REVISTA TÓPICOS
ISSN 2965-6672 | Qualis A2

INTELIGÊNCIA ARTIFICIAL NA TOMADA DE DECISÃO GERENCIAL: CONFIANÇA NAS RECOMENDAÇÕES ALGORÍTMICAS E O PAPEL DA SUPERVISÃO HUMANA

ARTIFICIAL INTELLIGENCE IN MANAGERIAL DECISION-MAKING: TRUST IN ALGORITHMIC RECOMMENDATIONS AND THE ROLE OF HUMAN OVERSIGHT

Ciências Sociais Aplicadas • 13/11/2026

REGISTRO DOI: 10.70773/revistatopicos/794524551

Luis Gustavo Silva Batista[1]

Gabriel da Silva Couto Marcondes[2]

Luis Américo Bertolaci Júnior[3]

Denis dos Santos Santiago Pereira[4]

Wagner dos Reis Marques Araújo[5]

RESUMO

Este artigo analisa como a literatura científica caracteriza os fatores associados à aceitação, à rejeição e ao uso crítico de recomendações de inteligência artificial (IA) por gestores, considerando a confiança algorítmica e a supervisão humana. Desenvolveu-se pesquisa bibliográfica de abordagem qualitativa e finalidade descritivo-analítica, com seleção intencional de 12 artigos publicados entre 2021 e 2026, apoiada por referências conceituais e fontes complementares. A síntese temática contemplou quatro eixos: confiança e aversão algorítmica; transparência, explicabilidade e utilização das recomendações; delegação, autonomia e responsabilidade; e qualidade decisória e riscos éticos. Os resultados indicam que a aceitação varia conforme características das tarefas, experiências e condições organizacionais, sem equivaler necessariamente ao uso criterioso ou à melhoria das decisões. Transparência e explicabilidade não apresentam efeitos uniformes sobre a adesão, enquanto a manutenção formal da autoridade humana não garante supervisão efetiva. Os estudos também distinguem eficácia percebida, desempenho aferido e consequências éticas. Conclui-se que a contribuição gerencial da IA deve ser examinada pelas condições que permitem avaliar, contestar e justificar recomendações, e não apenas pela intensidade de sua aceitação. As conclusões estão limitadas à seleção intencional e à diversidade metodológica do corpus.

Palavras-chave: Inteligência artificial; Tomada de decisão gerencial; Confiança algorítmica; Recomendações algorítmicas; Supervisão humana.

ABSTRACT

This article examines how the scientific literature characterizes factors associated with managers' acceptance, rejection, and critical

use of artificial intelligence (AI) recommendations, focusing on trust in algorithms and human oversight. A qualitative, descriptive-analytical literature review was conducted through a purposive selection of 12 articles published between 2021 and 2026, supported by conceptual and complementary sources. The thematic synthesis addressed four areas: trust and algorithm aversion; transparency, explainability, and advice use; delegation, autonomy, and accountability; and decision quality and ethical risks. Findings indicate that acceptance varies with task characteristics, experience, and organizational conditions, and does not necessarily imply critical use or improved decisions. Transparency and explainability do not have uniform effects on adherence to recommendations, while retaining formal human decision authority does not guarantee effective oversight. The studies also distinguish perceived effectiveness, measured performance, and ethical consequences. The review concludes that the managerial contribution of AI should be assessed in terms of the conditions that enable decision-makers to evaluate, challenge, and justify recommendations, rather than simply the extent to which they accept them. Conclusions are limited by the purposive selection and methodological diversity of the corpus.

Keywords: Artificial intelligence; Managerial decision-making; Algorithmic trust; Algorithmic recommendations; Human oversight.

1. INTRODUÇÃO

A inteligência artificial (IA) vem sendo incorporada a atividades gerenciais que exigem interpretar informações, estimar resultados e escolher entre alternativas. Em tais situações, sistemas algorítmicos podem oferecer previsões e recomendações, modificando não apenas os recursos disponíveis ao gestor, mas também a

organização do processo decisório. Shrestha, Ben-Menahem e von Krogh (2019) distinguem diferentes arranjos de participação humana e algorítmica, indicando que a adoção de IA envolve escolhas sobre como distribuir tarefas e autoridade entre pessoas e sistemas.

Entretanto, a disponibilidade de uma recomendação não assegura sua aceitação nem sua utilização criteriosa. A literatura sobre confiança em IA identifica fatores técnicos e contextuais que influenciam a relação das pessoas com esses sistemas (Glikson; Woolley, 2020). Além disso, pesquisas sobre aversão e valorização algorítmica mostram que indivíduos podem reagir de maneiras distintas ao aconselhamento produzido por algoritmos, dependendo das condições em que ele é apresentado e avaliado (Dietvorst; Simmons; Massey, 2015; Logg; Minson; Moore, 2019). Desse modo, não basta investigar se uma tecnologia é considerada confiável: importa compreender como essa avaliação se relaciona à decisão efetivamente tomada.

No ambiente organizacional, essa questão adquire relevância adicional porque a aceitação de uma recomendação pode envolver exigências de desempenho, limites de conhecimento e mecanismos de responsabilização. Pesquisas sobre utilização de conselhos baseados em aprendizado de máquina e sobre a responsabilidade dos decisores evidenciam a importância de considerar tanto as características das informações quanto as condições em que o gestor precisa justificar suas escolhas (Aschauer; Sohn; Hirsch, 2024; Sturm et al., 2023). Em decisões com consequências para outras pessoas, também se torna necessário examinar possíveis implicações éticas do apoio algorítmico (Voiseux; Zhou; Huang, 2025).

