergem questionamentos sobre seus efeitos reais na racionalidade, na ética e na autonomia das decisões estratégicas.

Embora existam evidências de que a adoção de ferramentas inteligentes contribui para a melhoria da eficiência operacional e para a satisfação do cliente (Aguiar-Costa et al., 2022), permanecem lacunas quanto ao entendimento de seus impactos na tomada de decisão estratégica, sobretudo no que se refere à transparência, à *explicabilidade* dos modelos e à responsabilidade ética de seu uso (Floridi et al., 2018).

Esta pesquisa concentra-se na aplicação da Inteligência Artificial em decisões estratégicas de nível organizacional, envolvendo especialmente gestores e equipes executivas que utilizam sistemas de apoio à decisão baseados em aprendizado de máquina. Tal delimitação permite analisar como a IA influencia o processo de formulação, análise e escolha de alternativas estratégicas em ambientes corporativos complexos.

Dessa forma, a situação-problema que orienta esta pesquisa decorre da tensão entre o potencial analítico da IA e os limites da racionalidade humana, especialmente quando decisões estratégicas envolvem ambiguidade, riscos éticos e múltiplos stakeholders.

Apesar do crescente interesse sobre IA aplicada à gestão, é importante realizar uma revisão sistemática da literatura que integrem suas implicações cognitivas, éticas e estratégicas na tomada de decisão empresarial.

Essa lacuna é particularmente relevante em um contexto no qual a racionalidade gerencial passa a depender crescentemente de sistemas de IA, exigindo uma nova compreensão sobre o papel do julgamento humano na formulação estratégica (Simon, 1979; Berente et al., 2021).

Diante desse contexto, surge a seguinte questão de pesquisa: De que forma o uso de IA como suporte à decisão contribui para aprimorar a alocação de recursos estratégicos ou comprometer a autonomia decisória em pequenas e médias empresas?

O objetivo geral deste trabalho é analisar de que forma o uso da inteligência artificial como suporte à decisão contribui para aprimorar a alocação de recursos estratégicos ou para comprometer a autonomia decisória em pequenas e médias empresas. Como objetivos específicos, busca-se: (i) identificar os efeitos da IA sobre a alocação de recursos estratégicos em PMEs, documentando os ganhos analíticos observados na literatura; (ii) avaliar os riscos associados à perda de autonomia decisória decorrentes da adoção desbalanceada de sistemas de IA; (iii) analisar o fenômeno da descarga cognitiva e seus desdobramentos sobre a qualidade do julgamento gerencial em contextos de uso intensivo de IA generativa; (iv) propor um modelo conceitual integrativo que represente o funcionamento sistêmico da decisão estratégica mediada pela IA em PMEs.

Para atingir tais objetivos, foi conduzida uma revisão sistemática da literatura, que permitiu mapear e integrar as evidências teóricas e empíricas disponíveis sobre o tema.

A relevância desta pesquisa está em contribuir para o avanço teórico e prático da administração contemporânea. Para gestores e profissionais, a análise fornece subsídios sobre as melhores práticas de adoção da IA em processos decisórios, apoiando a busca por maior eficiência e competitividade. Essas contribuições têm implicações diretas para a formulação de políticas corporativas de governança algorítmica, desenho de estratégias baseadas em dados e desenvolvimento de competências gerenciais voltadas à interpretação crítica de resultados produzidos por sistemas de IA. Para o campo acadêmico, o estudo amplia o debate sobre a integração de tecnologias emergentes na gestão, especialmente em relação às tensões entre inovação, ética e responsabilidade social (Félix et al., 2024).

A oportunidade desta pesquisa reside no atual momento de difusão acelerada de soluções de IA generativa no ambiente corporativo, o que torna urgente compreender seus efeitos sobre a racionalidade e a responsabilidade nas decisões estratégicas.

Este estudo está estruturado em cinco seções, além desta introdução. A segunda seção apresenta a fundamentação teórica, abordando os conceitos de Inteligência Artificial, sua evolução e os principais debates sobre seu papel na tomada de decisão estratégica. A terceira seção descreve os procedimentos metodológicos, detalhando o delineamento da revisão sistemática da literatura. A quarta seção apresenta e discute os resultados obtidos, com base na análise das evidências teóricas e empíricas. Por fim, a quinta seção reúne as conclusões do estudo, destacando as contribuições, limitações e oportunidades para futuras pesquisas.

2 REFERENCIAL TEÓRICO

Este capítulo apresenta as bases teóricas que sustentam a pesquisa, organizando-se em torno da intersecção entre tecnologia e gestão estratégica. Na primeira seção, aborda-se a evolução conceitual da Inteligência Artificial, partindo de seus fundamentos históricos até as configurações atuais da IA Generativa e seus desafios éticos e cognitivos. Na segunda seção, examina-se a natureza da tomada de decisão estratégica, fundamentada na teoria da racionalidade limitada e na complexidade inerente ao ambiente organizacional. Na terceira seção, integram-se esses domínios para analisar como a adoção da IA pode ampliar a capacidade decisória dos gestores no contexto das Pequenas e Médias Empresas. Por fim, a quarta seção apresenta o modelo conceitual integrativo que sintetiza as contribuições teóricas identificadas. Cada seção apoia e prepara a seguinte, de modo que o referencial converge progressivamente para o modelo integrador proposto ao final do capítulo, refletindo uma construção articulada e não uma simples compilação de conceitos isolados.

2.1 INTELIGÊNCIA ARTIFICIAL: CONCEITOS, EVOLUÇÃO E DESAFIOS ATUAIS

A Inteligência Artificial (IA) consolidou-se como um campo tecnológico e científico que tem redefinido processos em múltiplos setores da sociedade e na administração de empresas (Berente *et al.*, 2021). Sua definição permanece um desafio, em função da natureza dinâmica e da expansão contínua de suas fronteiras. De modo abrangente, a IA pode ser entendida como a capacidade de máquinas ou programas de computador imitarem o raciocínio e o comportamento humano para realizar tarefas de forma autônoma (Berente *et al.*, 2021). Isso inclui a habilidade de interpretar dados externos, aprender a partir deles e utilizar esses aprendizados para alcançar objetivos específicos por meio de adaptação (Kaplan; Haenlein, 2019). Essa fluidez conceitual é acentuada pelo chamado "efeito IA", fenômeno pelo qual tecnologias de IA, ao se tornarem amplamente adotadas e compreendidas, deixam de ser percebidas como "inteligência" para serem tratadas como ferramentas computacionais (Haenlein; Kaplan, 2019). A IA não constitui uma tecnologia singular, mas um conjunto de abordagens e técnicas que evoluem de modo contínuo, buscando emular ou superar capacidades cognitivas humanas em domínios progressivamente mais complexos (Berente *et al.*, 2021).

Embora a busca por replicar a inteligência em máquinas tenha raízes filosóficas e matemáticas antigas, o nascimento formal da IA como disciplina acadêmica situa-se em meados do século XX. O trabalho de Alan Turing sobre a computabilidade e sua proposta do "Teste de Turing" (Turing, 1950) forneceram um arcabouço conceitual inicial, ao questionar se máquinas poderiam exibir comportamento inteligente indistinguível do humano (Sobreira, 2025). A expressão "Inteligência Artificial" foi cunhada em 1956, na Conferência de Dartmouth, evento que reuniu pesquisadores da área e estabeleceu a agenda inicial do campo, centrada na simulação de capacidades cognitivas como raciocínio, linguagem e aprendizado (McCarthy *et al.*, 1955 apud Berente *et al.*, 2021; Sobreira, 2025; Haenlein; Kaplan, 2019). As primeiras décadas foram marcadas pela abordagem da IA Simbólica, também conhecida como *Good Old-Fashioned AI* (GOFAI), que buscava representar o conhecimento e o raciocínio por meio de regras lógicas e manipulação de símbolos (Berente *et al.*, 2021). Essa vertente conduziu ao desenvolvimento dos Sistemas Especialistas nas décadas de 1970 e 1980, que obtiveram resultados positivos em domínios delimitados, como diagnóstico médico e análise química, mas revelaram limitações para lidar com a complexidade, a incerteza, o aprendizado a partir da experiência e o conhecimento tácito (Berente *et al.*, 2021).

As limitações da abordagem simbólica impulsionaram o desenvolvimento da IA Conexionista, inspirada na estrutura neuronal do cérebro humano. Essa abordagem utiliza Redes Neurais Artificiais (RNAs), compostas por unidades de processamento interconectadas que aprendem padrões diretamente dos dados, ajustando a força de suas conexões por meio da experiência (Sobreira, 2025). As ideias conexionistas existiam desde os anos 1940 e 1950, mas limitações computacionais e teóricas restringiram seu desenvolvimento até as últimas décadas do século XX (Sobreira, 2025). O potencial do conexionismo foi ampliado com a popularização do Aprendizado de Máquina (*Machine Learning*, ML), subcampo da IA que se concentra na criação de algoritmos capazes de aprender a partir de dados, sem programação explícita para cada tarefa (Duque-Pereira; Moura, 2023). Em vez de seguir regras fixas, os sistemas de ML identificam padrões nos dados de treinamento e os utilizam para realizar previsões ou tomar decisões sobre novos dados. As principais abordagens do ML são:

- a) Aprendizado Supervisionado: o modelo aprende a mapear entradas para saídas com base em pares de exemplos rotulados. É aplicado em tarefas como classificação e regressão (Géron, 2019);
- b) Aprendizado Não Supervisionado: o modelo busca identificar estruturas ou padrões em dados não rotulados, por meio de técnicas como *clustering* e redução de dimensionalidade (Géron, 2019);

- c) Aprendizado por Reforço: o modelo aprende a tomar sequências de decisões interagindo com um ambiente e recebendo recompensas ou penalizações por suas ações, sendo aplicado em robótica, jogos e sistemas de controle (Géron, 2019).

O Aprendizado Profundo (*Deep Learning*, DL) representa uma evolução do ML, caracterizada pelo uso de RNAs com múltiplas camadas ocultas. Essas camadas permitem que o modelo aprenda representações de dados em níveis crescentes de abstração, capturando padrões hierárquicos (LeCun; Bengio; Hinton, 2015). Arquiteturas comuns de DL incluem as Redes Neurais Convolucionais (CNNs), utilizadas no processamento de imagens, e as Redes Neurais Recorrentes (RNNs), adequadas para dados sequenciais. Estas últimas foram progressivamente substituídas por arquiteturas mais recentes em tarefas de linguagem (LeCun; Bengio; Hinton, 2015). A expansão do DL foi viabilizada pela disponibilidade de grandes volumes de dados (*Big Data*) e pelo aumento do poder computacional proporcionado pelas Unidades de Processamento Gráfico (GPUs) (Berente *et al.*, 2021).

No campo do Processamento de Língua Natural (PLN), a arquitetura *Transformer*, introduzida em 2017, representou um avanço relevante (Vaswani *et al.*, 2017). Por meio de mecanismos de auto-atenção que ponderam a relevância de diferentes partes de uma sequência ao processar cada elemento, os *Transformers* demonstraram capacidade de capturar dependências de longo alcance em textos, superando limitações das RNNs (Duque-Pereira; Moura, 2023). Essa arquitetura tornou-se a base para os Grandes Modelos de Linguagem (*Large Language Models*, LLMs) (Jurafsky; Martin, 2024). Modelos como GPT-4, Gemini e Llama são treinados em extensos corpora textuais e apresentam capacidades de compreensão contextual, geração de texto, tradução e sumarização, fundamentando-se em princípios da Semântica Distribucional para representar o significado das palavras a partir de seus contextos de uso (Jurafsky; Martin, 2024).

