Inteligência artificial na análise de conteúdo em gestão:
eficiência e desafios metodológicos

Ygila Evangelista de Lima

Graduação em Administração pela UECE
Especialização em engenharia de Software pela UECE
E-mail: ygilalimadigital@gmail.com

José Iran Batista de Melo Filho

Doutor em Administração pela UECE
Professor de Administração da UNIFOR
E-mail: irandemelo@unifor.br

Ezequiel Alves Lobo

Doutor em Administração UECE
Professor de Administração da UVA
E-mail: ezequiel_alves@uvanet.br

Recebido: 14 mai. 2026 Aprovado: 25 out 2026

Resumo: O avanço da Inteligência Artificial (IA) impacta a produção científica na síntese de grandes volumes textuais. Este estudo analisa o papel da IA na eficiência da análise de conteúdo em pesquisas de gestão, avaliando uma ferramenta de sumarização automática. A pesquisa caracteriza-se como aplicada, exploratória e de abordagem mista. Os resultados indicam redução no tempo de leitura e preservação de conceitos centrais, apesar de limitações de concisão, formatação e interface.

Palavras-chave: Inteligência Artificial. Análise de Conteúdo. Pesquisa em Gestão.

Abstract: The advancement of Artificial Intelligence (AI) is impacting scientific production by facilitating the synthesis of large volumes of text. This study examines the role of AI in enhancing the efficiency of content analysis within management research, evaluating an automated summarization tool. The research is classified as applied and exploratory, employing a mixed-methods approach. The findings indicate a reduction in reading time and the preservation of core concepts, notwithstanding certain limitations regarding conciseness, formatting, and interface.

Keywords: Artificial Intelligence. Content Analysis. Management Research.

Resumen: Resumen: El avance de la Inteligencia Artificial (IA) impacta la producción científica en la síntesis de grandes volúmenes de texto. Este estudio analiza el papel de la IA en la eficiencia del análisis de contenido en investigaciones sobre gestión, evaluando una herramienta de resumen automático. La investigación se caracteriza por ser aplicada, exploratoria y de enfoque mixto. Los resultados indican una reducción en el tiempo de lectura y la preservación de los conceptos centrales, a pesar de ciertas limitaciones en cuanto a concisión, formato e interfaz.

Palabras clave: Inteligencia Artificial. Análisis de Contenido. Investigación en Gestión.

1 Introdução

A inteligência artificial (IA) tem ampliado as possibilidades de processamento e análise de grandes volumes de dados, transformando diferentes setores e atividades. Os avanços em algoritmos, aprendizagem de máquina e processamento de linguagem natural permitiram o desenvolvimento de ferramentas capazes de identificar padrões, sintetizar informações e apoiar a resolução de problemas complexos (Russell; Norvig, 2022; Goodfellow; Bengio; Courville, 2016). Entretanto, a utilização dessas tecnologias também envolve desafios relacionados à qualidade dos resultados, à adaptação dos métodos de trabalho e à necessidade de avaliação crítica de suas aplicações.

No campo acadêmico, o crescimento da produção científica impõe dificuldades para localizar, processar e integrar informações relevantes de um volume cada vez maior de publicações (Liu; Mutz, 2015). Nesse contexto, ferramentas de inteligência artificial voltadas à análise textual e à sumarização automática apresentam potencial para agilizar a leitura, identificar conceitos centrais e reduzir o esforço empregado em tarefas repetitivas. Esses recursos podem contribuir para que os pesquisadores dediquem mais tempo à interpretação crítica dos conteúdos e à construção de contribuições teóricas, sem comprometer o rigor da investigação.

Apesar dessas possibilidades, a utilização da IA na pesquisa científica exige atenção à fidelidade das informações sintetizadas, à seleção dos conteúdos relevantes e à adequação dos resultados aos objetivos dos pesquisadores. A sumarização automática, portanto, não deve ser compreendida como substituta da leitura e da análise crítica, mas como um recurso de apoio cujo desempenho precisa ser avaliado. Além disso, a formulação das instruções fornecidas aos modelos de IA, por meio da engenharia de prompts, constitui um aspecto importante para orientar a geração de resultados e adequá-los às necessidades de uso (Liu et al., 2023).

