

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
INSTITUTO DE CIÊNCIAS EXATAS
BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO

**Um processo automatizado para
levantamento de literatura apoiado por
inteligência artificial generativa**

Marina Condé Araújo

JUIZ DE FORA
SETEMBRO, 2024

Um processo automatizado para levantamento de literatura apoiado por inteligência artificial generativa

MARINA CONDÉ ARAÚJO

Universidade Federal de Juiz de Fora

Instituto de Ciências Exatas

Departamento de Ciência da Computação

Bacharelado em Ciência da Computação

Orientador: Marco Antônio Pereira Araújo

JUIZ DE FORA

SETEMBRO, 2024

UM PROCESSO AUTOMATIZADO PARA LEVANTAMENTO DE
LITERATURA APOIADO POR INTELIGÊNCIA ARTIFICIAL
GENERATIVA

Marina Condé Araújo

MONOGRAFIA SUBMETIDA AO CORPO DOCENTE DO INSTITUTO DE CIÊNCIAS
EXATAS DA UNIVERSIDADE FEDERAL DE JUIZ DE FORA, COMO PARTE INTE-
GRANTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE
BACHAREL EM CIÊNCIA DA COMPUTAÇÃO.

Aprovada por:

Marco Antônio Pereira Araújo
Doutor em Engenharia de Sistemas e Computação

Luiz Maurílio da Silva Maciel
Doutor em Engenharia de Sistemas e Computação

Tássio Ferezini Martins Sirqueira
Doutor em Informática

JUIZ DE FORA
02 DE SETEMBRO, 2024

*Dedico a minha família por todo o apoio na
minha vida acadêmica*

Resumo

A crescente quantidade de publicações científicas torna desafiador realizar um levantamento de literatura abrangente e eficiente. A inteligência artificial (IA) generativa, com suas capacidades de aprendizado de máquina e processamento de linguagem natural, surge como uma solução promissora para esse desafio. Este trabalho visa desenvolver e avaliar um processo automatizado para levantamento de literatura apoiado por IA generativa, buscando otimizar a eficiência e precisão na identificação, análise e síntese de informações científicas relevantes em diversas áreas do conhecimento. A implementação de um processo automatizado oferece vantagens como a aceleração do processo de revisão, a identificação de padrões e a facilitação ao acesso ao conhecimento. Além disso, a IA generativa pode auxiliar na construção de *strings* de busca mais eficazes e na definição de critérios de inclusão e exclusão rigorosos, contribuindo para a robustez e relevância da literatura selecionada. Espera-se que o processo automatizado proposto seja capaz de adaptar-se a diferentes áreas de pesquisa, fornecendo resultados personalizados e relevantes para os usuários.

Palavras-chave: Revisão da Literatura, Revisão Sistemática, Mapeamento Sistemático, Inteligência Artificial Generativa, Processo Automatizado.

Abstract

The increasing number of scientific publications makes it challenging to conduct a comprehensive and efficient literature review. Generative artificial intelligence (AI), with its machine learning and natural language processing capabilities, emerges as a promising solution to this challenge. This work aims to develop and evaluate an automated process for literature review supported by generative AI, seeking to optimize efficiency and accuracy in the identification, analysis, and synthesis of relevant scientific information across various fields of knowledge. The implementation of an automated process offers advantages such as accelerating the review process, identifying patterns, and facilitating access to knowledge. Furthermore, generative AI can assist in constructing more effective search strings and defining rigorous inclusion and exclusion criteria, contributing to the robustness and relevance of the selected literature. It is expected that the proposed automated process will be adaptable to different research areas, providing personalized and relevant results for users.

Keywords: Literature Review, Systematic Review, Systematic Mapping, Generative Artificial Intelligence, Automated Process.

Agradecimentos

Gostaria de expressar minha mais profunda gratidão a todos que me apoiaram ao longo desta jornada acadêmica e contribuíram para a conclusão deste trabalho. Agradeço à minha família, que sempre esteve ao meu lado, oferecendo amor, compreensão e encorajamento incondicional.

Faço um agradecimento especial à minha mãe, que esteve presente em minha vida acadêmica desde o ensino primário. Desde os primeiros passos na escola até a conclusão deste trabalho, sua orientação, incentivo e amor incondicional me permitiram enfrentar desafios com confiança. Devo a ela muito do que sou e de tudo o que conquisei.

Agradeço especialmente ao meu pai, que, além de ser um exemplo de dedicação e integridade, desempenhou um papel duplo e fundamental como meu orientador. Sua orientação foi muito mais do que acadêmica, sendo uma experiência enriquecedora que me guiou no desenvolvimento deste trabalho e na formação dos valores que levarei para a vida toda. Sua paciência, sabedoria e comprometimento foram inspirações constantes em cada etapa deste projeto.

Sou profundamente grata aos meus professores por todo o conhecimento compartilhado e pela dedicação com que me guiaram ao longo da minha formação. Cada aula, discussão e conselho contribuíram de forma inestimável para o meu crescimento acadêmico e pessoal. As lições que aprendi transcendem os limites da sala de aula e continuarão a me guiar em minha trajetória futura.