Esses avanços impulsionaram a Inteligência Artificial Generativa (IA Generativa), que se orienta para a criação de conteúdo novo a partir de padrões aprendidos (Jurafsky; Martin, 2024). Ferramentas baseadas em LLMs, como o ChatGPT, tornaram a IA Generativa acessível ao público por meio de interações em linguagem natural, ampliando o debate sobre seu potencial e seus riscos (Jurafsky; Martin, 2024). Muitos desses sistemas utilizam o Aprendizado por Reforço com Feedback Humano (RLHF) para refinar as respostas geradas e alinhar o comportamento do modelo às expectativas dos usuários (Sobreira, 2025).

A IA contemporânea é caracterizada por três dimensões interconectadas: autonomia, aprendizado e inescrutabilidade (Berente *et al.*, 2021). A autonomia progressiva permite que sistemas de IA tomem decisões com menor supervisão humana. O aprendizado contínuo, alimentado por dados, refina o desempenho e adapta o comportamento desses sistemas. A inescrutabilidade, por sua vez, torna os processos internos de decisão opacos, configurando o problema da caixa-preta (Berente *et al.*, 2021). A busca por IA Explicável (XAI) tornou-se um campo de pesquisa ativo, com o objetivo de desenvolver métodos que tornem as decisões de modelos complexos mais compreensíveis para os usuários (Berente *et al.*, 2021).

A IA também apresenta desafios técnicos e éticos relevantes. O fenômeno das "alucinações" refere-se à geração de informações factualmente incorretas por LLMs, comprometendo sua confiabilidade (Sobreira, 2025). Os vieses presentes nos dados de treinamento podem ser reproduzidos e amplificados pelos modelos, resultando em discriminação algorítmica (Berente *et al.*, 2021). Somam-se a isso questões relacionadas à privacidade dos dados, segurança dos sistemas, direitos autorais e responsabilidade por ações autônomas (Berente *et al.*, 2021).

Nesse cenário, ganha relevância o fenômeno do *cognitive offloading* (descarga cognitiva), que consiste na tendência humana de delegar funções mentais para ferramentas

externas, incluindo sistemas de IA (Gerlich, 2025). Pesquisas recentes indicam correlação negativa entre o uso frequente de ferramentas de IA e a capacidade de pensamento crítico, sendo a descarga cognitiva um fator mediador desse processo (Gerlich, 2025). O acesso facilitado a respostas geradas por IA pode reduzir a prática de processos cognitivos como análise de evidências e raciocínio independente, habilidades necessárias para a tomada de decisão estratégica (Gerlich, 2025). A confiança excessiva nos resultados da IA, amplificada pela capacidade desses sistemas de emular a comunicação humana, pode conduzir à redução da verificação crítica e à atrofia do julgamento analítico ao longo do tempo, representando um desafio para a administração organizacional (Gerlich, 2025; Berente *et al.*, 2021).

2.2 TOMADA DE DECISÃO ESTRATÉGICA

A tomada de decisão constitui o centro da atividade gerencial e administrativa, permeando todos os níveis organizacionais, das operações rotineiras às escolhas que definem a trajetória da empresa (Simon, 1979). No âmbito da administração, a tomada de decisão estratégica assume relevância específica, pois se refere ao processo de selecionar cursos de ação que moldam a posição competitiva da organização a longo prazo, em resposta às condições percebidas no ambiente externo e interno (Maitlis; Christianson, 2014). Essas decisões são, por natureza, não estruturadas, infrequentes e carregadas de incerteza, exigindo dos gestores a capacidade de analisar ambientes dinâmicos, interpretar informações ambíguas e antecipar consequências futuras (Simon, 1979). Diferentemente das decisões operacionais, mais programadas e orientadas para a eficiência de processos existentes, as decisões estratégicas envolvem a adaptação da organização ao ambiente, a alocação de recursos e a definição de objetivos de longo prazo (Eisenhardt; Zbaracki, 1992).

A complexidade da tomada de decisão estratégica decorre de múltiplos fatores. O primeiro é o contexto de incerteza e ambiguidade em que essas decisões ocorrem (Simon, 1979). A informação disponível é frequentemente incompleta, imprecisa ou de difícil interpretação, e a capacidade de prever as consequências futuras das ações é limitada (Simon, 1979). Os gestores operam, portanto, com base em pressupostos e julgamentos, e não em certezas. O segundo fator é a presença de múltiplos objetivos, frequentemente conflitantes e de difícil mensuração, como crescimento de receita versus margem de lucro, inovação de longo prazo versus resultados de curto prazo, ou a satisfação de diferentes partes interessadas, como acionistas, clientes, funcionários e sociedade (Abelson; Levi, 1985).

As decisões estratégicas também se caracterizam por consequências de longo alcance e pelo alto custo de reversão. Um investimento estratégico equivocado ou a incapacidade de adaptação a mudanças ambientais pode comprometer a posição competitiva ou a sobrevivência da organização (Berente *et al.*, 2021). Além disso, o processo decisório estratégico não é puramente analítico: é influenciado por fatores cognitivos, sociais e políticos internos à organização (Eisenhardt; Zbaracki, 1992). As percepções, vieses cognitivos, experiências e modelos mentais dos gestores, bem como a cultura organizacional, as dinâmicas de poder e os processos de negociação, exercem papel relevante na forma como os problemas são definidos, as alternativas são avaliadas e a escolha é realizada (Mintzberg; Raisinghani; Théorêt, 1976).

A teoria clássica da decisão, fundamentada na racionalidade econômica, postulava um *homo economicus* com preferências estáveis e capacidade computacional ilimitada para avaliar todas as alternativas e maximizar a utilidade esperada (Simon, 1979). Herbert Simon (1979) contestou essa premissa ao introduzir o conceito de racionalidade limitada (*bounded rationality*). O autor argumentou que a capacidade cognitiva humana é finita em termos de processamento de informação, memória de curto prazo e atenção seletiva, e que as decisões são tomadas sob restrições de tempo, custo e disponibilidade de informação (Simon, 1979). Diante

dessas limitações, os decisores não buscam a otimização, mas a satisfação, ou seja, a seleção de uma alternativa suficientemente adequada a um nível de aspiração aceitável (Simon, 1979). Para lidar com a complexidade, os decisores constroem modelos simplificados da realidade e recorrem a heurísticas, que são atalhos mentais que permitem decisões rápidas, embora possam produzir erros sistemáticos em determinados contextos (Simon, 1979).

A perspectiva da racionalidade limitada desloca a compreensão da tomada de decisão estratégica de um modelo linear e analítico para um processo iterativo, interpretativo e socialmente construído (Eisenhardt; Zbaracki, 1992). Nesse contexto, o conceito de *sensemaking* (construção de sentido) assume destaque. Conforme Maitlis e Christianson (2014), *sensemaking* é o processo pelo qual indivíduos e grupos atribuem significado a experiências novas, ambíguas ou que violam expectativas. Diante da incerteza estratégica, os gestores constroem interpretações plausíveis sobre o ambiente a partir de pistas selecionadas, de experiências anteriores e de interações sociais (Maitlis; Christianson, 2014). Esse processo é retrospectivo, enativo, social e contínuo, influenciando a definição do problema, as alternativas consideradas e as ações subsequentes (Maitlis; Christianson, 2014).

As heurísticas também tornam os decisores vulneráveis a vieses cognitivos sistemáticos, identificados pela psicologia cognitiva e pela economia comportamental (Kahneman, 2011). Entre os mais relevantes para a estratégia estão: o viés de confirmação, que leva à busca por informações que confirmem crenças preexistentes; o excesso de confiança, que resulta na superestimação da precisão dos próprios julgamentos; o viés de ancoragem, que induz a dependência excessiva da primeira informação disponível; a falácia do custo irrecuperável, que leva à continuidade de investimentos em projetos com resultados desfavoráveis; o pensamento de grupo, que privilegia o consenso em detrimento da avaliação crítica; e a aversão à perda, que torna as perdas cognitivamente mais pesadas do que ganhos equivalentes (Kahneman, 2011). A implementação de mecanismos para mitigar esses vieses, como a busca ativa por informações discordantes, contribui para a melhoria da qualidade das decisões estratégicas (Kahneman, 2011).

A Visão Baseada em Recursos (*Resource-Based View*, RBV) reforça a relevância das decisões estratégicas para a competitividade organizacional. Essa teoria argumenta que a vantagem competitiva sustentável não reside no posicionamento de mercado, mas nos recursos e capacidades internas da organização que sejam valiosos, raros, de difícil imitação e sem substitutos estratégicos perfeitos (Barney, 1991). Nesse quadro, a tomada de decisão estratégica envolve a identificação, o desenvolvimento, a proteção e a alocação desses recursos. A capacidade da alta administração de perceber oportunidades, reconfigurar ativos e adaptar-se às mudanças ambientais é considerada determinante para o desempenho de longo prazo (Teece; Pisano; Shuen, 1997).

Historicamente, as organizações recorreram a diversas ferramentas para superar as limitações da racionalidade limitada e apoiar o processo decisório estratégico. A evolução dos sistemas de informação, dos Sistemas de Informação Gerencial (SIG) para os Sistemas de Apoio à Decisão (SAD) e, posteriormente, para as plataformas de *Business Intelligence* (BI) e *Analytics*, reflete essa busca por suporte informacional e analítico (Santos; Jorge; Winkler, 2021). Essas tecnologias ampliam a capacidade cognitiva dos gestores ao fornecer acesso a volumes maiores de dados, ferramentas para identificação de padrões, modelos de simulação de cenários e instrumentos de monitoramento de desempenho (Duan *et al.*, 2019). Ao estruturar informações e automatizar determinadas análises, essas ferramentas contribuem para a redução da carga cognitiva e para uma avaliação mais sistemática das alternativas (Berente *et al.*, 2021). Entretanto, mesmo as ferramentas analíticas mais desenvolvidas não eliminam a necessidade de julgamento humano no processo estratégico. A formulação do problema, a avaliação de fatores qualitativos, a negociação entre partes interessadas e a liderança na implementação da decisão permanecem como responsabilidades gerenciais (Jarrahi, 2018).

2.3 INTELIGÊNCIA ARTIFICIAL NA TOMADA DE DECISÃO ESTRATÉGICA NO CONTEXTO DAS PMES

As decisões estratégicas de nível organizacional são, por natureza, ambíguas, infrequentes e marcadas por incerteza (Mintzberg; Raisinghani; Théorêt, 1976). Diante desse contexto, os gestores não se limitam a processar informações objetivas, construindo ativamente uma interpretação plausível do ambiente para orientar a ação, em um processo de construção de sentido (*sensemaking*, conforme discutido na seção anterior). Esse processo interpretativo esbarra nas restrições cognitivas documentadas pela teoria da racionalidade limitada, que postula que o decisor não busca a solução ótima, mas uma alternativa satisfatória, dadas as limitações de tempo, informação e capacidade de processamento (Simon, 1979).