Diante desse cenário, justifica-se investigar como ferramentas de sumarização automática podem auxiliar a análise de textos acadêmicos na área de gestão e quais limitações apresentam quando utilizadas por pesquisadores. Assim, este estudo busca responder à seguinte questão: de que forma a inteligência artificial pode ser empregada na construção de ferramentas de sumarização de textos para melhorar a análise e a síntese de conteúdo em pesquisas acadêmicas?

Para responder a esse questionamento, o objetivo do trabalho é desenvolver e avaliar uma ferramenta de sumarização automática de textos acadêmicos, considerando a relevância dos resumos produzidos, sua contribuição para a leitura e as possibilidades de aprimoramento. A pesquisa caracteriza-se como aplicada e exploratória, com abordagem mista, combinando avaliações numéricas e comentários qualitativos de pesquisadores. Dessa forma, pretende-se contribuir para a discussão sobre o uso da inteligência artificial como instrumento de apoio à análise de conteúdo em pesquisas de gestão, reconhecendo suas potencialidades e limitações.

2 Referencial teórico

2.1 Análise de grandes volumes de dados

Conforme Domingos (2017), a Inteligência Artificial (IA) tem revolucionado a forma como grandes volumes de dados são processados e analisados, trazendo rapidez e precisão para áreas que antes dependiam de métodos mais lentos e sujeitos a erros humanos. Ao viabilizar essas análises em escala, a IA não só acelera o progresso em pesquisas, mas também contribui para descobertas mais precisas e transformadoras nesses campos.

De acordo com Russell e Norvig (2022), o impacto da Inteligência Artificial (IA) na análise de grandes volumes de dados vai além de sua capacidade técnica, integrando-se como uma ferramenta essencial para a resolução de problemas complexos. Na saúde pública, a IA é amplamente utilizada para analisar padrões epidemiológicos, identificar surtos de doenças e prever sua propagação. Estudos mostram que algoritmos de aprendizado de máquina podem melhorar a detecção precoce de doenças, como demonstrado durante a pandemia de COVID-19, quando ferramentas de IA auxiliaram na previsão e monitoramento da disseminação do vírus (WHO, 2021; Zhou et al., 2020).

Essas aplicações têm permitido que governos e organizações internacionais tomem decisões mais embasadas, otimizem recursos e reduzam impactos sociais. Da mesma forma, na economia, a IA desempenha um papel crucial ao processar dados financeiros em tempo real para identificar tendências de mercado e prever variações econômicas. Segundo Brynjolfsson e McAfee (2017), a automação e os algoritmos de aprendizado de máquina estão transformando mercados ao aprimorar a análise de risco,

prever flutuações de preços e otimizar investimentos, permitindo uma tomada de decisão mais precisa em ambientes econômicos voláteis.

Complementando essa visão, LeCun, Bengio e Hinton (2015) destacam que os avanços em aprendizado profundo têm ampliado ainda mais as aplicações da IA ao possibilitar uma análise detalhada de dados não estruturados, como imagens, textos e sons. Essa capacidade é especialmente relevante em setores como a geociência, onde o processamento de imagens de satélite é fundamental para monitorar mudanças ambientais e prever desastres naturais. Essa democratização da análise avançada de dados, promovida pela IA, não apenas acelera processos, mas também amplia o alcance de descobertas e aplicações em uma variedade de campos que dependem da manipulação de informações complexas.

2.2 Automação de tarefas repetitivas

Conforme Harari (2018), a integração de ferramentas de Inteligência Artificial (IA) na pesquisa científica tem transformado significativamente os métodos tradicionais. Essas ferramentas automatizam tarefas rotineiras, como a revisão de literatura e a coleta de dados, permitindo que os pesquisadores direcionem seus esforços para atividades mais analíticas e criativas. Essa automação não apenas aumenta a produtividade, mas também reduz o tempo necessário para a conclusão de projetos de pesquisa.

Complementando essa perspectiva, Brynjolfsson e McAfee (2016) apontam que a automação promovida pela Inteligência Artificial (IA) está mudando não apenas a forma como os dados são processados, mas também a dinâmica do trabalho científico. Com o uso de ferramentas de IA, os pesquisadores podem realizar análises complexas de grandes volumes de dados em tempo reduzido, o que antes demandava semanas ou meses de trabalho manual. Além disso, a capacidade de prever padrões em dados experimentais abre novas possibilidades para a formulação de hipóteses mais precisas, levando a avanços mais rápidos e impactantes em diversas áreas do conhecimento.