Esses debates, embora relacionados, investigam fenômenos que não devem ser tratados como equivalentes: confiança, preferência, intenção de delegar, utilização de recomendações e qualidade decisória. A diversidade de conceitos, métodos e contextos torna relevante uma leitura que coloque os resultados em diálogo e considere suas limitações. Sob essa perspectiva, a questão não se restringe a identificar fatores que aumentam a adesão à IA, mas inclui compreender quando suas recomendações podem ser aceitas, examinadas criticamente ou rejeitadas.

Diante disso, esta pesquisa busca responder à seguinte questão: como a literatura científica caracteriza a aceitação, a rejeição e a utilização crítica de recomendações de inteligência artificial por gestores nos processos de tomada de decisão? O objetivo geral consiste em analisar os fatores associados a esses comportamentos, considerando a confiança algorítmica e o papel da supervisão humana. Especificamente, busca-se identificar fatores relacionados à confiança e à aceitação das recomendações; examinar a intervenção humana, a autonomia e a responsabilidade gerencial; e comparar benefícios, limitações e possibilidades de complementaridade entre o aconselhamento algorítmico e o julgamento humano. Para tanto, desenvolveu-se uma pesquisa bibliográfica qualitativa, com um corpus analítico de 12 artigos publicados entre 2021 e 2026 e apoio de referências conceituais e documentais complementares.

A contribuição pretendida é articular perspectivas sobre confiança, transparência, autonomia, responsabilidade e qualidade da decisão, sem pressupor que maior aceitação algorítmica corresponda, necessariamente, a melhores resultados. Além desta introdução, o artigo apresenta o referencial teórico, os procedimentos

metodológicos, a discussão organizada em quatro eixos temáticos e as considerações finais.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. Inteligência Artificial Como Suporte à Decisão Gerencial

A tomada de decisão gerencial envolve selecionar alternativas diante de objetivos, informações e restrições organizacionais. Nesse processo, sistemas de inteligência artificial (IA) podem apoiar a análise de dados, produzir previsões e oferecer recomendações para diferentes situações administrativas. Neste artigo, o interesse recai sobre a IA como fonte de aconselhamento decisório, isto é, sobre situações em que uma orientação algorítmica pode ser aceita, modificada ou rejeitada por um responsável humano. Essa delimitação distingue o apoio à decisão da automação integral de atividades.

Shrestha, Ben-Menahem e von Krogh (2019) argumentam que a organização das decisões apoiadas por IA depende de características como a delimitação das alternativas disponíveis, a interpretabilidade, a velocidade e a possibilidade de replicação das decisões. Os autores distinguem três estruturas de interação: delegação integral à IA, processos híbridos sequenciais — nos quais humanos e sistemas atuam em etapas diferentes — e decisões que agregam contribuições humanas e algorítmicas. Trata-se de uma classificação teórica dos arranjos decisórios, e não de uma indicação de que algum deles seja superior em qualquer circunstância.

Assim, a incorporação de IA à gestão não altera apenas os instrumentos de análise; ela também pode modificar a distribuição de tarefas e a forma de exercer o julgamento. Para compreender

esse processo, é necessário examinar tanto as características do aconselhamento algorítmico quanto a disposição dos profissionais para considerá-lo.

2.2. Confiança, Aceitação e Aversão Algorítmica

A confiança constitui um conceito relevante para a relação entre pessoas e sistemas de IA, mas não se confunde com sua utilização. Em uma revisão de pesquisas empíricas, Glikson e Woolley (2020) identificaram fatores associados à formação da confiança, entre eles a transparência, a confiabilidade percebida, a forma de apresentação do sistema e suas capacidades. As autoras também distinguem componentes cognitivos e emocionais da confiança, ressaltando que a interação com IA não produz necessariamente a mesma resposta em todos os contextos.

Duas noções ajudam a compreender essa variabilidade: aversão algorítmica, relacionada à tendência de evitar algoritmos em determinadas condições, e valorização algorítmica, caracterizada pela maior disposição para considerar conselhos apresentados como provenientes de algoritmos. Esses fenômenos foram investigados, respectivamente, por Dietvorst, Simmons e Massey (2015) e Logg, Minson e Moore (2019). Embora apontem comportamentos diferentes, não constituem categorias fixas de gestores: as respostas podem depender da tarefa, da experiência, das comparações disponíveis e do modo como o aconselhamento é apresentado.

Por essa razão, é importante distinguir confiança, entendida como avaliação ou expectativa em relação ao sistema; aceitação, como disposição favorável à recomendação; e utilização, como incorporação do conselho à decisão. Essas dimensões podem estar

relacionadas, mas uma não comprova automaticamente as demais. A distinção orienta a análise dos estudos empíricos desenvolvida na seção de resultados e discussão.

2.3. Autonomia, Supervisão e Responsabilidade Humana

O uso gerencial de IA exige considerar quem conserva a autoridade para decidir e como se estabelece a responsabilidade pelos resultados. Nos arranjos descritos por Shrestha, Ben-Menahem e von Krogh (2019), a participação humana varia conforme a estrutura adotada: pode anteceder, suceder ou ocorrer conjuntamente à contribuição algorítmica. Por isso, a expressão supervisão humana não deve ser reduzida à presença formal de uma pessoa no processo, mas examinada à luz de sua possibilidade de compreender a recomendação e exercer julgamento sobre ela.