Em contraposição à premissa normativa do *homo economicus*, dotado de capacidade computacional ilimitada para avaliar todas as alternativas disponíveis (Kahneman, 2011), a teoria da racionalidade limitada descreve um decisor sujeito a restrições cognitivas e de memória que impedem o processamento simultâneo de todas as variáveis de um ambiente organizacional dinâmico (Simon, 1979). Para lidar com essa sobrecarga informacional, a mente humana recorre a heurísticas, regras práticas que reduzem a complexidade do julgamento probabilístico (Kahneman, 2011). O uso contínuo dessas heurísticas em contextos organizacionais expõe os decisores a vieses cognitivos que podem comprometer a qualidade das escolhas e produzir ineficiências na alocação de recursos (Abelson; Levi, 1985; Barney, 1991).

A introdução da IA no ambiente organizacional apresenta-se como um mecanismo de apoio às limitações cognitivas descritas (Duan *et al.*, 2019). A arquitetura computacional da IA permite o processamento de volumes de dados em larga escala e a identificação de correlações em conjuntos de informações não estruturadas (Santos *et al.*, 2022). O uso de algoritmos preditivos viabiliza a simulação de cenários com base na projeção de variáveis quantitativas (Haenlein; Kaplan, 2019), reduzindo a dependência de atalhos heurísticos nas fases de diagnóstico e de formulação de estratégias (Duan *et al.*, 2019). A literatura de gestão da tecnologia indica, entretanto, que a integração de sistemas computacionais não pressupõe a exclusão do decisor humano do processo organizacional (Jarrahi, 2018).

O modelo de configuração indicado para a gestão em ambientes de negócios instáveis consiste na colaboração entre humanos e sistemas de IA (Jarrahi, 2018). Nesse formato, a tecnologia executa o mapeamento analítico, a correlação de bases de dados e o cálculo de probabilidades, enquanto a capacidade cognitiva do gestor é redirecionada para a interpretação de variáveis de natureza qualitativa (Paschen *et al.*, 2020). A função humana no processo decisório mantém a responsabilidade pelo julgamento ético, pela negociação entre partes interessadas e pela gestão de informações que não se prestam à codificação algorítmica (Paschen *et al.*, 2020). A combinação entre o processamento matemático do algoritmo e a análise interpretativa do gestor resulta em um arranjo de inteligência híbrida que busca aumentar a precisão analítica no planejamento estratégico (Jarrahi, 2018; Duan *et al.*, 2019).

A integração da IA no formato de ampliação cognitiva requer o desenvolvimento de protocolos de acompanhamento contínuo pelos envolvidos (Berente *et al.*, 2021). A pressão organizacional por redução de custos e de tempo, entretanto, gera conflitos metodológicos categorizados por Raisch e Krakowski (2021) como o paradoxo da automação versus ampliação cognitiva. O direcionamento exclusivo para a automação induz a substituição do julgamento humano por fluxos de execução algorítmica, promovendo a atrofia das competências analíticas da equipe e reduzindo a capacidade da empresa de formular inovações ou de responder a mudanças no mercado (Raisch; Krakowski, 2021).

A delegação de etapas de raciocínio à máquina caracteriza o *cognitive offloading* (Bastone *et al.*, 2025). O uso de ferramentas de IA generativa, ao fornecer respostas estruturadas, tende a inibir a formulação independente de soluções pelos gestores (Bastone *et al.*, 2025). A redução do esforço de validação resulta em uma postura de passividade analítica, na qual os resultados do sistema computacional são tratados como orientações definitivas (Kahneman, 2011; Gerlich, 2025). Essa adesão desconsidera o fato de que sistemas de IA apresentam falhas de programação, desvios de calibração e reproduzem vieses presentes nas bases de dados de treinamento (Haenlein; Kaplan, 2019), o que compromete a eficácia das decisões tomadas nos níveis gerenciais (Berente *et al.*, 2021).

As dinâmicas de implementação da IA diferem de modo relevante no contexto das Pequenas e Médias Empresas (PMEs). Essas organizações apresentam condições estruturais distintas em relação às grandes corporações para a adoção de tecnologias (Oldemeyer *et al.*, 2024), caracterizando-se por restrições de capital, infraestrutura de dados não padronizada e escassez de recursos humanos especializados (Oldemeyer *et al.*, 2024; Mikalef; Gupta, 2021). A restrição orçamentária agrava as consequências da racionalidade limitada no processo de planejamento, dado que a alocação ineficiente de recursos condiciona diretamente a viabilidade e a continuidade do negócio (Simon, 1979).

A integração de soluções baseadas em aprendizado de máquina nesse contexto esbarra em barreiras associadas aos custos de licenciamento de *software* e à baixa maturidade digital da infraestrutura existente (Oldemeyer *et al.*, 2024). A qualidade e a disponibilidade de dados estruturados constituem pré-requisitos técnicos para a geração de previsões válidas pelos modelos (Haenlein; Kaplan, 2019). A ausência de bases de dados corporativas organizadas dificulta o treinamento de algoritmos proprietários e eleva a probabilidade de imprecisões nas recomendações geradas (Kahneman, 2011). Em decorrência dessas limitações, as PMEs tendem a recorrer à contratação de sistemas fornecidos por plataformas de tecnologia em nuvem de terceiros (Berente *et al.*, 2021).

Essa dependência de fornecedores externos transfere o processamento de inteligência competitiva para infraestruturas cujo código-fonte não é acessível ao gestor (Floridi *et al.*, 2018). O uso de algoritmos opacos impede que os administradores auditem as variáveis e os pesos estatísticos utilizados na formulação das recomendações estratégicas (Berente *et al.*, 2021). A impossibilidade de rastrear a cadeia de processamento compromete a transparência do processo decisório e interfere nos protocolos de governança corporativa (Floridi *et al.*, 2018), induzindo as organizações a assumirem níveis não quantificados de risco operacional (Glikson; Woolley, 2020).

A subordinação das deliberações gerenciais às diretrizes de plataformas externas afeta a configuração das capacidades dinâmicas da empresa e restringe a autonomia decisória dos gestores (Raisch; Krakowski, 2021). O alinhamento dessas recomendações automatizadas com as metas organizacionais requer a manutenção da capacidade humana de verificação e correção (Maitlis; Christianson, 2014). A avaliação da tecnologia exige, portanto, o mapeamento de seus efeitos sobre os índices de eficiência e sobre o grau de controle da liderança (Jarrahi, 2018), com o objetivo de determinar os meios pelos quais as PMEs podem equilibrar a otimização na alocação de recursos com a preservação da autonomia decisória (Raisch; Krakowski, 2021).

As discussões anteriores evidenciam que a IA tem se consolidado como elemento relevante na transformação dos processos decisórios, ampliando a capacidade analítica das organizações e redefinindo o papel do gestor. Ainda assim, há fragmentação conceitual entre as abordagens tecnológicas, cognitivas e organizacionais na literatura, o que torna necessária a integração dessas perspectivas em uma estrutura teórica capaz de representar, de modo articulado, como a IA influencia o processo de tomada de decisão estratégica. Com base nessa necessidade, apresenta-se a seguir o Modelo Conceitual Integrativo proposto nesta pesquisa.

2.4 MODELO CONCEITUAL INTEGRATIVO: O PAPEL DA INTELIGÊNCIA ARTIFICIAL NO PROCESSO DE TOMADA DE DECISÃO ESTRATÉGICA

Com base nas discussões das seções anteriores, propõe-se um Modelo Conceitual Integrativo que sintetiza as principais contribuições teóricas sobre o papel da IA no processo de tomada de decisão estratégica. O modelo representa, de forma sistemática, como a interação entre elementos tecnológicos, cognitivos e organizacionais molda as decisões estratégicas.

A literatura sobre decisão estratégica (Simon, 1979; Mintzberg *et al.*, 1976; Maitlis; Christianson, 2014) indica que a racionalidade gerencial é limitada por restrições cognitivas e informacionais. Em paralelo, estudos sobre IA e gestão (Jarrahi, 2018; Berente *et al.*, 2021; Raisch; Krakowski, 2021; Von Krogh, 2023) sugerem que os sistemas inteligentes ampliam a capacidade das organizações de processar dados e antecipar cenários, sem eliminar as dimensões subjetivas e éticas das decisões humanas. Nesse sentido, a IA deve ser compreendida não como substituta da racionalidade humana, mas como complemento cognitivo que redefine o papel do gestor no processo estratégico.

O modelo estrutura-se em três camadas interdependentes, denominadas inputs, processos e outputs, que descrevem o funcionamento sistêmico da decisão estratégica mediada pela IA:

a) Inputs (Fontes de Inteligência e Contexto Decisório): a decisão estratégica é alimentada por múltiplas fontes de informação, que incluem dados estruturados e não estruturados processados por algoritmos de IA (Berente *et al.*, 2021), o conhecimento tácito dos gestores (Simon, 1979) e fatores contextuais como cultura organizacional, ética e ambiente institucional (Floridi *et al.*, 2018). A integração desses elementos constitui a base informacional sobre a qual o julgamento estratégico é construído;

b) Processos (Interação Cognitiva Humano-IA): o núcleo do modelo consiste na interação entre agentes humanos e sistemas de IA. Essa interação pode assumir duas formas: automação, quando a IA formula recomendações com baixa participação humana; e ampliação cognitiva, quando a IA expande a capacidade analítica dos gestores sem substituir seu julgamento (Jarrahi, 2018; Brynjolfsson; McAfee, 2017). Essa relação é mediada por aspectos de transparência algorítmica, explicabilidade (XAI) e confiança tecnológica (Floridi *et al.*, 2018), configurando o processo decisório como uma coprodução entre cognição humana e cálculo algorítmico;

c) Outputs (Resultados, Aprendizado e Implicações Estratégicas): as decisões resultantes geram efeitos em três níveis: cognitivo, com a ampliação da percepção analítica e a redução seletiva de vieses (Kahneman, 2011); organizacional, com maior agilidade nas decisões e o risco de dependência tecnológica (*overreliance*) (Raisch; Krakowski, 2021); e ético-social, com dilemas de responsabilidade e justiça algorítmica (Floridi *et al.*, 2018). Esses resultados retroalimentam o sistema, gerando aprendizado organizacional e ajustes contínuos nas práticas decisórias.

Em síntese, o modelo propõe que a IA não substitui a racionalidade humana, mas a reconfigura em um formato híbrido de racionalidade ampliada. A decisão estratégica passa a ser compreendida como um processo sociotécnico (Berente *et al.*, 2021), no qual a tecnologia fornece análise e previsão, enquanto o gestor contribui com julgamento, ética e legitimidade interpretativa. O Quadro 1 apresenta a síntese estrutural do modelo.

Quadro 1 - Síntese Estrutural do Modelo

Camada	Elemento central	Função teórica	Referências-chave
--------	------------------	----------------	-------------------

Inputs	Dados, julgamento humano e contexto	Fontes informacionais e cognitivas do processo decisório	Simon (1979); Berente et al. (2021); Floridi et al. (2018)
Processos	Interação humano-IA (automação ↔ augmentação)	Coprodução das decisões estratégicas	Jarrahi (2018); Raisch, Krakowski (2021); Von Krogh (2023)
Outputs	Resultados cognitivos, organizacionais e éticos	Aprendizado e retroalimentação estratégica	Kahneman (2011); Floridi et al. (2018); Gerlich (2025)

Fonte: Elaborado pelo autor (2026).

A síntese estrutural apresentada consolida o arcabouço teórico que orienta a análise dos resultados. Para que as relações entre os inputs de dados, a interação processual entre gestores e algoritmos e os outputs organizacionais pudessem ser verificadas empiricamente, foi necessário estruturar um percurso investigativo fundamentado em procedimentos metodológicos rigorosos. A seção a seguir detalha as etapas adotadas para a coleta, triagem e análise das evidências empíricas que dialogam com este modelo conceitual.