Para mais, Goodfellow, Bengio e Courville (2016), a integração da IA na pesquisa científica não se limita à automação de tarefas, mas também promove a personalização e o aperfeiçoamento das metodologias utilizadas. Modelos baseados em aprendizado profundo têm sido empregados para gerar previsões mais detalhadas e identificar correlações sutis em dados experimentais, permitindo a descoberta de insights inéditos. Por exemplo, na química computacional, a IA auxilia no desenvolvimento de novos

materiais e medicamentos ao prever propriedades moleculares antes mesmo da realização de experimentos práticos. No campo da educação, ferramentas baseadas em IA personalizam o acesso a informações científicas, ajudando estudantes e pesquisadores a navegar por um volume cada vez maior de publicações. Assim, a IA não apenas acelera a produção científica, mas também democratiza o acesso ao conhecimento, ampliando suas aplicações em múltiplos contextos.

3 Metodologia

A presente pesquisa caracteriza-se como aplicada, exploratória e de abordagem metodológica mista. Trata-se de uma investigação aplicada, uma vez que tem como objetivo o desenvolvimento de uma ferramenta prática de sumarização automática de textos, voltada para a otimização de processos de análise textual em contextos acadêmicos e técnicos, promovendo soluções concretas para desafios relacionados à condensação de informações (Gil, 2002).

Além disso, a pesquisa configura-se como exploratória por buscar aprofundar o entendimento sobre o uso de *prompt engineering* na criação de sistemas automatizados com inteligência artificial generativa, uma área ainda emergente e com referências teóricas em fase de consolidação (Saunders; Lewis; Thornhill, 2019; Liu et al., 2023).

No presente estudo, a abordagem metodológica adotada foi o modelo mist**o**, combinando procedimentos quantitativos e qualitativos de análise. No que se refere aos dados coletados, foram consideradas tanto informações numéricas quanto descritivas. As avaliações de relevância atribuídas pelos especialistas, expressas por meio de notas, foram utilizadas como indicadores numéricos para uma análise descritiva do desempenho da ferramenta, sem a aplicação de procedimentos estatísticos inferenciais.

Paralelamente, os feedbacks textuais fornecidos pelos avaliadores foram analisados de forma interpretativa, com o objetivo de identificar nuances, limitações e potenciais melhorias do sistema. Dessa forma, o estudo não se caracteriza como quantitativo no sentido estatístico estrito, mas como uma pesquisa de natureza predominantemente qualitativa, que faz uso complementar de dados numéricos para apoiar a análise.

Essa estratégia evidencia o princípio da triangulação dos dados, na medida em que diferentes fontes e tipos de evidências são integrados em um mesmo processo analítico

(Creswell; Clark, 2011). A triangulação não apenas aumenta a robustez metodológica, mas também amplia a confiabilidade dos resultados, pois permite que as conclusões não se sustentem em um único tipo de dado. No caso desta pesquisa, a triangulação ocorreu ao articular:

a) Dados numéricos: expressos em escalas de relevância atribuídas aos resumos;
b) Dados textuais/interpretativos: provenientes dos comentários dos especialistas;
c) Comparação entre as duas perspectivas: verificando convergências (quando os números reforçam os comentários) e divergências (quando surgem apontamentos qualitativos que não aparecem nas notas).

Dessa forma, a combinação de dados numéricos de caráter descritivo e feedbacks qualitativos permitiu que a análise não se restringisse a uma única perspectiva analítica. Essa abordagem integrada contribuiu para uma compreensão mais abrangente do fenômeno investigado, enriquecendo a avaliação da eficácia da ferramenta de sumarização.

Esta pesquisa foi conduzida em três etapas principais: desenvolvimento da ferramenta de sumarização, aplicação da sumarização sobre textos fornecidos por especialistas e avaliação quantitativa e qualitativa da eficácia dos resumos gerados. Inicialmente, foi elaborado um conjunto de prompts otimizados para orientar uma Inteligência Artificial (IA) generativa na programação da ferramenta de sumarização.