A responsabilidade também deve ser diferenciada da simples utilização do conselho. Aschauer, Sohn e Hirsch (2024) e Kotzian, Bauch e Weißenberger (2025) abordam mecanismos distintos ligados à responsabilização gerencial: a possibilidade de compartilhar consequências negativas com um conselheiro e a exigência de justificar decisões perante superiores. Esses mecanismos evidenciam a relevância do contexto organizacional para compreender a relação entre aconselhamento, autonomia e prestação de contas, sem pressupor que a manutenção da decisão final humana garanta, por si só, uma avaliação crítica.

Neste trabalho, o uso crítico de recomendações algorítmicas é compreendido como a possibilidade de examinar sua pertinência à tarefa, considerar suas limitações e justificar a decisão de segui-las ou contrariá-las. Trata-se de uma delimitação analítica adotada na

revisão, e não de um modelo cuja eficácia tenha sido previamente demonstrada. Com essa base conceitual, a pesquisa examina como os estudos selecionados caracterizam as condições associadas à aceitação, à rejeição e ao emprego criterioso da IA na gestão.

3. METODOLOGIA

3.1. Caracterização da Pesquisa

Esta pesquisa caracteriza-se como bibliográfica, de abordagem qualitativa e finalidade descritivo-analítica. Busca compreender como a literatura científica caracteriza fatores associados à aceitação, à rejeição e ao uso crítico de recomendações de inteligência artificial (IA) por gestores e profissionais envolvidos em decisões organizacionais.

Adotou-se seleção intencional de trabalhos pertinentes ao problema, seguida de síntese temática crítica. Não se trata de revisão sistemática ou metanálise: o propósito foi confrontar evidências de diferentes métodos e contextos, identificando convergências, divergências e limites de interpretação.

3.2. Procedimentos de Busca e Seleção da Literatura

O levantamento abrangeu publicações de 2015 a novembro de 2026, com atenção especial à produção recente. Foram realizadas e documentadas consultas na SciELO, na SPELL e no Portal de Periódicos CAPES. Empregaram-se, entre outras expressões documentadas, “inteligência artificial” AND “tomada de decisão”, “inteligência artificial” AND “gestores”, “inteligência artificial” AND “confiança” e artificial intelligence AND managerial decision-making.

Na SPELL, também se utilizaram combinações com “decisão” e “tomada de decisão” em buscas por título e resumo.

Os registros foram examinados quanto à pertinência ao processo decisório organizacional, ao método empregado e à possibilidade de leitura integral. Foram considerados elegíveis artigos científicos com evidências sobre confiança, resistência, aceitação, transparência, delegação, supervisão, responsabilização ou qualidade das decisões apoiadas por IA. Excluíram-se duplicatas, trabalhos distantes do problema, materiais sem acesso integral suficiente e estudos cujas inconsistências inviabilizavam a interpretação segura dos achados. A seleção resultou em 12 artigos publicados entre 2021 e 2026, dos quais dez integravam o núcleo inicialmente fichado e dois foram incorporados após reavaliação da elegibilidade.

A delimitação do corpus a 12 artigos decorreu da pertinência direta à pergunta de pesquisa e da possibilidade de confrontar resultados empíricos obtidos com métodos, amostras e desfechos distintos. Privilegiou-se a profundidade da leitura e a comparação crítica das evidências disponíveis, sem pretensão de esgotar a produção científica ou de afirmar saturação teórica.

As consultas não constituem um fluxo exaustivo de identificação e exclusão de estudos únicos. Na SciELO, por exemplo, uma busca apresentou 59 ocorrências, incluindo nove repetições internas; na SPELL, uma consulta exibiu 97 registros, mas apenas 80 foram disponibilizados para a triagem documental. O lote exportado do Portal CAPES continha 87 entradas bibliográficas, e o filtro utilizado não abrangia publicações de 2026. Os três artigos desse ano foram analisados por meio de seus textos integrais e conferidos nas páginas editoriais dos periódicos, sem serem atribuídos ao lote

filtrado da CAPES. Como houve sobreposição entre consultas e exportação parcial de resultados, não se somaram os totais brutos nem se atribuiu à revisão uma contagem consolidada de estudos únicos recuperados.

3.3. Organização e Análise dos Estudos

Os 12 artigos foram fichados em matriz com referência bibliográfica, contexto, desenho metodológico, participantes, medidas, resultados, limitações e localização das evidências. A comparação organizou-se em quatro eixos: (i) confiança, aceitação e aversão algorítmica; (ii) transparência, explicabilidade e utilização das recomendações; (iii) delegação, autonomia e responsabilidade humana; e (iv) qualidade decisória e riscos éticos.

Na síntese, distinguiram-se confiança e preferência, intenção de delegar, uso relatado, comportamento observado, qualidade percebida e desempenho aferido. As interpretações desta revisão foram explicitadas separadamente dos resultados observados nos estudos.

Dietvorst, Simmons e Massey (2015) e Logg, Minson e Moore (2019) foram utilizados como referências conceituais, sem integrar a contagem do corpus principal. A tese de Souza (2023) e o estudo de Guedes e Oliveira Júnior (2024) constituíram fontes complementares, igualmente identificadas à parte.

As principais limitações são o caráter intencional da seleção, a recuperação parcial de alguns registros, a indisponibilidade integral de determinados trabalhos e a heterogeneidade de países, setores, amostras e medidas. Por isso, a revisão não pretende estimar a

prevalência das respostas gerenciais nem generalizar seus resultados para todas as organizações.