3 PROCEDIMENTOS METODOLÓGICOS

O presente trabalho possui uma abordagem qualitativa e emprega como estratégia de pesquisa uma revisão sistemática da literatura. Este delineamento foi selecionado por ser desenvolvido com base em material já elaborado, constituído principalmente de artigos científicos, abrangendo a bibliografia tornada pública referente ao tema de estudo e permitindo uma análise aprofundada do conhecimento já consolidado sobre o fenômeno (Marconi; Lakatos, 2017).

Quanto aos seus fins, a pesquisa foi classificada como exploratória, pois seu objetivo principal foi proporcionar maior familiaridade com o problema, com vistas a torná-lo mais explícito (Gil, 2008). Adicionalmente, o estudo adotou uma abordagem descritiva, buscando as características da interseção entre os campos da Inteligência Artificial (IA) e da Tomada de Decisão Estratégica, identificando e correlacionando as variáveis e conceitos centrais que definem este campo de estudo.

Os dados foram coletados por meio da base de dados Web of Science (WOS). A seleção do material foi operacionalizada por meio de uma busca booleana projetada para capturar a intersecção obrigatória entre as categorias de tecnologia e o domínio da decisão estratégica. A *string* de pesquisa utilizada foi:

("Artificial intelligence" OR "AI") AND ("decision making" OR "strategic decision making" OR "decision making process" OR "decision making-process" OR "strategic decision-making").

Até o início da análise dos trabalhos encontrados, diferentes critérios de exclusão foram aplicados em diferentes fases da pesquisa. O Quadro 2, sintetiza esses critérios.

Quadro 2 – Critérios de exclusão de dados


CRITÉRIOS DE EXCLUSÃO	ESPECIFICIDADE	FASE DA EXCLUSÃO	JUSTIFICATIVA
Idioma	Diferentes de inglês	Busca na base de dados	Os trabalhos com mais impacto na ciência são publicados em inglês.
Tipo de documento	Diferentes de artigo completo	Busca na base de dados	Artigos publicados passaram por revisão por pares (<i>peer-review</i>), aumentando a confiabilidade do trabalho.
Ano da publicação	Inferiores a 2022	Busca na base de dados	Foco em pesquisas recentes e no atual estado da Inteligência Artificial.

Área de concentração	Diferentes de <i>Business e Management</i>	Busca na base de dados	Aumentar a acuracidade e garantir alinhamento estrito à área de negócios.
Acesso ao documento	Diferentes de <i>Open Access</i> e <i>Early Access</i>	Busca na base de dados	Garantir a acessibilidade integral aos textos para a análise qualitativa profunda, assegurar que todo o corpo de evidências analisado esteja disponível sem barreiras de acesso e viabilizar a replicabilidade do protocolo por pesquisadores futuros.
Escopo operacional / técnico	Foco em micro-otimizações ou setores puramente técnicos	Leitura dos resumos	O objetivo foca em decisões estratégicas de alta gestão, excluindo processos algorítmicos e operacionais isolados.
Foco transacional	Foco na automação de tarefas rotineiras de RH	Leitura das introduções e conclusões	Evitar desvios de escopo que não englobam a autonomia gerencial e a cognição estratégica.
Relação com o tema	Não apresentar relação direta com a decisão estratégica e a interação Humano-IA	Leitura das introduções e conclusões	Identificar e selecionar apenas os trabalhos que possibilitem a análise sob a lente do Modelo Conceitual Integrativo.
Conformidade de escala	Não abordar o contexto de Pequenas e Médias Empresas (PMEs) ou <i>startups</i>	Leitura das introduções e conclusões	Analisar e manter apenas os trabalhos que estão estritamente aderentes à pergunta de pesquisa delimitada.

Fonte: Elaborado pelo autor (2026).

A partir deste ponto os critérios de exclusão foram aplicados, conforme demonstra o fluxo da pesquisa na Figura 1.

Figura 1 – Fluxograma do Processo de Seleção dos Estudos



Fonte: Elaborado pelo Autor (2026).

O recorte temporal da pesquisa foi delimitado aos últimos cinco anos (2022 a 2026). A escolha dessa data justifica-se pelo fato de que a Inteligência Artificial (IA), especialmente com a ascensão disruptiva e a popularização da IA Generativa (como os Grandes Modelos de Linguagem), sofreu saltos exponenciais recentes de capacidade analítica. O grande marco temporal desta revolução tecnológica foi o lançamento do ChatGPT pela empresa *OpenAI*, ocorrido no final de 2022 (Aydin; Karaarslan, 2022). A disponibilização e o rápido ganho de popularidade desta ferramenta evidenciaram as capacidades avançadas de geração de texto e

interação em linguagem natural, gerando uma nova onda de interesse nas pesquisas sobre os impactos e limites destas IAs na atualidade.

Na primeira fase (Busca Inicial), realizada em 07 de abril de 2026, aplicou-se a *string* de pesquisa delimitada na base *Web of Science* (WOS), sem restrições adicionais. A consulta retornou 91.722 artigos, volume que fundamenta a necessidade das fases de filtragem subsequentes.

Na segunda fase (Filtros da Base de Dados), aplicaram-se os refinamentos disponíveis diretamente na plataforma WOS de forma sequencial. O primeiro filtro aplicado foi o de idioma, restringindo os resultados ao inglês, o que reduziu a amostra para 90.373 artigos. Na sequência, a restrição ao tipo de documento para artigos completos (*articles*), submetidos a revisão por pares (*peer-review*), reduziu o corpus para 64.259 trabalhos. A aplicação do recorte temporal de 2022 a 2026 afunilou a amostra para 31.247 artigos. A seleção das categorias *Business* e *Management* da WOS reduziu o corpus para 2.834 artigos. Por fim, a exigência de acesso aberto (*Open Access* e *Early Access*) consolidou a amostra em 98 artigos. Essa restrição responde a um compromisso com a transparência e a replicabilidade da revisão: ao limitar o portfólio a artigos publicamente acessíveis, garante-se que qualquer pesquisador que decida reproduzir ou expandir este protocolo possa acessar integralmente o mesmo corpus de evidências, sem depender de assinaturas institucionais. A redução de 91.722 para 98 não resultou da leitura ou avaliação manual de mais de 90 mil trabalhos, mas da aplicação automática e cumulativa dos filtros disponibilizados pela própria base. A triagem manual foi iniciada somente a partir dos 98 registros remanescentes.

Na terceira fase (Triagem Primária), procedeu-se à leitura dos resumos dos 98 artigos remanescentes. O objetivo foi eliminar trabalhos com escopo puramente operacional, focados em engenharia de algoritmos ou microrrotinas técnicas. Foram excluídos também os artigos que tratavam exclusivamente de tomada de decisão, sem qualquer relação com a Inteligência Artificial. Esses trabalhos foram descartados por não englobarem a cognição, a autonomia gerencial ou a decisão estratégica, que constituem o núcleo desta pesquisa. A triagem suprimiu 62 artigos, reduzindo a amostra a 36 estudos.

Na quarta fase (Análise de Introdução e Conclusão), os 36 artigos pré-selecionados tiveram suas introduções e conclusões avaliadas para verificar a adequação metodológica, a aderência simultânea à base teórica (Racionalidade Limitada e Simbiose Humano-IA) e a relação direta com o problema central da pesquisa. Neste crivo, um total de 28 artigos foram descartados. As exclusões ocorreram por duas razões principais: o foco excessivo em metodologias puramente técnicas (sem alinhamento com a gestão estratégica de negócios) e a incompatibilidade com o perfil de Pequenas e Médias Empresas (PMEs). A maioria dos estudos eliminados focava em corporações multinacionais, fluxos macroeconômicos, ou não apresentava dados empíricos sólidos sobre o dilema da alocação de recursos atrelado ao risco à autonomia do decisor humano.

A superação destas barreiras metodológicas culminou na quinta fase (Amostra Final), consolidando um portfólio de 8 estudos. Esta amostra atende a todos os critérios estabelecidos e compõe a base para a leitura integral, fichamento e síntese qualitativa que fundamentará a discussão dos resultados.

4 RESULTADOS E DISCUSSÃO

Esta seção apresenta e discute os resultados obtidos a partir da análise qualitativa aprofundada dos oito artigos que compõem o portfólio final desta revisão sistemática. A discussão organiza-se em cinco blocos temáticos complementares, estruturados de forma a responder, de maneira progressiva e articulada, à pergunta de pesquisa central: de que forma o uso de inteligência artificial como suporte à decisão contribui para aprimorar a alocação de

recursos estratégicos ou para comprometer a autonomia decisória em pequenas e médias empresas. O primeiro bloco caracteriza as dimensões metodológicas do portfólio. Os blocos subsequentes analisam, respectivamente, os benefícios observados na alocação de recursos, os riscos associados à perda de autonomia, o fenômeno da descarga cognitiva e, por fim, as implicações gerenciais integradas ao modelo conceitual proposto.

4.1 VISÃO GERAL E CARACTERÍSTICAS METODOLÓGICAS DO PORTFÓLIO

O portfólio final desta revisão sistemática é composto por oito artigos científicos publicados entre 2024 e 2026, todos oriundos de periódicos revisados por pares e alinhados ao escopo das pequenas e médias empresas. A análise do conjunto evidencia uma heterogeneidade metodológica intencional e equilibrada, resultante dos critérios de seleção adotados no protocolo desta revisão: cinco estudos adotam abordagem qualitativa ou experimental (Kao, 2025; Bastone et al., 2025; Ciccola et al., 2025; Cristofaro e Giardino, 2025; Remke et al., 2026), dois são predominantemente quantitativos por *survey* ou *text mining* (Almashawreh et al., 2024; Klonek e Parker, 2025) e um adota *design* experimental pré-registrado com múltiplos modelos de inteligência artificial (Kleinert e Urbig, 2026). Essa diversidade garante que as conclusões desta revisão emirjam da triangulação entre dados empíricos, análises qualitativas e reflexões conceituais, sem subordinação a um único paradigma epistemológico.

Almashawreh et al. (2024) conduziram um *survey* quantitativo com 364 proprietários e gestores de PMEs jordanianas, investigando os fatores tecnológicos e organizacionais que influenciam a adoção de inteligência artificial com base no *framework* TOE (Tecnologia-Organização-Ambiente). Kao (2025) realizou um estudo de casos múltiplos com 32 entrevistas semiestruturadas em empresas B2B de doze setores na China, analisando como a IA preditiva contribui para o desenvolvimento de capacidades dinâmicas orientadas à sustentabilidade organizacional. Bastone et al. (2025) conduziram uma observação participante com 20 estudantes de mestrado em empreendedorismo na Itália, investigando como indivíduos sem experiência empreendedora prévia interagem com a IA generativa em tarefas decisórias complexas.

Cristofaro e Giardino (2025) empregaram um experimento controlado com 123 inovadores distribuídos aleatoriamente em três condições de uso, sendo elas a ausência de IA, o uso moderado e o uso elevado da ferramenta, para examinar como diferentes níveis de assistência afetam o engajamento cognitivo e a qualidade das ideias geradas. Ciccola et al. (2025) adotaram estudo de caso múltiplo com duas empresas italianas de médio porte do setor calçadista, analisando como a adoção de IA remodela as dimensões do capital intelectual no contexto do relato de sustentabilidade. Klonek e Parker (2025) aplicaram mineração de texto com Grandes Modelos de Linguagem a 2.704 publicações do *Twitter* sobre uso de IA no trabalho, testando os efeitos do controle algorítmico e dos processos de equipe humano-IA sobre o estresse dos trabalhadores.