Essa etapa fundamentou-se no conceito de *prompt engineering*, prática que busca aprimorar a performance de modelos de linguagem por meio da formulação estratégica de instruções, como discutido por (Liu et al. 2023), que destacam que a qualidade do prompt influencia diretamente a precisão e a relevância do conteúdo gerado. A otimização ocorreu em ciclos iterativos, nos quais os prompts foram testados e ajustados progressivamente até que se alcançasse um nível satisfatório de coesão e cobertura temática nos resumos. Abaixo, apresentam-se os prompts utilizados para a construção de cada bloco de código da ferramenta.

Prompt 1:

Crie uma função Python chamada ajusta_quebra_linhas que recebe um texto como entrada e ajusta a formatação para remover quebras de linha desnecessárias. O objetivo é manter a fluidez do texto, substituindo quebras de linha que não seguem um ponto final

por espaços em branco.

Bloco de Código 1:

```
    def ajusta_quebra_linhas(text):
# Ajusta quebras de linha mantendo apenas as que seguem pontos finais
text = re.sub(r'(?<!\.)\n', ' ', text)
return text
```

Prompt 2:

Crie uma função Python chamada upload_pdf que usa a biblioteca google.colab.files para abrir uma janela de upload no Google Colab. A função deve permitir ao usuário enviar um arquivo PDF e retornar seu nome e conteúdo em memória.

Bloco de Código 2:

```
from google.colab import files
from io import BytesIO


def upload_pdf():
  # Faz upload de um arquivo PDF no Colab
  uploaded = files.upload()
  for filename in uploaded.keys():
    return filename, BytesIO(uploaded[filename])
```

Prompt 3:

Crie um controle interativo no Google Colab que permita ao usuário especificar a porcentagem de sumarização do texto, variando entre 10% e 100%. Retorne esse valor como um número inteiro.

Bloco de Código 3:

```
import ipywidgets as widgets
from IPython.display import display
slider = widgets.IntSlider(value=50, min=10, max=100, step=10, description='Resumo %:')
display(slider)
# Para acessar o valor em execução:
percentage = slider.value
```

Prompt 4:

Crie uma função Python chamada create_word_summary que recebe os resumos por página e as imagens extraídas do PDF. A função deve gerar um documento Word formatado, adicionar o conteúdo e as imagens, salvar o arquivo .docx e disponibilizá-lo para download no Google Colab.

Bloco de Código 4:

```
from docx import Document
from docx.shared import Pt, Inches
from docx.enum.text import WD_ALIGN_PARAGRAPH
from docx.image.exceptions import UnrecognizedImageError
import os

def create_word_summary(paged_summaries, images_by_page):
    document = Document()
    style = document.styles['Normal']
    font = style.font
    font.name = 'Times New Roman'
    font.size = Pt(12)

    for i, page_summary in enumerate(paged_summaries, 1):
        document.add_heading(f"Página {i}", level=1)
        p = document.add_paragraph(page_summary.strip())
        p.paragraph_format.first_line_indent = Pt(28.35)
        p.paragraph_format.alignment = WD_ALIGN_PARAGRAPH.JUSTIFY
        for image_path in images_by_page.get(i, []):
            try:
                document.add_picture(image_path, width=Inches(5.5))
            except UnrecognizedImageError:
                continue

    path = "resumo_formatado.docx"
    document.save(path)
    files.download(path)
```

Prompt 5:

Crie uma função Python chamada summarize_per_page que recebe um texto, o código do idioma e um valor percentual de sumarização. A função deve usar a biblioteca sumy com o método LsaSummarizer para gerar um resumo de cada página e retornar a lista de resumos.

Bloco de Código 5:

```
from sumy.parsers.plaintext import PlaintextParser
from sumy.nlp.tokenizers import Tokenizer
from sumy.summarizers.lsa import LsaSummarizer

def summarize_per_page(text, language_code, percentage):
    pages = text.split("\f")
    summarized_pages = []
    for page in pages:
        parser = PlaintextParser.from_string(page.strip(), Tokenizer(language_code))
        sentences = list(parser.document.sentences)
        num_sentences = max(1, int(len(sentences) * percentage / 100))
        summarizer = LsaSummarizer()
        summary = summarizer(parser.document, num_sentences)
```

```
        summarized_pages.append(" ".join(str(sentence) for sentence in summary))
    return summarized_pages
```

Prompt 6:

Crie uma função Python chamada analyze_semantics que recebe o texto original e o resumo, e calcula a similaridade semântica entre ambos usando um modelo do spaCy. Retorne a similaridade como um número decimal entre 0 e 1.