4. RESULTADOS E DISCUSSÃO

4.1. Caracterização dos Estudos Selecionados

O corpus analítico reúne 12 artigos publicados entre 2021 e 2026: um em 2021, um em 2022, três em 2023, um em 2024, três em 2025 e três em 2026. O levantamento mais amplo alcançou estudos desde 2015, mas os trabalhos clássicos de Dietvorst, Simmons e Massey (2015) e Logg, Minson e Moore (2019) integram apenas a fundamentação conceitual.

Os estudos apresentam sete delineamentos experimentais, três levantamentos quantitativos e duas investigações qualitativas por entrevistas. Foram examinados contextos como finanças, agronegócio, recrutamento, previsão gerencial e pós-venda industrial. Nem todas as amostras são compostas por gestores em exercício: alguns experimentos empregaram participantes em tarefas gerenciais simuladas. O Quadro 1 sintetiza seus perfis.

Quadro 1. Caracterização dos artigos integrantes do corpus analítico

Autores e ano	Método e participantes	Contexto investigado	Foco da pesquisa
Haesevoets et al. (2021)	Cinco estudos com 1.025 gestores, no total	Reino Unido	Aceitação de diferentes níveis de participação humana e algorítmica

Bandeira, Móta e Behr (2022)	Pesquisa qualitativa com cinco entrevistados, entre gestores e produtores rurais	Agronegócio brasileiro	Uso da IA como apoio ao processo decisório
Blumen e Cepellos (2023)	Pesquisa qualitativa com 12 profissionais de recrutamento e seleção	Empresas farmacêuticas em São Paulo	Benefícios, resistências e preservação do contato humano
Mahmud, Islam e Mitra (2023)	Levantamento com 179 gestores	Instituições financeiras de Bangladesh	Barreiras organizacionais e individuais associadas à aversão algorítmica
Sturm et al. (2023)	Levantamento com 239 decisores, cada um relatando uma decisão	Decisões organizacionais envolvendo aprendizado de máquina	Fatores relacionados à utilização de recomendações algorítmicas
Aschauer, Sohn e Hirsch (2024)	Experimento com 143 gestores	Contexto gerencial na Alemanha, Áustria e Suíça	Aceitação de conselhos e compartilhamento de responsabilidade
Omura e Francisco (2025)	Dois experimentos com 320 participantes no total	Decisões hipotéticas de contratação nos Estados Unidos	Complexidade da tarefa e intenção de delegar decisões à IA
Kotzian, Bauch e Weißenberger (2025)	Experimento com 248 participantes	Simulação de decisão gerencial nos Estados Unidos	Explicações, origem do conselho e responsabilização

Voiseux, Zhou e Huang (2025)	Experimento principal com 379 gestores	Decisões simuladas de remuneração	Recomendações de IA, sobrecarga decisória e consciência moral
Cao, Duan e Edwards (2026)	Levantamento com 300 gestores	Organizações do Reino Unido	Confiabilidade da IA, utilização e eficácia decisória percebida
Kotzian, Weißenberger e Prinz (2026)	Dois experimentos com 138 e 204 participantes	Tarefas de previsão empresarial	Mecanismos comportamentais associados ao uso de algoritmos
Schempp, Jung e Sturm (2026)	Experimento organizacional com 30 profissionais	Departamento de pós-venda da Porsche, Alemanha	Integração de recomendações humanas e algorítmicas e qualidade da decisão

Fonte: Elaboração própria, com base nos 12 artigos selecionados (2026).

A diversidade de países e atividades amplia o contraste entre situações, mas limita extrapolações. Os estudos de Bandeira, Móta e Behr (2022) e Blumen e Cepellos (2023) abordam contextos brasileiros; Omura e Francisco (2025), embora vinculados à produção acadêmica brasileira, investigaram participantes dos Estados Unidos.

Também variam os desfechos: Haesevoets et al. (2021) analisaram preferências por arranjos decisórios; Omura e Francisco (2025), intenção de delegar; Sturm et al. (2023), utilização relatada; Cao, Duan e Edwards (2026), eficácia percebida; e Schempp, Jung e Sturm (2026), desempenho em tarefas com indicadores de erro.

Essas medidas não são equivalentes e serão diferenciadas na discussão.

4.2. Confiança, Aceitação e Aversão às Recomendações Algorítmicas

A literatura não descreve uma aceitação uniforme do aconselhamento algorítmico. Confiança, preferência por uma fonte e incorporação efetiva de recomendações são dimensões relacionadas, mas distintas; sua manifestação depende da tarefa, da experiência e das condições de escolha.

Dietvorst, Simmons e Massey (2015) observaram, em tarefas experimentais de previsão, que erros percebidos dos algoritmos podiam levar participantes a evitá-los mesmo quando seu desempenho superava o humano. Em sentido aparentemente oposto, Logg, Minson e Moore (2019) identificaram situações de valorização do aconselhamento algorítmico, menos frequentes quando os participantes comparavam o conselho à própria estimativa ou tinham experiência na tarefa. Os resultados não se anulam: examinam configurações diferentes de comparação, erro e julgamento.

Mahmud, Islam e Mitra (2023), em levantamento com 179 gestores de instituições financeiras de Bangladesh, identificaram associações significativas da aversão com barreiras percebidas de valor, tradição e imagem; as barreiras de uso e risco não foram significativas no modelo. Os achados destacam avaliações profissionais e institucionais, mas não estabelecem relações causais generalizáveis para todos os setores.