Kleinert e Urbig (2026) conduziram um experimento pré-registrado com 171 empreendimentos de *equity crowdfunding* e 900 avaliadores humanos, comparando as avaliações de três modelos de linguagem com resultados reais de captação de recursos. Remke et al. (2026) realizaram 57 entrevistas semiestruturadas com especialistas em economia circular, pesquisadores de inteligência artificial e fundadores de novas *ventures* em dez países, investigando como IA e dinâmicas circulares co-habilitam a inovação em modelos de negócio. Em termos de escopo geográfico e setorial, o portfólio abrange contextos diversificados: Jordânia, China, Itália, Europa e Sul Global. Essa pluralidade amplia o potencial de generalização das conclusões, ao demonstrar que os efeitos da adoção de IA sobre a decisão estratégica transcendem contextos econômicos e culturais específicos.

Em relação ao tipo de IA empregado, os estudos distribuem-se entre aplicações preditivas, voltadas à análise de dados e à antecipação de cenários, e ferramentas generativas

baseadas em Grandes Modelos de Linguagem, voltadas à criação de conteúdo e à interação em linguagem natural, o que reflete a divisão tecnológica que caracteriza o atual momento de adoção empresarial da tecnologia.

O Quadro 3 a seguir sintetiza as principais características de cada estudo do portfólio.

Quadro 3 - Síntese das Características dos Estudos do Portfólio

Estudo	País	Setor	Método	Abordagem teórica principal	Tipo de IA	Achado principal
Almashawreh et al. (2024)	Jordânia	Misto (PMEs)	Quantitativo (survey, n=364)	TOE (Tecnologia-Organização-Ambiente)	IA (múltiplos tipos)	Suporte gerencial é o preditor mais robusto da atitude em relação à IA; estratégia tecnológica formal não impacta significativamente
Kao (2025)	China (B2B)	Misto (12 setores B2B)	Qualitativo (casos múltiplos, 32 entrevistas)	Capacidades Dinâmicas (Teece, 2007)	IA Preditiva	Seis capacidades de IA como microfundamentos de <i>sensing</i> , <i>seizing</i> e <i>reconfiguring</i> ; duas abordagens de realização: humanista e instrumental
Bastone et al. (2025)	Itália	Empreendedorismo / Educação	Qualitativo (observação participante, n=20)	Paradigma <i>Human+</i> e Racionalidade Limitada	IA Generativa (<i>ChatGPT</i>)	Empreendedores latentes assumem papel ativo na interação com <i>GenAI</i> ; uso como ferramenta operacional e como fonte de aprendizado
Cristofaro e Giardino (2025)	Itália / EUA	Inovação de Produto	Experimental controlado (n=123, 3 grupos)	Teoria da Carga Cognitiva	IA Generativa (<i>ChatGPT-4</i>)	Relação em U invertido entre assistência de IA e inovação; uso moderado (até ~15 interações) maximiza originalidade, quantidade e viabilidade
Ciccola et al. (2025)	Itália	Manufatura (médias empresas)	Qualitativo (casos múltiplos, 2 empresas)	Capital Intelectual	IA (múltiplos tipos)	IA remodela capital humano, organizacional e relacional; fragmentação de dados é barreira crítica; emergência de perfis híbridos

Estudo	País	Setor	Método	Abordagem teórica principal	Tipo de IA	Achado principal
						'contador-engenheiro'
Klonek e Parker (2025)	Contexto digital (Twitter/X)	Transversal (múltiplos setores)	<i>Text mining</i> com LLM	Teoria do Design do Trabalho e Paradoxo Automação-Aumentação	IA (múltiplos tipos)	Controle da IA aumenta o estresse dos trabalhadores; processos colaborativos de equipe reduzem o estresse; os dois efeitos são dimensões empiricamente independentes
Kleinert e Urbig (2026)	Alemanha / Europa	<i>Startups</i> / Capital Empreendedor	Experimental pré-registrado (171 <i>ventures</i> , 3 LLMs, 900 avaliadores)	Heurísticas e Vieses Cognitivos (ancoragem, <i>herding</i>)	IA Generativa (GPT-4, GPT-4o, Gemini 2.5 Pro)	LLMs superam humanos na avaliação de atratividade de investimento; previsões de sobrevivência dependem de exposição prévia nos dados de treinamento
Remke et al. (2026)	Europa / Global	Indústria / Economia Circular	Qualitativo (57 entrevistas, 10 países)	<i>Framework</i> de Habilidade Externa (Davidsson, 2015)	IA (múltiplos tipos)	IA e economia circular co-habilitam modelos de negócio circulares; <i>dual enablement</i> cria espaços de oportunidade qualitativamente novos

Fonte: Elaborado pelo autor (2026).

A partir deste panorama estrutural, a discussão organiza-se em torno da tensão central desta pesquisa: de um lado, o potencial da IA para ampliar a capacidade analítica e aprimorar a alocação de recursos estratégicos nas PMEs; de outro, os riscos associados ao comprometimento da autonomia decisória e à dependência tecnológica.

4.2 A MITIGAÇÃO DA RACIONALIDADE LIMITADA E A ALOCAÇÃO DE RECURSOS

O primeiro bloco temático emergente do portfólio diz respeito aos efeitos positivos da inteligência artificial sobre a qualidade das decisões de alocação de recursos em PMEs. Três estudos fornecem evidências diretas sobre essa dimensão: Almashawreh et al. (2024), Kao (2025) e Remke et al. (2026). Os achados convergem para demonstrar que a adoção estruturada de sistemas de IA produz ganhos na precisão analítica dos processos de planejamento e na capacidade das empresas de identificar e explorar oportunidades de inovação.

Almashawreh et al. (2024) documentam, por meio de *survey* com 364 gestores de PMEs jordanianas, que o suporte gerencial ativo da alta liderança é o fator determinante da

atitude positiva em relação à IA, superando com expressiva margem todos os demais preditores testados no modelo, incluindo o conhecimento de tecnologia da informação dos colaboradores e os programas de treinamento. A estratégia tecnológica formal não apresentou impacto estatisticamente relevante sobre a atitude dos gestores, resultado que contraria a literatura dominante e sugere que, no contexto de economias emergentes, as PMEs operam de forma mais reativa do que planejada. A adoção tende a ocorrer a partir de condições operacionais que o gestor vivencia diretamente no cotidiano, como o acesso a treinamentos, o suporte da liderança imediata e a percepção de recompensas associadas ao uso da ferramenta. O planejamento tecnológico formal, quando existe, mostrou-se estatisticamente irrelevante para explicar a disposição do gestor em adotar a tecnologia nesse contexto específico.

A ausência de efeito significativo da estratégia tecnológica formal tem implicação direta para a teoria da racionalidade limitada (Simon, 1979). A adoção de IA nesse contexto é impulsionada menos pelo processamento racional de informações estratégicas e mais pelas condições organizacionais que tornam a tecnologia acessível e percebida como útil. O gestor que vivencia no cotidiano o suporte da liderança, o acesso a treinamentos e as recompensas associadas ao uso da ferramenta tende a desenvolver atitude favorável, independentemente de haver um planejamento digital formalizado.

Kao (2025) amplia esse espectro ao identificar, por meio de estudo de casos múltiplos em doze setores B2B na China, seis capacidades de IA que funcionam como microfundamentos das capacidades dinâmicas de *sensing*, *seizing* e *reconfiguring*, no sentido de Teece, Pisano e Shuen (1997). As capacidades de reconhecimento de padrões e tomada de decisão ágil, vinculadas respectivamente à detecção e ao aproveitamento de oportunidades, permitem às empresas antecipar mudanças regulatórias, ajustar recursos em tempo real e integrar conhecimentos de diferentes áreas da empresa que antes permaneciam isolados entre departamentos. Um gerente de fazenda do setor agrícola descreveu como a realocação de água e energia com base em dados preditivos tornou as operações sistematicamente alinhadas às metas de sustentabilidade, sem depender de aproximações intuitivas.

O estudo de Kao (2025) identifica ainda duas abordagens pelas quais as empresas realizam essas capacidades dinâmicas na prática. A abordagem instrumental prioriza eficiência operacional e ganhos financeiros imediatos, enquanto a abordagem humanista orienta-se à cocriação de soluções com *stakeholders* para metas de sustentabilidade compartilhadas. As duas coexistem e, com frequência, tensionam-se no interior das organizações. Um gerente de produção do setor manufatureiro relatou que as estratégias não eram conscientemente separadas, emergindo naturalmente conforme o contexto e as questões em pauta. Essa hibridação prática desafia representações lineares da adoção de IA e reforça a centralidade do julgamento humano como mediador do uso da tecnologia.

Remke et al. (2026) complementam esse quadro ao demonstrar como a interação entre IA e as dinâmicas da economia circular cria um fenômeno denominado pelos autores de *dual enablement*. Nas fases pré-uso, uso e pós-uso do ciclo de vida dos produtos, a IA possibilita eficiência na gestão de recursos, rastreamento de fluxos materiais e decisões holísticas de recuperação baseadas em dados, funções que individualmente não seriam realizáveis em escala adequada sem suporte tecnológico. O estudo revela que IA e economia circular amplificam mutuamente seus efeitos habilitadores, abrindo espaços de oportunidade para modelos de negócio que nenhum dos dois habilitadores sozinho seria capaz de gerar. Para PMEs e novas *ventures*, esse fenômeno representa uma vantagem competitiva estrutural: ao processar informações sobre fluxos de materiais e requisitos regulatórios em tempo real, a tecnologia apresenta ao gestor alternativas que ele sequer consideraria formular de forma autônoma, elevando o que Simon (1979) denomina o nível de aspiração da decisão satisfatória.

4.3 O COMPROMETIMENTO DA AUTONOMIA E O ESTRESSE ORGANIZACIONAL

Se o bloco anterior evidenciou o potencial da IA como amplificador de racionalidade, os achados de Klonck e Parker (2025) e Ciccola et al. (2025) confrontam essa narrativa com uma dimensão crítica igualmente documentada no portfólio: os riscos sistêmicos ao bem-estar do gestor e à autonomia organizacional derivados de uma adoção desbalanceada. Esses dois estudos, de natureza metodológica distinta, convergem para a mesma conclusão. Quando a IA é adotada sem protocolos de governança que preservem o protagonismo do decisor humano, a tecnologia gera formas progressivas de dependência que comprometem tanto a saúde psicológica quanto a capacidade interna de inovação.

Klonck e Parker (2025) fornecem a evidência mais direta sobre o comprometimento da autonomia decisória. Por meio de mineração de texto com Grandes Modelos de Linguagem aplicada a 2.704 publicações do *Twitter* sobre o uso de IA no trabalho, os autores demonstram que o controle exercido pela IA sobre as decisões está associado a níveis mais elevados de estresse humano, enquanto os processos colaborativos de equipe humano-IA estão associados à redução significativa do estresse. O achado central é que essas duas dimensões, controle da IA e qualidade dos processos de equipe, são empiricamente independentes e produzem efeitos opostos sobre o bem-estar dos trabalhadores.