Bloco de Código 6:

```
def analyze_semantics(original_text, summarized_text, model):
    # Calcula similaridade entre texto completo e resumo
    doc_original = model(original_text)
    doc_summary = model(summarized_text)
    return doc_original.similarity(doc_summary)
```

4 Aplicação da ferramenta

Após gerar o código com base nesses prompts, foram realizados testes para validar sua funcionalidade:

a) Um modelo menor do SpaCy (pt_core_news_sm) para evitar problemas de memória foi usado.
b) Foi testado a extração e sumarização de um texto fictício.
c) Foi calculado à similaridade semântica entre o texto original e o resumo.

Os testes foram bem-sucedidos, confirmando que a IA (chatgpt 4.0) foi capaz de recriar um código funcional e usável a partir dos prompts gerados. Na segunda etapa, foram coletados seis textos originais, produzidos por **seis** pesquisadores voluntários, os quais serviram como base para a avaliação da ferramenta de sumarização. O convite aos participantes foi realizado de forma direta, por meio de contato via aplicativo de mensagens (*WhatsApp*), sendo que todos os pesquisadores convidados aceitaram participar do estudo. Cada texto foi submetido ao sistema, gerando resumos automáticos que foram posteriormente enviados aos respectivos autores para análise crítica.

Para a caracterização dos sujeitos da pesquisa, consideraram-se suas percepções sobre hábitos de leitura acadêmica, estratégias utilizadas para a compreensão de textos científicos e impressões acerca do uso da ferramenta proposta. Os pesquisadores pertencem à área 27 da CAPES, com tempo de atuação em pesquisa variando entre quatro

e oito anos, sendo todos do sexo masculino. A avaliação dos resumos seguiu uma escala de 1 (nada relevante) a 10 (muito relevante), considerando critérios como precisão, completude e fidelidade ao texto original. Esse processo foi complementado por reflexões críticas e sugestões de melhoria, possibilitando uma compreensão mais abrangente do potencial da ferramenta como apoio à leitura acadêmica. A seguir, apresenta-se a tabela com a caracterização dos sujeitos da pesquisa e suas avaliações.

Por fim, os dados coletados foram analisados qualitativamente, por meio de análise temática dos comentários oferecidos pelos avaliadores, buscando identificar aspectos recorrentes de aprovação ou crítica. Assim, a metodologia proposta permitirá avaliar não apenas a eficácia da ferramenta em termos de relevância percebida, mas também mapear limitações e potencialidades do uso de IA orientada por prompts no contexto da construção de ferramentas de sumarização textual acadêmica, alinhando-se aos debates contemporâneos sobre a integração de IA generativa em processos de apoio à academia (Ouyang et al., 2022).

Tabela 1 – Caracterização dos sujeitos da pesquisa e suas avalizaçoes

Tabela com a Caracterização dos Sujeitos da Pesquisa e suas Avaliações					
Sujeito	**Estratégias de Leitura**	**Experiência com a Ferramenta**	**Pontos Positivos**	**Pontos de Melhoria**	**Satisfação**
P1	Busca inicial, leitura do resumo/overview e leitura intervalativa com anotações.	Resumo claro, sem perdas principais; menor profundidade, mas positivo por evitar excesso.	Facilitou pela economia de tempo frente ao grande volume de artigos.	Sumarizar com foco nas seções essenciais.	8
P2	Estudos são lidos de forma objetiva, focando em trechos-chave e utilizando fontes acadêmicas.	Percebeu uma redução do volume de textos. Preservação do conceito principal.	Economia de tempo e conceito principal mantidos.	Erros e confusão estrutural comprometem a clareza.	8
P3	Leitura focada para o que importa e uso de ferramentas para otimização.	A ferramenta não gera resumos concisos; é mais útil como revisão posterior do que para a primeira leitura.	Relembrar o artigo original.	Resumo por topico do trabalho e não páginas.	6
P4	Uso de PDFs para comentários e destaque de textos.	A sumarização tinha a mesma quantidade de pág que o artigo original, trouxe confusão.	A introdução ficou sucinta.	Focar em partes essenciais do artigo que será sumarizado.	6
P5	Leitura por camadas: escanear título, estrutura do artigo; se servir, faz se à leitura completa.	Interressante o fato da ferramenta fazer a sumarização por pág.	Trouxe referências e fez citação indireta dos autores.	Fazer um front end.	10
P6	Leituras seletivas: foco em resumo, referencial, adaptando o caminho conforme o objetivo da pesquisa.	A Ferramenta é interessante e pode ajudar bastante. Cód simples e fácil de usar.	A ferramenta realmente pegar pontos importantes e resumir.	Seções subdivididas. Focar em partes essencias e insere as fig do texto.	7