Em cinco estudos com 1.025 gestores do Reino Unido, Haesevoets et al. (2021) encontraram maior aceitação de arranjos colaborativos com predominância da contribuição humana, em torno de 70%. Esse percentual expressa preferência, e não proporção ideal comprovada de responsabilidades. Kotzian, Weißenberger e Prinz (2026), em experimentos de previsão, encontraram evidências limitadas de aversão e fraca associação entre confiança declarada e uso das previsões; destacaram a atenção seletiva à superioridade do conselho humano e o apego à estimativa própria.

No Brasil, Blumen e Cepellos (2023) relataram, em entrevistas com 12 recrutadores, ganhos percebidos na triagem e preocupações com a perda de contato humano e a exclusão de candidatos adequados. Seu objeto incluiu IA e outras tecnologias de seleção, que não devem ser confundidas. Bandeira, Móta e Behr (2022), com cinco participantes do agronegócio, também evidenciaram a importância atribuída ao julgamento humano. São percepções situadas, não provas de superioridade geral da decisão humana.

O confronto indica que resistir à IA não decorre necessariamente de desconhecimento e que aceitá-la não comprova confiança justificada. O desafio para a gestão é possibilitar avaliação criteriosa do conselho, em vez de tratar maior adesão como objetivo suficiente.

4.3. Transparência, Explicabilidade e Utilização das Recomendações

Transparência e explicabilidade são relevantes, mas distintas: a primeira diz respeito a informações sobre o funcionamento, os dados e os limites de um sistema; a segunda, às razões que

permitem compreender determinada recomendação. Ambas podem influenciar a avaliação gerencial sem necessariamente produzir maior adesão.

Em levantamento com 239 decisores, cada qual relatando uma decisão organizacional, Sturm et al. (2023) encontraram associações positivas entre uso relatado de recomendações e qualidade da informação ($\beta = 0{,}46$; $p < 0{,}001$), confiança nos cientistas de dados ($\beta = 0{,}25$; $p < 0{,}001$) e transparência percebida ($\beta = 0{,}14$; $p = 0{,}037$). A qualidade e a eficiência decisórias também foram avaliadas pelos próprios respondentes; não houve aferição independente de melhora objetiva.

Kotzian, Bauch e Weißenberger (2025), em experimento com 248 participantes, observaram que justificativas favoreceram a utilização de conselhos algorítmicos sob diferentes exigências de prestação de contas. As diferenças entre os padrões de responsabilização são examinadas na seção 4.4; aqui, o achado destaca a relevância das explicações para o aproveitamento das recomendações.

Um contraste importante aparece na tese de Souza (2023). Em experimento com 102 respostas válidas em instituição financeira brasileira, maior transparência reduziu a aderência à recomendação de IA ($p = 0{,}0496$); o tipo de decisão, isoladamente, não foi significativo ($p = 0{,}1158$), e a interação alcançou apenas o nível de 10% ($p = 0{,}0752$). Como aderência significava proximidade ao valor sugerido pelo sistema, discordar não equivalia necessariamente a decidir pior. Esses resultados são atribuídos exclusivamente à tese consultada.

O contraste com Sturm et al. (2023) não configura contradição direta: um estudo mediu transparência percebida e utilização autorrelatada; o outro manipulou transparência e observou aderência em uma tarefa. Uma interpretação possível, ainda não demonstrada como mecanismo geral, é que explicações também forneçam elementos para rejeitar uma orientação fundamentadamente.

Cao, Duan e Edwards (2026), com 300 gestores do Reino Unido, relacionaram confiabilidade percebida da IA — incluindo ética, transparência e explicabilidade — a utilização relatada e eficácia decisória percebida. Como as dimensões foram avaliadas em conjunto e por questionário, não se pode isolar efeito causal da explicabilidade nem concluir que houve melhoria objetiva. Schempp, Jung e Sturm (2026) associaram a integração ativa de conselhos humanos e algorítmicos a maior precisão em determinadas tarefas, mostrando a importância do modo de utilização.

Em síntese, acesso a explicações, confiança na fonte e aproveitamento do aconselhamento são fenômenos diferentes. A transparência pode contribuir para um julgamento mais informado, mas sua utilidade não deve ser medida apenas pelo aumento da aceitação.

4.4. Delegação Decisória, Autonomia e Responsabilidade Humana

A delegação decisória envolve mais do que a utilização de uma sugestão: diz respeito a quem decide, a quem pode questionar o sistema e a quem responde pelo resultado. Por isso, conservar

autoridade formal não implica, automaticamente, exercer supervisão substantiva.

Omura e Francisco (2025) verificaram, em cenários hipotéticos de contratação nos Estados Unidos, maior intenção de delegar decisões à IA à medida que aumentava a complexidade da tarefa ($p = 0,023$ e $p = 0,006$ nos dois estudos). Entre 134 respostas abertas, aproximadamente 65% defenderam delegação parcial, com decisão final humana. A amostra ampliada do estudo chegou a 320 participantes, sem representar 320 decisões organizacionais reais. Em paralelo, a preferência por participação humana identificada por Haesevoets et al. (2021) reforça a distinção entre aceitar apoio e entregar integralmente a decisão.

O controle humano, contudo, pode conviver com incentivos que distorcem a avaliação. Em experimento com 143 gestores, Aschauer, Sohn e Hirsch (2024) observaram ajustes menores a previsões ruins quando era possível compartilhar a responsabilidade com o conselheiro ($p = 0,008$ no teste principal). Alguns resultados adicionais sobre diferenças entre conselheiros humanos e algorítmicos tiveram significância apenas marginal; o estudo não demonstra que um tipo de conselho seja universalmente mais confiável.