Os autores demonstram ainda que processos colaborativos de equipe humano-IA bem estruturados reduzem o impacto negativo do controle algorítmico sobre o bem-estar dos trabalhadores. Quanto mais ativa e organizada a colaboração entre humanos e IA, menor a intensidade com que o controle algorítmico se traduz em estresse ocupacional. O mesmo nível de autonomia delegada ao algoritmo produz efeitos distintos dependendo de como essa colaboração é conduzida na prática. O que determina o bem-estar do gestor, portanto, é a forma como o trabalho com IA é organizado, e não o grau de sofisticação da tecnologia adotada.

Essa conclusão dialoga com o Paradoxo Automação-Aumentação descrito por Raisch e Krakowski (2021), segundo o qual pressões de curto prazo empurram as organizações sistematicamente para o polo da automação, mesmo quando a aumentação cognitiva seria estrategicamente superior. Gestores que operam sob sistemas de IA sem protocolos de contestação e validação tendem a experienciar heteronomia algorítmica, estado em que as recomendações do sistema são percebidas como prescritivas, com impactos mensuráveis sobre o bem-estar psicológico e sobre a capacidade de adaptação estratégica da empresa. Esse estado representa a negação prática do Paradigma *Human+* proposto por Bastone et al. (2025), segundo o qual a IA deve ampliar as capacidades do gestor sem substituir seu julgamento. Quando a heteronomia algorítmica se instala, a tecnologia deixa de ser instrumento de expansão cognitiva e passa a ocupar o lugar do decisor humano.

Ciccola et al. (2025) ampliam essa perspectiva ao examinar, por meio de estudo de caso múltiplo em duas empresas italianas de médio porte do setor calçadista, como a adoção de IA remodela o capital humano, organizacional e relacional no contexto do relato de sustentabilidade. Um achado central diz respeito às trajetórias divergentes das duas empresas: a primeira, de postura proativa, vislumbra a IA como substituta de tarefas operacionais, libertando colaboradores para atividades de maior valor estratégico; a segunda, mais conservadora, alerta para o risco de perder os momentos de reflexão coletiva e de aprendizagem organizacional caso a automação avance sem critério. Essa tensão empírica entre eficiência e riqueza interpretativa expressa, no plano da gestão real, o paradoxo teórico de Raisch e Krakowski (2021).

A fragmentação de dados entre departamentos e plataformas tecnológicas foi identificada como barreira crítica compartilhada pelas duas empresas. Ambas reconhecem que a adoção de IA é contingente à implementação de sistemas integrados de informação, sem os quais o potencial da tecnologia permanece represado. Para médias empresas que dependem de fornecedores externos de *software*, o ritmo da adoção é determinado não apenas pela prontidão

interna, mas pela capacidade de resposta desses fornecedores, uma dimensão do capital organizacional que Ciccola et al. (2025) apontam como lacuna na literatura sobre adoção de IA em médias empresas. Quando a empresa não consegue auditar os algoritmos que contrata, a opacidade dos sistemas compromete tanto a governança corporativa quanto a transparência das decisões estratégicas.

Para as PMEs, esse risco assume contornos ainda mais agudos do que em grandes corporações. Oldemeyer et al. (2024) documentam que essas organizações raramente dispõem de recursos humanos especializados para contestar as recomendações dos sistemas adotados. A dependência de fornecedores externos de *software* decorre, com frequência, das restrições orçamentárias típicas desse segmento, e não de uma escolha estratégica deliberada. O resultado é um ciclo estrutural de dependência de trajetória (*path dependency*): a PME adota a IA por necessidade competitiva, torna-se tecnicamente incapaz de auditá-la e, progressivamente, perde a autonomia que a adoção deveria preservar. Esse aprisionamento progressivo compromete exatamente as capacidades dinâmicas que Teece, Pisano e Shuen (1997) identificam como determinantes da vantagem competitiva de longo prazo.

4.4 VIESES HEURÍSTICOS E A DESCARGA COGNITIVA (COGNITIVE OFFLOADING)

O terceiro bloco temático aprofunda o risco decisório ao introduzir a dimensão do *cognitive offloading*, ou seja, a transferência de etapas de raciocínio para ferramentas externas, e seus desdobramentos sobre a qualidade do julgamento gerencial. Os estudos de Cristofaro e Giardino (2025), Kleinert e Urbig (2026) e Bastone et al. (2025) convergem para uma conclusão central: em determinadas condições, o uso de IA generativa não apenas falha em mitigar os vieses cognitivos do decisor, como os intensifica ao fornecer âncoras algorítmicas que substituem o processo de deliberação independente, em vez de complementá-lo.

A contribuição mais experimentalmente controlada nesse bloco é de Cristofaro e Giardino (2025). Em experimento com 123 inovadores distribuídos em três condições de uso de IA, os autores demonstraram que a relação entre assistência de IA e resultados de inovação segue um padrão de U invertido mediado pelo engajamento cognitivo. O grupo de IA moderada, com até quinze interações com a ferramenta, produziu o maior número de ideias, os índices mais elevados de originalidade e viabilidade e o menor nível de excesso de confiança. Os grupos sem IA e com IA elevada produziram resultados comparáveis em quantidade e qualidade de ideias, porém por mecanismos cognitivos opostos.

O grupo sem IA sofreu sobrecarga cognitiva, o que restringiu a exploração divergente de alternativas. O grupo de IA elevada desenvolveu viés de automação, aceitando os *outputs* do sistema de forma acrítica e ativando predominantemente o que Kahneman (2011) denomina Sistema 1 do processamento cognitivo: o modo intuitivo, rápido e de baixo esforço. O grupo de IA moderada, por sua vez, operou no modo analítico e deliberativo do Sistema 2, com a ferramenta funcionando como andaime cognitivo que sustentou o engajamento dentro da zona de carga ótima. O ponto de inflexão identificado pelos autores, de aproximadamente quinze interações, foi validado por modelagem estatística com expressivo poder explicativo. Todas as oito hipóteses do estudo foram confirmadas, fornecendo suporte consistente ao modelo proposto.

Kleinert e Urbig (2026) oferecem perspectiva complementar ao demonstrar que os Grandes Modelos de Linguagem exibem vieses heurísticos análogos aos humanos no contexto da avaliação de *startups*. Em experimento com 171 empreendimentos e três modelos de IA, os autores identificaram comportamento de *herding*: o número de investidores que já expressaram interesse em um empreendimento afeta as avaliações dos modelos além da qualidade intrínseca do negócio, indicando que a pressão social mimetizada nos dados de treinamento contamina os julgamentos algorítmicos. Os modelos também exibiram viés de ancoragem nas avaliações

contextuais, com *ventures* apresentados em determinadas posições de um conjunto recebendo avaliações sistematicamente mais favoráveis. O fenômeno assemelha-se ao que Kahneman (2011) descreve como viés de disponibilidade: o modelo mimetiza o endosso social humano de forma acrítica, sem atualizar racionalmente sua avaliação com base nos méritos do empreendimento.

Um achado metodologicamente central do estudo de Kleinert e Urbig (2026) é a distinção entre raciocínio e *recall* nos modelos de linguagem. As previsões de sobrevivência mostram-se precisas quando havia exposição prévia aos empreendimentos nos dados de treinamento, tornando-se estatisticamente indistinguíveis do acaso na ausência dessa exposição. A aparente capacidade preditiva dos modelos reflete, portanto, memória de informações históricas, e não raciocínio prospectivo genuíno sob incerteza. Há ainda uma implicação sistêmica: quando múltiplos avaliadores passam a utilizar os mesmos modelos treinados nos mesmos dados, a diversidade epistêmica do sistema de alocação de capital se reduz, e é exatamente essa diversidade de perspectivas que permite aos mercados identificar oportunidades subavaliadas e corrigir distorções de precificação (Kahneman, 2011; Kleinert; Urbig, 2026).

Bastone et al. (2025), por sua vez, identificaram que os indivíduos sem experiência empreendedora prévia, ao interagir com o *ChatGPT* em tarefas complexas, assumem papel proativo no processo decisório. Os participantes debatiam em sequências de três a quatro interações para formular opiniões mais estruturadas, questionando diretamente as sugestões do sistema quando estas divergiam de seu julgamento. Esse comportamento observado empiricamente é a expressão prática do Paradigma *Human+*: o indivíduo não abdica de seu papel decisório diante da ferramenta, mas o exerce de forma mais qualificada a partir da interação com ela. O *cognitive offloading*, portanto, não é uma consequência inevitável do uso de IA generativa. Seu surgimento depende das condições sob as quais a interação ocorre, incluindo familiaridade técnica, pressão temporal e presença de protocolos institucionais de validação.

Os achados dos três estudos dialogam diretamente com a teoria das heurísticas de Kahneman (2011). O portfólio demonstra que a IA generativa pode funcionar como amplificador de ancoragem: ao fornecer um ponto de referência inicial, o *output* do modelo captura o processo de julgamento e reduz a variação que seria necessária para que diferentes avaliadores chegassem a conclusões genuinamente distintas. O atalho cognitivo, vulnerabilidade já conhecida do decisor humano, torna-se estruturalmente mais provável quando uma ferramenta externa fornece a âncora de forma automática e com aparência de objetividade algorítmica.

4.5 IMPLICAÇÕES GERENCIAIS E O MODELO CONCEITUAL INTEGRATIVO

A síntese dos três blocos temáticos analisados permite responder de forma articulada à pergunta de pesquisa central. O uso de IA como suporte à decisão contribui simultaneamente para aprimorar a alocação de recursos estratégicos e para comprometer a autonomia decisória em PMEs, não como alternativas excludentes, mas como dimensões coexistentes de um mesmo fenômeno tecnológico. O sentido em que cada dimensão predomina depende das escolhas organizacionais que governam a adoção da tecnologia, ou seja, da intencionalidade estratégica com que a empresa define o papel da IA em seu processo decisório. A implicação gerencial central que emerge do portfólio é a necessidade de que o gestor de PME opere segundo o que Bastone et al. (2025) denominam Paradigma *Human+*, assumindo o papel de líder da conversa: o profissional que interage com a IA generativa com intencionalidade estratégica, formula os problemas com precisão, questiona os *outputs* com competência técnica mínima e integra as recomendações algorítmicas com o conhecimento tácito e contextual que

nenhum modelo consegue capturar. Trata-se de uma competência gerencial, desenvolvida por prática reflexiva e por mecanismos institucionais de governança, e não de uma habilidade técnica de programação ou ciência de dados.

Para que essa postura seja operacionalizável em PMEs, com suas limitações estruturais de capital humano e financeiro, o estudo de Cristofaro e Giardino (2025) sugere que a zona ótima de uso de IA pode ser operacionalizada por *design* de interação: *checkpoints* de reflexão e protocolos em etapas que separam uma fase divergente assistida pela ferramenta de uma fase de convergência conduzida pelo humano. Klonck e Parker (2025) complementam ao demonstrar que a autonomia percebida do gestor pode ser preservada mesmo em contextos de adoção intensa de IA, desde que a tecnologia seja comunicada internamente como instrumento de suporte, e não como substituta do julgamento estratégico.

Ciccola et al. (2025) acrescentam que a maturidade dos sistemas de informação é um pré-requisito técnico para que qualquer uma dessas recomendações seja operacionalizável. Empresas com dados fragmentados entre departamentos e plataformas não realizarão o potencial analítico da IA, independentemente da orientação gerencial adotada. A integração de sistemas ERP e de *business intelligence* precede a adoção de IA, e a dependência de fornecedores externos, típica das PMEs, torna a gestão ativa dessas relações uma competência organizacional em si mesma.