Fonte: Elaborado pelos autores (2026)

5 Resultados

A coleta dos dados qualitativos foi realizada por meio de entrevistas individuais com seis pesquisadores voluntários, conduzidas de forma digital, por meio da plataforma Google Meet, utilizando notebook. As entrevistas foram gravadas em áudio, com o auxílio do gravador do telefone celular, mediante consentimento dos participantes, e ocorreram nas seguintes datas: 11 de julho de 2025 (duas entrevistas), 18 de julho de

2025, 24 de julho de 2025 e 31 de julho de 2025 (duas entrevistas), totalizando seis entrevistas, cada uma com duração média aproximada de 20 minutos.

Para a condução das entrevistas, foi utilizado um roteiro estruturado, composto por questões previamente definidas, voltadas à compreensão dos hábitos de leitura acadêmica, das estratégias de compreensão de textos científicos e das percepções dos pesquisadores sobre o uso da ferramenta de sumarização. A análise dos dados qualitativos seguiu os procedimentos da Análise de Conteúdo, conforme proposto por Bardin (2011), iniciando-se pela pré-análise, com leitura exploratória do material, seguida da exploração do conteúdo, na qual foram identificadas unidades de sentido recorrentes e construídas categorias de análise definidas a posteriori, emergentes das falas dos participantes e alinhadas aos objetivos do estudo.

A partir desse processo, emergiram as seguintes categorias analíticas: (i) estratégias de leitura acadêmica adotadas pelos pesquisadores; (ii) percepções sobre a qualidade e utilidade dos resumos gerados; (iii) limitações identificadas na ferramenta de sumarização; e (iv) sugestões de melhoria e potencial de uso da ferramenta no contexto acadêmico. Por fim, na etapa de tratamento e interpretação dos resultados, os conteúdos categorizados permitiram identificar padrões, percepções convergentes e elementos críticos relacionados ao uso da sumarização automática como apoio à leitura acadêmica.

Os participantes demonstraram estratégias de leitura variadas, que influenciaram a forma como utilizaram a ferramenta. Enquanto alguns adotam uma leitura objetiva e seletiva, focando apenas em trechos-chave, como resumo e referencial teórico:

> *"Quando são estudos que vou citar ou utilizar de forma pontual, costumo focar em trechos-chave, como o resumo, a introdução ou alguma parte do referencial teórico que me interessa." (P2)*

> *"Tenho a ideia do que ele fala, passo no referencial para ver se tem alguma hipótese que eu quero me aprofundar, se tem algum modelo, se o modelo faz sentido." (P6)*

Outros utilizam leitura por camadas, escaneando título, estrutura e seções do artigo antes de aprofundar em pontos relevantes:

> *"Só passando o olho mesmo, seção por seção, para ver o que é que é abordado nas seções, principalmente no referencial teórico, o que é que vem de ilustração, o que é que tem de tabela, de figura, de framework, para ver se faz sentido." (P5)*

Alguns ainda mantêm uma abordagem mais tradicional, lendo parcialmente ou integralmente o texto para compreender melhor o conteúdo:

> *"Eu primeiro faço um overview, uma leitura de todo o conteúdo de forma dinâmica e rápida, e principalmente focando no resumo para saber se realmente aquele artigo é importante para eu ler. Se ele for, eu vou então, ao mesmo tempo que realizar a leitura, eu tenho um método de leitura que é meu que é a leitura intervalativa, eu vou me perguntando quais pontos do artigo se ligam ao meu objetivo e vou anotando, anotando em um papel e depois faço um fechamento." (P1)*

> *"Quando o artigo é realmente do meu interesse, eu o leio por completo. Mas, quando apenas algumas partes são relevantes para mim, eu foco só nessas partes específicas." (P3)*

> *"Normalmente, eu utilizo PDF, a leitura no PDF, seja no computador, tablet ou celular. E vou destacando, colocando comentários, destacando trechos." (P4)*

Os principais aspectos positivos apontados incluem:

a) Economia de tempo diante do grande volume de artigos (P1).

b) Preservação de conceitos principais sem perda de conteúdo relevante (P2).