Kotzian, Bauch e Weißenberger (2025) investigaram mecanismo distinto: a exigência de justificar a decisão perante superiores. Para conselhos humanos, o efeito das justificativas sobre a utilização foi maior sob alta responsabilização ($p = 0,039$, teste unilateral); para conselhos algorítmicos, as justificativas favoreceram o uso nas duas condições. Contudo, a interação tripla que comparava esses padrões não alcançou significância a 5% ($p = 0,081$, teste unilateral).

Compartilhar culpa e prestar contas à hierarquia são mecanismos diferentes.

A supervisão também depende da integração efetiva das informações. Schempp, Jung e Sturm (2026) observaram menor engajamento na passagem de decisões individuais para coletivas em um contexto organizacional específico. Como fonte complementar no contexto brasileiro, Guedes e Oliveira Júnior (2024) descreveram o Sistema de Seleção Aduaneira por Aprendizado de Máquina (SISAM), utilizado pela Receita Federal, no qual explicações em linguagem natural apoiam análises e os agentes preservam margem de decisão; o caso não comprova, isoladamente, a eficácia dessa supervisão.

O conjunto permite distinguir três aspectos analíticos da supervisão: autoridade para aceitar ou contrariar a recomendação, capacidade prática de avaliá-la e regras de responsabilização pela escolha. Essa organização é uma interpretação desta revisão, não uma tipologia validada pelos 12 artigos. A assinatura humana, portanto, só indica supervisão efetiva quando acompanhada de condições reais de exame e contestação.

4.5. Qualidade Decisória e Riscos Éticos

A qualidade da decisão não pode ser inferida apenas da aceitação da IA: os estudos medem resultados diferentes, como eficácia percebida, erro de estimativa, intenção de delegação e consciência moral. Convém separar desempenho verificável de avaliações subjetivas e efeitos éticos.

Sturm et al. (2023) associaram a utilização relatada de conselhos de aprendizado de máquina a avaliações favoráveis de qualidade e

eficiência. Cao, Duan e Edwards (2026) também identificaram relações entre uso declarado da IA e eficácia percebida, abrangendo qualidade, velocidade e integridade. Ambos se apoiaram em questionários, sem mensuração independente dos resultados organizacionais.

Schempp, Jung e Sturm (2026) ofereceram evidência de natureza diferente: em tarefas de estimativa de custos com 30 profissionais de pós-venda, compararam previsões com valores financeiros observados e analisaram erros percentuais absolutos. As avaliações subjetivas de qualidade não diferiram significativamente entre condições ($p = 0,21$), enquanto a precisão variou conforme o tipo de conselho e a forma de integração das informações. O estudo não demonstra superioridade universal da combinação humano–IA, e suas observações repetidas não equivalem a participantes independentes adicionais.

A diferença entre recorrer à tecnologia e decidir melhor também aparece em Omura e Francisco (2025), que mediram intenção de delegação, não acerto nas contratações, e em Aschauer, Sohn e Hirsch (2024), que encontraram efeitos relacionados ao compartilhamento da responsabilidade mesmo diante de previsões ruins. Assim, a adoção pode refletir complexidade ou incentivos pessoais, não apenas expectativa de precisão.

Os riscos éticos são ilustrados por Voiseux, Zhou e Huang (2025). Em experimento principal com 379 gestores submetidos a decisões simuladas de remuneração, a interação entre origem do conselho e número de decisões foi significativa para consciência moral ($p = 0,02$). Sob cinco decisões simultâneas, participantes aconselhados por IA reconheceram menos as implicações éticas do que aqueles

aconselhados por humanos (teste direcional, p = 0,006); a diferença não foi observada na condição de decisão única.

No experimento principal, nem o efeito direto da origem do conselho (p = 0,51) nem sua interação com a quantidade de decisões (p = 0,33) foram estatisticamente significativos para escolhas antiéticas. Entretanto, a análise de mediação identificou um caminho indireto associado à consciência moral. Na análise conjunta de dois experimentos suplementares, realizados apenas com múltiplas decisões, os autores observaram maior aceitação de recomendações antiéticas de IA do que de conselheiros humanos. Os dados foram reunidos de diferentes cenários de gestão de pessoas. Como esses experimentos não incluíram uma condição de decisão única, seus resultados não permitem atribuir isoladamente o efeito à quantidade de decisões nem generalizá-lo a qualquer situação organizacional.

No recrutamento, Blumen e Cepellos (2023) registraram receios de filtros automatizados descartarem bons candidatos. Trata-se de percepções de entrevistados, e não de auditoria que tenha comprovado discriminação algorítmica. O estudo lembra, contudo, que decisões sobre pessoas exigem critérios além da rapidez e da produtividade.

Da comparação emergem três dimensões analíticas, não reunidas em um índice empiricamente testado: precisão do resultado quando aferível, qualidade do processo de julgamento e integridade ética. Uma decisão pode avançar em uma delas sem melhorar necessariamente nas demais. Como implicações organizacionais possíveis, destacam-se justificativas documentadas, revisão de recomendações sensíveis e condições de trabalho que favoreçam

análise crítica; o corpus não demonstra a eficácia universal dessas medidas.