Essas implicações práticas encontram sustentação e sistematização no Modelo Conceitual Integrativo proposto na fundamentação teórica deste trabalho. O modelo, estruturado em três camadas interdependentes, descreve o funcionamento sistêmico da decisão estratégica mediada pela IA nas PMEs. O Quadro 4 a seguir apresenta essa estrutura de forma visual e sintética.

Quadro 4 - Modelo Conceitual Integrativo: Estrutura de Inputs, Processos e Outputs

Camada	Elemento central	Função teórica	Referências-chave
Inputs Fontes de Inteligência e Contexto Decisório	(1) Dados estruturados e séries históricas processados por algoritmos; (2) Conhecimento tácito dos gestores; (3) Fatores contextuais: cultura, ética, ambiente institucional e restrições de recursos.	Fornecer a base informacional e cognitiva sobre a qual o julgamento estratégico é construído. A qualidade dos inputs determina o teto da qualidade das decisões.	Simon (1979); Berente et al. (2021); Floridi et al. (2018)
Processos Representar a coprodução da decisão estratégica entre cognição humana e cálculo algorítmico. A posição no continuum	(a) Automação: IA executa e recomenda sem supervisão ativa; (b) Aumentação: IA amplia a capacidade analítica do gestor, que mantém protagonismo; (c) Mediadores: transparência algorítmica, literacia do gestor e protocolos de governança.	Representar a coprodução da decisão estratégica entre cognição humana e cálculo algorítmico. A posição no continuum define se a IA gera autonomia ampliada ou heteronomia algorítmica.	Jarrah (2018); Raisch e Krakowski (2021); Klonck e Parker (2025)

Camada	Elemento central	Função teórica	Referências-chave
define se a IA gera autonomia ampliada ou heteronomia algorítmica.			
Outputs Resultados, Aprendizado e Implicações Estratégicas	(i) Cognitivo: ampliação da percepção e redução seletiva de vieses; (ii) Organizacional: maior agilidade nas decisões vs. risco de dependência tecnológica e atrofia de competências; (iii) Ético-social: dilemas de responsabilidade e transparência. Outputs retroalimentam o sistema como novos inputs.	Registrar os efeitos da interação Humano-IA sobre a vantagem competitiva, o bem-estar do gestor e a responsabilidade organizacional. O ciclo de retroalimentação conecta os resultados ao próximo ciclo decisório.	Kahneman (2011); Floridi et al. (2018); Gerlich (2025); Cristofaro e Giardino (2025)

Fonte: Elaborado pelo autor (2026).

A camada de *Inputs* representa as fontes de informação e de contexto que alimentam o processo decisório. Nessa camada coexistem, de forma necessariamente complementar, os dados estruturados processados pelos algoritmos, documentados empiricamente nos estudos de Almashawreh et al. (2024) e Remke et al. (2026), o conhecimento tácito dos gestores, acumulado por meio da experiência organizacional e impossível de ser capturado integralmente por qualquer modelo computacional, e os fatores contextuais de cada organização, como cultura institucional, restrições éticas e condicionantes do ambiente competitivo. Sistemas que ignoram o conhecimento tácito geram recomendações tecnicamente coerentes, mas organizacionalmente inadequadas; gestores que ignoram os dados processados pela IA perdem a capacidade analítica que a tecnologia oferece e que a racionalidade limitada sozinha não consegue suprir.

A camada de Processos representa o núcleo dinâmico do modelo. Descreve a interação cognitiva entre o gestor e o sistema de IA como um *continuum* entre os polos da automação e da aumentação, o paradoxo central descrito por Raisch e Krakowski (2021). Os achados de Klonek e Parker (2025) e Kleinert e Urbig (2026) demonstram que, sem mecanismos deliberados de governança, a interação tende a derivar para o polo da automação, com os riscos de heteronomia algorítmica, dependência de fornecedores e ancoragem cognitiva.

Os achados de Cristofaro e Giardino (2025) e Bastone et al. (2025) evidenciam, em contrapartida, que a interação pode ser conduzida para o polo da aumentação quando os gestores mantêm protagonismo no processo decisório, contestam ativamente os *outputs* da IA e integram as recomendações algorítmicas com seu julgamento contextual. A posição da organização nesse *continuum* é determinada pelas práticas de governança e pela literacia algorítmica cultivada internamente, e não pelas características da tecnologia adotada.

A camada de *Outputs* integra os resultados em três níveis analíticos complementares. No nível cognitivo, a adoção bem estruturada da IA produz ampliação da percepção analítica e redução seletiva de vieses, conforme os dados de Almashawreh et al.

(2024) e Cristofaro e Giardino (2025) evidenciam em contextos empíricos distintos. No nível organizacional, os benefícios de maior agilidade e precisão nas decisões coexistem com o risco de dependência tecnológica e de atrofia de competências estratégicas internas, como os estudos de Klonek e Parker (2025) e Ciccola et al. (2025) documentam. No nível ético e social, emergem dilemas de responsabilidade e transparência algorítmica, especialmente relevantes quando gestores operam sob sistemas cujos mecanismos internos são opacos e cujos efeitos sobre o bem-estar psicológico são subestimados pelas organizações. Esses *outputs* retroalimentam o sistema: as condições favoráveis geradas por capacidades dinâmicas bem desenvolvidas, conforme demonstrado por Kao (2025), tornam-se *inputs* qualificados para os ciclos decisórios subsequentes, enquanto a atrofia cognitiva produzida pelo uso irrefletido degrada progressivamente a qualidade dos insumos humanos que o modelo necessita para operar de forma eficaz.

5 CONSIDERAÇÕES FINAIS

Este trabalho teve como objetivo geral analisar de que forma o uso da inteligência artificial como suporte à decisão contribui para aprimorar a alocação de recursos estratégicos ou para comprometer a autonomia decisória em pequenas e médias empresas. Os resultados obtidos demonstram que os efeitos da IA sobre a gestão estratégica das PMEs são simultaneamente positivos e negativos, configurando uma dualidade que não se resolve pela adoção ou pela rejeição da tecnologia, mas pelo modelo de governança que orienta seu uso no cotidiano organizacional.

Do ponto de vista das contribuições teóricas, esta pesquisa avança ao integrar, em um único modelo conceitual, *frameworks* que até então eram mobilizados de forma isolada na literatura: a teoria da racionalidade limitada de Simon (1979), as heurísticas e vieses cognitivos de Kahneman (2011), o Paradoxo Automação-Aumentação de Raisch e Krakowski (2021) e a teoria das capacidades dinâmicas de Teece, Pisano e Shuen (1997). Ao articular essas perspectivas em torno da realidade específica das PMEs, o trabalho propõe um modelo com três camadas interdependentes, *Inputs*, *Processos* e *Outputs*, que descreve o funcionamento sistêmico da decisão estratégica mediada pela IA e permite identificar os pontos em que a tecnologia amplia a racionalidade do gestor e aqueles em que a compromete. A discussão sobre equidade tecnológica, evidenciada pelo achado de que PMEs de menor porte se beneficiam proporcionalmente mais da adoção de IA (Almashawreh et al., 2024), representa uma contribuição adicional com implicações para políticas públicas de fomento à digitalização. A identificação do fenômeno de dependência de trajetória (*path dependency*) como risco estrutural das PMEs que dependem de fornecedores externos de IA amplia o debate teórico sobre os limites das capacidades dinâmicas nesse segmento.

Do ponto de vista das contribuições práticas, os resultados oferecem orientações concretas para gestores de PMEs que buscam adotar a IA de forma estrategicamente responsável. A contribuição central consiste na consolidação do Paradigma *Human+* como referencial operacional (Bastone et al., 2025): o gestor deve atuar como curador ativo dos *outputs* algorítmicos, integrando as recomendações da IA com o conhecimento tácito, o contexto competitivo e os valores organizacionais que nenhum modelo computacional consegue capturar integralmente. Essa postura exige o desenvolvimento de literacia algorítmica mínima e a implementação de protocolos internos de validação das recomendações. Um mecanismo concreto e de baixo custo para operacionalizar esses protocolos é a revisão por pares interna: antes de agir sobre recomendações algorítmicas em decisões estratégicas relevantes, como alocação de recursos, entrada em novos mercados ou reestruturações, o gestor submete o *output* da IA à análise crítica de ao menos um colega interno. Essa prática reduz a ancoragem cognitiva nas recomendações automáticas, identificada empiricamente por Cristofaro e

Giardino (2025) e Kleinert e Urbig (2026) como um dos principais vetores de comprometimento do julgamento estratégico, e cria um registro colaborativo de decisão implementável em PMEs sem custos adicionais.

Para desenvolvedores e fornecedores de plataformas de IA destinadas a PMEs, os achados reforçam a necessidade de interfaces que tornem os mecanismos de decisão dos algoritmos mais transparentes e auditáveis, reduzindo o efeito de vigilância opaca sobre o bem-estar psicológico e a autonomia dos gestores (Klonek; Parker, 2025). Para formuladores de políticas públicas e entidades de fomento, os resultados indicam que programas de capacitação digital precisam incluir, além de treinamentos técnicos de uso das ferramentas, formação em pensamento crítico algorítmico, habilitando os gestores a questionar, validar e contextualizar as recomendações dos sistemas que adotam.

No que se refere às limitações desta pesquisa, a revisão sistemática da literatura está condicionada ao conjunto de estudos disponíveis e indexados na base consultada até a data de busca. O portfólio final de oito artigos, representativo do estado atual do conhecimento, não esgota a totalidade das perspectivas possíveis sobre o tema. A restrição aos artigos de acesso aberto (*Open Access*) e acesso antecipado (*Early Access*) reduziu o corpus analisado a uma parcela da produção científica disponível, excluindo trabalhos publicados sob restrição de acesso que poderiam ampliar ou contrastar os achados aqui consolidados. A concentração geográfica dos estudos empíricos em países como Jordânia, Alemanha, Itália e China limita a extrapolação direta dos achados para o contexto brasileiro, em que as PMEs operam sob condicionantes institucionais, de infraestrutura digital e de acesso a capital consideravelmente distintos. A ausência de estudos longitudinais de longo prazo é compreensível dado que a adoção massiva de IA generativa em PMEs é um fenômeno recente, o que ainda não permitiu à comunidade acadêmica acumular evidências temporalmente extensas sobre a evolução dos efeitos identificados.

Para pesquisas futuras, recomenda-se a realização de estudos empíricos primários com PMEs brasileiras e latino-americanas, de modo a verificar se os padrões identificados na literatura internacional se repetem em contextos de menor maturidade digital. Sugere-se, ainda, a condução de revisões sistemáticas com uma gama mais ampla de artigos, sem a restrição a trabalhos de acesso aberto e acesso antecipado, o que permitiria incorporar ao corpus estudos publicados sob restrição de acesso e potencialmente ampliar ou revisar as conclusões aqui apresentadas. Estudos longitudinais que acompanhem a mesma organização ao longo de múltiplos ciclos de adoção de IA seriam úteis para capturar a dinâmica temporal da transição entre automação e ampliação cognitiva, bem como os efeitos de longo prazo sobre as competências estratégicas internas. Pesquisas futuras poderiam ainda investigar o papel moderador das características do gestor, como experiência prévia, tolerância à ambiguidade e perfil cognitivo, sobre a propensão ao *cognitive offloading*, lacuna que o portfólio desta revisão indica, mas não responde empiricamente. Por fim, estudos experimentais que testem diretamente protocolos de governança algorítmica em PMEs, incluindo a revisão por pares interna aqui proposta, representariam uma contribuição de alto valor prático para o campo, ao transformar as recomendações conceituais aqui sistematizadas em evidências operacionais verificáveis.