> *"Facilitou, porque é muito cansativo estar sempre lutando contra o tempo." (P1)*

> *"Essa redução de volume, aliada à preservação do conceito principal trazido pelo artigo original, foi algo que eu realmente gostei." (P2)*

a) Facilidade na revisão de conteúdos já conhecidos, permitindo relembrar pontos importantes (P3, P5)

b) Identificação de referências e citação indireta dos autores, agregando valor à pesquisa (P5).

> *"Vejo a sumarização como útil, sim, mas talvez em um segundo momento — como uma forma de revisar. Por exemplo, ao invés de reler o texto inteiro, posso recorrer à sumarização para relembrar os principais pontos. Isso, para mim, faz mais sentido." (P3)*

> *"Na sumarização já é feita uma citação indireta dos autores que foram realmente citados diretamente no texto original, então isso me chamou bastante a atenção." (P5)*

a) Interface simples e prática, com potencial de auxiliar em releituras futuras (P6).

> "Eu acho que essa ferramenta me ajuda a relembrar o artigo. Ao invés de ter que ir lá no artigo e relembrar ele todo, entendeu?."(P6)

As sugestões de aprimoramento mais recorrentes foram:

Resumos mais concisos, com foco em seções essenciais (P1, P4, P6).

> *"Sim, a ideia é enxugar o texto, tornar a leitura mais rápida, mas sem perder o foco principal." (P1)*

> *"Porque, normalmente, o grande objetivo de uma ferramenta dessas é deixar tudo mais mastigado, porque se eu quero aprofundar o artigo, se eu quero ler o artigo, eu vou lá e vou ler ele na íntegra." (P4)*

Correção de erros linguísticos e confusão estrutural, incluindo tradução de termos e formatação adequada (P2, P4).

> *"Como eu já havia mencionado, o que me incomodou foi o fato de a ferramenta extrair apenas o texto bruto, sem tratar adequadamente os caracteres, as formatações ou os elementos adicionais do artigo." (P2)*

Separação clara entre conteúdo, autores e referências, evitando sobreposição de informações (P3, P4).

> *"O ideal seria trabalhar a sumarização por tópicos — produção, fundamentação teórica, metodologia, resultados, discussão. Para mim, essa forma de sumarizar seria muito mais interessante." (P3)*

Inclusão de elementos visuais e subdivisão das seções, para facilitar a compreensão e análise rápida (P6).

> *"Eu acho que tem que ter as subdivisões, tem que não vir só com a página, tem que vir subdividido dentro das seções." (P6)*

Desenvolvimento de *front-end*, sugerido para tornar a ferramenta mais interativa e amigável (P5).

> *"Começar a focar no front-end, para poder dar uma, minimamente uma cara de interface em que aquelas pessoas menos letradas em códigos pudessem já começar também a utilizar." (P5)*

A satisfação dos participantes variou entre 6 e 10, sendo que os pesquisadores que adotam leitura por camadas (P5) demonstraram maior apreço pela ferramenta, enquanto aqueles que esperavam resumos mais concisos apontaram menor satisfação (P3, P4). Isso evidencia que a adequação da ferramenta depende da estratégia de leitura e do objetivo de pesquisa de cada usuário.

Considerações finais

O presente trabalho teve como propósito investigar o papel das ferramentas desenvolvidas por Inteligência Artificial (IA) na melhoria da eficiência da análise de conteúdo em pesquisas de gestão, propondo e avaliando uma ferramenta prática de

sumarização automática de textos. A pesquisa demonstrou que o uso estratégico da IA, quando orientado por técnicas de *prompt engineering*, pode contribuir significativamente para a otimização de processos de leitura, síntese e compreensão de grandes volumes de informações acadêmicas.

Os resultados apontaram que a ferramenta desenvolvida apresentou potencial relevante para reduzir o tempo gasto com a leitura e auxiliar na revisão de conteúdos, especialmente em contextos nos quais o pesquisador precisa lidar com múltiplas fontes de informação simultaneamente. As percepções dos participantes revelaram benefícios como a economia de tempo, a preservação de conceitos principais e a possibilidade de uso da ferramenta como suporte para releituras e revisões, ao mesmo tempo em que foram levantadas sugestões de aprimoramento quanto à concisão dos resumos e à interface de uso.