4.6. Síntese Crítica: Quando Confiar, Questionar ou Rejeitar a IA?

Os estudos indicam que a resposta gerencial à IA depende do contexto, e não de uma preferência fixa por humanos ou algoritmos. Aversão e valorização foram observadas em condições distintas (Dietvorst; Simmons; Massey, 2015; Logg; Minson; Moore, 2019), enquanto confiança, transparência e utilização apresentam relações distintas conforme a tarefa e o desenho da pesquisa (Souza, 2023; Sturm et al., 2023). Por isso, aumentar a adesão não equivale necessariamente a melhorar a decisão.

A preservação de autoridade humana, por si, tampouco garante exame crítico: intenção de delegar, incentivos de responsabilização e integração de conselhos são fenômenos diferentes (Aschauer; Sohn; Hirsch, 2024; Omura; Francisco, 2025; Schempp; Jung; Sturm, 2026). Os riscos à consciência moral identificados em condições específicas por Voiseux, Zhou e Huang (2025) reforçam a necessidade de observar consequências, e não só desempenho técnico.

Como síntese interpretativa, propõe-se avaliar o uso crítico a partir de três condições complementares: adequação demonstrável do sistema à tarefa, meios efetivos de examinar suas recomendações e respaldo organizacional para aceitá-las ou contrariá-las justificadamente. Não se trata de modelo validado, mas de um modo de organizar o debate sobre quando a confiança na IA pode ser fundamentada e revista.

5. CONSIDERAÇÕES FINAIS

Esta pesquisa buscou compreender como a literatura científica caracteriza os fatores relacionados à aceitação, à rejeição e ao uso crítico de recomendações de inteligência artificial (IA) por gestores. A análise dos 12 artigos selecionados indica que essas respostas não decorrem de um único atributo da tecnologia, mas envolvem percepções individuais, características das tarefas e condições organizacionais. Desse modo, a aceitação de recomendações algorítmicas não deve ser confundida com sua utilização criteriosa ou com a qualidade das decisões produzidas.

Quanto aos fatores associados à confiança e à aceitação, os estudos destacam a experiência do decisor, as barreiras percebidas e as justificativas que acompanham as recomendações (Kotzian; Bauch; Weißenberger, 2025; Kotzian; Weißenberger; Prinz, 2026; Mahmud; Islam; Mitra, 2023). A transparência também se mostrou relevante, embora seus efeitos não sejam uniformes: informações adicionais podem favorecer a utilização de recomendações, mas não asseguram maior adesão em todas as situações (Souza, 2023; Sturm et al., 2023).

Em relação à intervenção humana, à autonomia e à responsabilidade gerencial, os achados sugerem que preservar a autoridade formal do gestor não garante, isoladamente, uma supervisão efetiva. A delegação pode ser influenciada pela complexidade da tarefa e por incentivos relacionados à responsabilização (Aschauer; Sohn; Hirsch, 2024; Omura; Francisco, 2025). Assim, a supervisão exige considerar não apenas quem responde pela decisão, mas também as condições para examinar e, quando necessário, contrariar a recomendação.

Quanto aos benefícios, às limitações e à complementaridade entre IA e julgamento humano, a literatura aponta possibilidades de aprimoramento das decisões, condicionadas à forma como as informações são utilizadas. Ao mesmo tempo, evidencia que precisão, qualidade do julgamento e integridade ética não são dimensões equivalentes (Schempp; Jung; Sturm, 2026; Voiseux; Zhou; Huang, 2025). A contribuição do apoio algorítmico, portanto, não pode ser avaliada exclusivamente pela frequência de aceitação das recomendações.

Diante desses resultados, propõe-se que o desafio gerencial não consiste simplesmente em ampliar a confiança na IA, mas em criar condições para uma confiança fundamentada, crítica e passível de revisão. Isso envolve avaliar a adequação das recomendações às tarefas, preservar a possibilidade de contestação e estabelecer responsabilidades claras. Essa proposição constitui uma síntese interpretativa da revisão, e não um modelo de supervisão empiricamente validado.

Como limitações, destacam-se a seleção intencional de um corpus restrito, a diversidade dos contextos investigados, a utilização de medidas autorrelatadas e cenários experimentais em parte dos estudos, além de restrições de acesso a determinadas publicações. Pesquisas futuras poderão examinar, em situações organizacionais reais, quais práticas de supervisão favorecem decisões simultaneamente precisas, justificáveis e eticamente responsáveis.

REFERÊNCIAS BIBLIOGRÁFICAS

ASCHAUER, Florian; SOHN, Matthias; HIRSCH, Bernhard. Managerial advice-taking—Sharing responsibility with (non)human advisors

trumps decision accuracy. **European Management Review,** v. 21, n. 1, p. 186-203, 2024. DOI: https://doi.org/10.1111/emre.12575

BANDEIRA, Marina Valim; MÓTA, Léia Michele Ferreira de Souza; BEHR, Ariel. Decision-making in agribusiness based on artificial intelligence. **Revista de Administração da UFSM,** v. 15, n. esp., p. 841-853, 2022. DOI: https://doi.org/10.5902/1983465969430

BLUMEN, Daniel; CEPELLOS, Vanessa Martines. Dimensões do uso de tecnologia e Inteligência Artificial (IA) em Recrutamento e Seleção (R&S): benefícios, tendências e resistências. **Cadernos EBAPE.BR,** v. 21, n. 2, e2022-0080, 2023. DOI: https://doi.org/10.1590/1679-395120220080