REFERÊNCIAS

ABELSON, Robert P.; LEVI, Ariel. Decision making and decision theory. In: LINDZEY, Gardner; ARONSON, Elliot (ed.). **The Handbook of Social Psychology**. 3. ed. New York: Random House, 1985. v. 1, p. 231-310.

AGUIAR-COSTA, Ana C. S. *et al.* Satisfação do cliente na prestação de serviços com Inteligência Artificial: uma análise bibliométrica. **Brazilian Journal of Development**, Curitiba, v. 8, n. 6, p. 44101-44119, jun. 2022.

ALMASHAWREH, Ra'ed *et al.* AI Adoption in Jordanian SMEs: The Influence of Technological and Organizational Orientations. **Global Business Review**, p. 1-18, June 2024. Disponível em: <https://journals.sagepub.com/home/gbr>. Acesso em: 28 set. 2025.

AYDIN, Ömer; KARAARSLAN, Enis. OpenAI ChatGPT generated literature review: Digital twin in healthcare. In: AYDIN, Ömer (ed.). **Emerging Computer Technologies**. Izmir: Cinius Publications, 2022. v. 2, p. 22-31.

BARNEY, Jay. Firm Resources and Sustained Competitive Advantage. **Journal of Management**, v. 17, n. 1, p. 99-120, mar. 1991

BASTONE, Anna. The Digitalisation Phenomenon within the Healthcare Sector: Transitioning from Industry 4.0 to Society 5.0 through GenAI. **Journal of Business Research**, v. 182, p. 114-129, Apr. 2025. Disponível em: <https://doi.org/10.1016/j.jbusres.2025.114129>. Acesso em: 30 mar. 2026.

BRYNJOLFSSON, Erik; McAfee, Andrew. **Machine, Platform, Crowd**: harnessing our digital future. New York: W. W. Norton, 2017.

DAVIDSSON, Per. Entrepreneurial opportunities and the entrepreneurship nexus: a re-conceptualization. **Journal of Business Venturing**, v. 30, n. 5, p. 674-695, set. 2015.

GLIKSON, Ella; WOOLLEY, Anita Williams. Human trust in artificial intelligence: review of empirical research. **Academy of Management Annals**, v. 14, n. 2, p. 627-660, 2020.

BERENTE, Nicholas *et al.* Managing Artificial Intelligence. **MIS Quarterly**, v. 45, n. 3, p. 1433-1450, set. 2021.

KAO, Ping-Jen. AI-augmented dynamic capabilities for business sustainability: enactment through humanistic and instrumental approaches. **Journal of Information Technology**, v. 0, n. 0, p. 1-17, 2025. Disponível em: <https://doi.org/10.1177/02683962251392284>. Acesso em: 30 mar. 2026.

CRISTOFARO, Matteo; GIARDINO, Pierluigi. Generative artificial intelligence for managerial foresight: Bounded rationality, cognitive engagement, and the mediating microfoundations of innovative behavior. **Futures**, v. 168, p. 103-121, Apr. 2025. Disponível em: <https://doi.org/10.1016/j.futures.2025.103121>. Acesso em: 30 mar. 2026.

DUAN, Yanqing *et al.* Artificial intelligence for decision making in the era of Big Data – evolution, challenges and research agenda. **International Journal of Information Management**, v. 48, p. 63-71, out. 2019.

DUQUE-PEREIRA, Ives da S.; MOURA, Sergio A. de. Compreendendo a Inteligência Artificial Generativa na perspectiva da Língua. **SciELO Preprints**, 2023. DOI:

10.1590/SciELOPreprints.7077. Disponível em:
<https://doi.org/10.1590/SciELOPreprints.7077>. Acesso em: 28 set. 2025.

EISENHARDT, Kathleen M.; ZBARACKI, Mark J. Strategic decision making. **Strategic Management Journal**, v. 13, n. S2, p. 17-37, Winter 1992.

FÉLIX, Elísio G. F. *et al.* O impacto da Inteligência Artificial no mercado de trabalho brasileiro. **Journal of Management & Technology**, v. 8, n. 22, p. 119-137, 2024.

FLORIDI, Luciano *et al.* AI4People—An Ethical Framework for a Good AI Society: Opportunities, Risks, Principles, and Recommendations. **Minds and Machines**, v. 28, n. 4, p. 689-707, nov. 2018.

GERLICH, Michael. AI Tools in Society: Impacts on Cognitive Offloading and the Future of Critical Thinking. **Societies**, v. 15, n. 1, p. 6, jan. 2025.

GÉRON, Aurélien. **Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow**: concepts, tools, and techniques to build intelligent systems. 2. ed. Sebastopol: O'Reilly Media, 2019. 819 p. ISBN 978-1492032649.

GERNONE, Fausto; TEECE, David J. **Competing in the Age of AI**: Firm Capabilities and Antitrust Considerations. Berkeley: University of California, Berkeley, 2024.

GIL, Antonio Carlos. **Métodos e técnicas de pesquisa social**. 6. ed. São Paulo: Atlas, 2008.
GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep learning**. Cambridge: MIT Press, 2016. 800 p. ISBN 978-0262035613.

HAENLEIN, Michael; KAPLAN, Andreas. A Brief History of Artificial Intelligence: On the Past, Present, and Future of Artificial Intelligence. **California Management Review**, v. 61, n. 4, p. 5-14, jul. 2019.

IDC. **Worldwide Artificial Intelligence Spending Guide**. Framingham: International Data Corporation, 2023.

JARRAHI, Mohammad Hossein. Artificial intelligence and the future of work: Human-AI symbiosis in organizational decision making. **Business Horizons**, v. 61, n. 4, p. 577-586, jul./ago. 2018.

JURAFSKY, Dan; MARTIN, James H. **Speech and language processing**: an introduction to natural language processing, computational linguistics, and speech recognition. 3. ed. Stanford: Stanford University, 2024. Disponível em: <https://web.stanford.edu/~jurafsky/slp3/>. Acesso em: 29 set. 2025.

KAHNEMAN, Daniel. **Rápido e devagar**: duas formas de pensar. Tradução de Cássio de Arantes Leite. Rio de Janeiro: Objetiva, 2011.

CICCOLA, Roberta *et al.* Artificial Intelligence and sustainability reporting: rethinking intellectual capital in the age of AI. **Journal of Intellectual Capital**, v. 26, n. 2, p. 289-318, 2025. Disponível em: <https://doi.org/10.1108/JIC-09-2024-0313>. Acesso em: 30 mar. 2026.

KLEINERT, Simon; URBIG, Diemo. Startup Evaluations with Generative Artificial Intelligence: An Exploratory Study on Early-Stage Investments and Survival Predictions by Large Language Models. **Entrepreneurship Theory and Practice**, v. 50, n. 2, p. 1-43, Mar. 2026. Disponível em: <https://doi.org/10.1177/10422587261430320>. Acesso em: 30 mar. 2026.

KLONEK, Florian; PARKER, Sharon. Does AI at Work Increase Stress? Text Mining Social Media About Human–AI Team Processes and AI Control. **Journal of Organizational Behavior**, v. 47, n. 4, p. 512-531, June 2025. Disponível em: <https://doi.org/10.1002/job.2841>. Acesso em: 30 mar. 2026.

LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep learning. **Nature**, v. 521, n. 7553, p. 436-444, maio 2015.

MAITLIS, Sally; CHRISTIANSON, Marlys. Sensemaking in Organizations: Taking Stock and Moving Forward. **The Academy of Management Annals**, v. 8, n. 1, p. 57-125, jun. 2014.

MARCONI, Marina de Andrade; LAKATOS, Eva Maria. **Fundamentos de metodologia científica**. 8. ed. São Paulo: Atlas, 2017.

MCCARTHY, John *et al.* **A proposal for the Dartmouth summer research project on artificial intelligence**. Hanover, NH: Dartmouth College, 1955. Disponível em: <http://jmc.stanford.edu/articles/dartmouth/dartmouth.pdf>. Acesso em: 22 set. 2025.

MIKALEF, Patrick; GUPTA, Manjul. Artificial intelligence capability: Conceptualization, measurement calibration, and empirical study on its impact on organizational performance. **Information & Management**, v. 58, n. 3, p. 103434, 2021. Disponível em: <https://doi.org/10.1016/j.im.2021.103434>. Acesso em: 29 set. 2025.

MINTZBERG, Henry; RAISINGHANI, Duru; THÉORÊT, André. The structure of "unstructured" decision processes. **Administrative Science Quarterly**, v. 21, n. 2, p. 246-275, jun. 1976.

OLDEMEYER, Lars; JEDE, Alexander; TEUTEBERG, Frank. Investigation of artificial intelligence in SMEs: a systematic review of the state of the art and the main implementation challenges. **Management Review Quarterly**, v. 74, p. 1-43, 2024.

PASCHEN, Jeannette *et al.* Human-AI collaboration in management decision-making. **AI & SOCIETY**, v. 37, p. 869-878, nov. 2020.

RAISCH, Sebastian; KRAKOWSKI, Sebastian. Artificial Intelligence and Management: The Automation–Augmentation Paradox. **Academy of Management Review**, v. 46, n. 1, p. 192-210, jan. 2021.

REMKE, Konstantin *et al.* Complexity Navigation and Dual Enablement: Business Model Innovation at the Intersection of Artificial Intelligence and the Circular Economy. **Journal of Product Innovation Management**, v. 43, n. 1, p. 76-98, Jan. 2026. Disponível em: <https://doi.org/10.1111/jpim.12749>. Acesso em: 30 mar. 2026.

SANTOS, Edicleia A. P. dos; JORGE, Cássia F. B.; WINKLER, Ingrid. O Papel da Inteligência Artificial e Business Intelligence no Processo Decisório Organizacional. **Journal of Management & Technology**, v. 8, n. 22, p. 1-17, 2022.

VON KROGH, Georg. Artificial intelligence in organizations: new opportunities for phenomenon-based theorizing. **Academy of Management Discoveries**, v. 4, n. 4, p. 404-409, 2018.

SIMON, Herbert A. Rational Decision Making in Business Organizations. **The American Economic Review**, v. 69, n. 4, p. 493-513, set. 1979.

SOBREIRA, Vitor. Um panorama da História da Inteligência Artificial e suas aplicações na pesquisa histórica. **Varia Historia**, Belo Horizonte, v. 41, e25035, 2025.

TEECE, David J.; PISANO, Gary; SHUEN, Amy. Dynamic capabilities and strategic management. **Strategic Management Journal**, v. 18, n. 7, p. 509-533, ago. 1997.

TURING, Alan M. Computing machinery and intelligence. **Mind**, [s. l.], v. 59, n. 236, p. 433–460, Oct. 1950.

TVERSKY, Amos; KAHNEMAN, Daniel. Judgment under Uncertainty: Heuristics and Biases. **Science**, v. 185, n. 4157, p. 1124-1131, set. 1974.

VASWANI, Ashish *et al.* Attention is all you need. *In: ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS (NeurIPS)*, 30., 2017, Long Beach. **Proceedings [...]**. Long Beach: NeurIPS, 2017. p. 5998–6008. Disponível em: <https://arxiv.org/abs/1706.03762>. Acesso em: 27 set. 2025.