No âmbito acadêmico, a pesquisa acrescenta evidências empíricas sobre o uso da IA como instrumento de apoio metodológico em revisões sistemáticas da literatura e na análise de conteúdo. O desenvolvimento e a validação de uma ferramenta prática contribuem para o avanço das discussões sobre a integração de tecnologias emergentes às práticas científicas, incentivando novas abordagens que conciliem rigor teórico e inovação tecnológica. Entretanto, reconhece-se que este estudo possui limitações, especialmente quanto ao número restrito de participantes e à versão inicial da ferramenta desenvolvida, que ainda carece de melhorias em aspectos técnicos, como usabilidade, tratamento linguístico e integração visual.

Diante disso, sugere-se que pesquisas futuras explorem: o aprimoramento da ferramenta com interfaces gráficas (*front-end*) e suporte multilíngue; a aplicação de modelos mais avançados de linguagem natural, como LLMs de última geração, para ampliar a precisão semântica dos resumos; a expansão do estudo para diferentes áreas do conhecimento, a fim de avaliar a generalização da ferramenta; investigações sobre os impactos cognitivos e éticos do uso da IA na leitura e interpretação acadêmica; e a integração da sumarização automática com sistemas de gestão do conhecimento em empresas e universidades.

Referências

BARDIN, Laurence. **Análise de conteúdo.** São Paulo: Edições 70, 2011.

BORNMANN, L.; MUTZ, R. Growth rates of modern science: A bibliometric analysis based on the number of publications and cited references. **Journal of the Association for Information Science and Technology**, v. 66, n. 11, p. 2215–2222, 2015.

BRYNJOLFSSON, E.; McAFEE, A. **Machine, platform, crowd**: harnessing our digital future. New York: Norton & Company, 2017.

CRESWELL, J. W.; CRESWELL, J. D. **Research design**: qualitative, quantitative, and mixed methods approaches. 5t. ed. Thousand Oaks: Sage publications, 2017.

DOMINGOS, Pedro. **O Algoritmo Mestre:** Como a Busca pelo Algoritmo Universal Pode Controlar Nossas Vidas. São Paulo: Novatec, 2017.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep Learning.** Cambridge: MIT Press, 2016.

GIL, Antonio Carlos. **Como elaborar projetos de pesquisa**. 4. ed. São Paulo: Atlas, 2002.

HARARI, Yuval Noah. **21 Lições para o Século 21**. São Paulo: Companhia das Letras, 2018.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, n. 7553, p. 436-444, 2016.

LIU, P.; YUAN, W.; FU, J.; JIANG, Z.; HAYASHI, H.; NEUBIG, G. Pre-train, Prompt, and Predict: A Systematic Survey of Prompting Methods in Natural **Language Processing. ACM Computing Surveys**, v. 55, n. 9, p. 1-35, 2023.

OPENAI. **Codex**: AI-powered coding assistant. Disponível em: https://openai.com.

OUYANG, L.; WU, J., JIANG, X.; ALMEIDA, D.; WAINWRIGHT, C.; MISHKIN, P; ZIEGLER, D. M. Training language models to follow instructions with human feedback. **Advances in Neural Information Processing Systems**, v. 35, p. 27730-27744, 2022.

RUSSELL, Stuart; NORVIG, Peter. **Inteligência artificial**: uma abordagem moderna. 4. ed. Harlow: Pearson, 2022.

SAUNDERS, M.; LEWIS, P.; THORNHILL, A. **Research methods for business students**. 8. ed. Harlow: Pearson, 2019.

WORLD HEALTH ORGANIZATION. **Artificial intelligence applications in the COVID-19 response**. Geneva: WHO, 2021. Disponível em: https://www.who.int.

ZENG, Daniel; CAO, Zhidong; NEILL, Daniel B. Artificial intelligence-enabled public health surveillance from local detection to global epidemic monitoring and control. In: **Artificial intelligence in medicine**: technical basis and clinical applications. Academic Press, 2021. p. 437–453.https://doi.org/10.1016/B978-0-12-821259-2.000223.