CAO, Guangming; DUAN, Yanqing; EDWARDS, John S. AI Trustworthiness in Managerial Decision-Making: Ethics, Transparency, and Explainability as Key Drivers. **Journal of Business Ethics,** publicação antecipada on-line, 2026. DOI: https://doi.org/10.1007/s10551-026-06400-x

DIETVORST, Berkeley J.; SIMMONS, Joseph P.; MASSEY, Cade. Algorithm aversion: People erroneously avoid algorithms after seeing them err. **Journal of Experimental Psychology: General,** v. 144, n. 1, p. 114-126, 2015. DOI: https://doi.org/10.1037/xge0000033

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. DOI: https://doi.org/10.5465/annals.2018.0057

GUEDES, Luis; OLIVEIRA JÚNIOR, Moacir. Artificial intelligence adoption in public organizations: a case study. **Future Studies**

Research Journal: Trends and Strategies, v. 16, n. 1, e860, 2024. DOI: https://doi.org/10.24023/FutureJournal/2175-5825/2024.v16i1.860

HAESEVOETS, Tessa; DE CREMER, David; DIERCKX, Kim; VAN HIEL, Alain. Human-machine collaboration in managerial decision making. **Computers in Human Behavior,** v. 119, 106730, 2021. DOI: https://doi.org/10.1016/j.chb.2021.106730

KOTZIAN, Peter; BAUCH, Kai A.; WEISSENBERGER, Barbara E. Accountability and managerial advice-taking: comparing human and algorithmic advisers. **Management Decision,** v. 63, n. 13, p. 545-567, 2025. DOI: https://doi.org/10.1108/MD-07-2024-1618

KOTZIAN, Peter; WEISSENBERGER, Barbara E.; PRINZ, Sonja G. Not So Averse After All: Behavioral Mechanisms Underlying the Use of Algorithms in Managerial Forecasting. **International Journal of Human–Computer Interaction,** v. 42, n. 7, p. 4907-4931, 2026. DOI: https://doi.org/10.1080/10447318.2025.2543988

LOGG, Jennifer M.; MINSON, Julia A.; MOORE, Don A. Algorithm appreciation: People prefer algorithmic to human judgment. **Organizational Behavior and Human Decision Processes,** v. 151, p. 90-103, 2019. DOI: https://doi.org/10.1016/j.obhdp.2018.12.005

MAHMUD, Hasan; ISLAM, A. K. M. Najmul; MITRA, Ranjan Kumar. What drives managers towards algorithm aversion and how to overcome it? Mitigating the impact of innovation resistance through technology readiness. **Technological Forecasting and Social Change,** v. 193, 122641, 2023. DOI: https://doi.org/10.1016/j.techfore.2023.122641

OMURA, Suely Fischer; FRANCISCO, Eduardo de Rezende. Hybrid Business Decisions: Does Task Complexity Uplift Delegation to Artificial Intelligence? **Revista de Administração Contemporânea,** v. 29, n. 6, e250032, 2025. DOI: https://doi.org/10.1590/1982-7849rac2025250032.en

SCHEMPP, Nicole Maria; JUNG, Dominik; STURM, Timo. Exploring the impact of human and machine learning ensemble advice on organizational decision-making processes. **Electronic Markets,** v. 36, art. 57, 2026. DOI: https://doi.org/10.1007/s12525-026-00910-2

SHRESTHA, Yash Raj; BEN-MENAHEM, Shiko M.; VON KROGH, Georg. Organizational Decision-Making Structures in the Age of Artificial Intelligence. **California Management Review,** v. 61, n. 4, p. 66-83, 2019. DOI: https://doi.org/10.1177/0008125619862257

SOUZA, Gustavo Henrique Costa. **Análise da relação entre a transparência da inteligência artificial e a tomada de decisões gerenciais.** 2023. 116 f. Tese (Doutorado em Ciências Contábeis) – Universidade Federal de Pernambuco, Recife, 2023. Disponível em: https://repositorio.ufpe.br/handle/123456789/51312. Acesso em: 10 nov. 2026.

STURM, Timo; PUMPLUN, Luisa; GERLACH, Jin P.; KOWALCZYK, Martin; BUXMANN, Peter. Machine learning advice in managerial decision-making: The overlooked role of decision makers' advice utilization. **The Journal of Strategic Information Systems,** v. 32, n. 4, 101790, 2023. DOI: https://doi.org/10.1016/j.jsis.2023.101790

VOISEUX, Gabrielle; ZHOU, Ryan Tao; HUANG, Hsuan-Che. Accepting the unacceptable in the AI era: When & how AI recommendations drive unethical decisions in organizations. **Behavioral Science &**

Policy, v. 11, n. 2, p. 20-30, 2025. DOI: https://doi.org/10.1177/23794607251384574

---

[1] Discente em Administração pela Universidade do Estado de Minas Gerais. E-mail: acesse o artigo original para visualizar o e-mail

[2] Discente em Administração pela Universidade do Estado de Minas Gerais. E-mail: acesse o artigo original para visualizar o e-mail

[3] Mestre em Administração de Empresas. ORCID: https://orcid.org/0000-0001-7410-5460. E-mail: acesse o artigo original para visualizar o e-mail

[4] Mestre em Economia Aplicada. UEMG, Carangola, Minas Gerais. E-mail: acesse o artigo original para visualizar o e-mail

[5] Doutor em Sociologia, UFRGS. ORCID: https://orcid.org/0000-0003-0793-0043. Lattes: http://lattes.cnpq.br/4203607567762001. E-mail: acesse o artigo original para visualizar o e-mail