Por fim, agradeço aos amigos e colegas que compartilharam comigo essa jornada. Os momentos de estudo, as conversas e o apoio mútuo foram essenciais para criar um ambiente de aprendizado rico e estimulante. A todos que, direta ou indiretamente, contribuíram para a realização deste trabalho, deixo aqui meu mais sincero agradecimento. Esta conquista não seria possível sem o apoio e a colaboração de todos vocês.

“O homem não teria alcançado o possível se, repetidas vezes, não tivesse tentado o impossível.”

Max Weber

Conteúdo

Lista de Figuras	8
Lista de Tabelas	10
Lista de Abreviações	11
1 Introdução	12
1.1 Apresentação do tema e contextualização	12
1.2 Descrição do problema	13
1.3 Justificativa/Motivação	14
1.4 Objetivos	15
1.5 Hipótese	15
1.6 Resultados obtidos	16
1.7 Organização do trabalho	16
2 Fundamentação Teórica	18
2.1 Inteligência Artificial	18
2.1.1 <i>Machine Learning</i>	19
2.1.2 <i>Deep Learning</i>	21
2.1.3 IA Generativa	22
2.1.4 <i>Large Language Models</i> - LLM	24
2.1.5 Engenharia de <i>prompt</i>	25
2.2 Automatização de processos em pesquisas acadêmicas	27
2.2.1 Ferramentas e tecnologias que apoiam a IA	28
2.2.2 Integração de Ferramentas e Abordagens de Automatização	30
2.3 Conclusões do capítulo	32
3 Referencial Teórico	33
3.1 Mapeamento sistemático da literatura	33
3.1.1 Construção das <i>strings</i> de busca	36
3.1.2 Critérios de inclusão e exclusão	38
3.2 Resultados	39
3.2.1 Análise de qualidade dos artigos	41
3.3 Trabalhos relacionados	43
3.4 Conclusões do capítulo	50
4 Materiais e Métodos	51
4.1 Ferramentas discutidas	53
4.1.1 Análise de ferramentas	53
4.1.2 Ferramenta de automação	54
4.1.3 Ferramenta de LLM	58
4.1.4 Ferramenta de análise de texto	62
4.1.5 Ferramenta de fichamento	65
4.1.6 Ferramenta de geração de gráficos	71

4.1.7	Ferramentas de Mapa de Palavras	74
4.1.8	Ferramenta de editoração de texto	76
4.1.9	Ferramenta de busca acadêmica	78
4.2	Considerações do capítulo	81
5	Estudo de caso	83
5.1	Procedimentos detalhados	83
5.1.1	Questão de pesquisa inicial	84
5.1.2	Configuração inicial da automação	85
5.1.3	Geração de palavras-chave, termos e sinônimos	90
5.1.4	Registro das palavras-chave, termos e sinônimos	93
5.1.5	Nova <i>string</i> de busca	96
5.1.6	Pesquisa de artigos acadêmicos	98
5.1.7	Sumarização dos artigos	102
5.1.8	Consolidação das respostas	105
5.1.9	Avaliação da qualidade dos artigos	108
5.1.10	Escala de Likert	111
5.1.11	Consolidação da avaliação	114
5.1.12	Geração de gráfico e mapa de palavras	117
5.2	Considerações do capítulo	120
6	Conclusões	122
6.1	Limitações e desafios	122
6.2	Próximos Passos	124
6.3	Aspectos éticos	125
6.4	Considerações Finais	126
	Bibliografia	127

Lista de Figuras

3.1	Mapa de autores.	40
3.2	Publicações por ano.	41
4.1	Fluxograma das etapas a serem seguidas.	52
4.2	Interface do Zapier.	57
4.3	Aplicações que interagem com o Zapier.	58
5.1	Processo automatizado para revisão da literatura.	83
5.2	Resultados gerados sem uso de IA.	85
5.3	Tela inicial do Zapier.	86
5.4	Questão de pesquisa inicial no Google Sheets.	86
5.5	PICOC no Google Sheets.	86
5.6	Questão de pesquisa inicial no Google Sheets.	87
5.7	Selecionar evento a ser realizado para a <i>string</i>	88
5.8	Conectar conta autenticada do Google para a <i>string</i>	88
5.9	Configuração da planilha no Zapier para a <i>string</i>	89
5.10	Fase de teste da planilha para a <i>string</i>	89
5.11	Selecionar o aplicativo da Open AI no Zapier para a <i>string</i>	90
5.12	Selecionar evento a ser realizado no Open AI para a <i>string</i>	91
5.13	Conectar conta da Open AI para a <i>string</i>	91
5.14	Configuração do <i>prompt</i> para a <i>string</i>	92
5.15	Fase de teste do <i>prompt</i> para a <i>string</i>	92
5.16	Selecionar o aplicativo do Google Docs para a <i>string</i>	93
5.17	Selecionar evento a ser realizado para a <i>string</i>	94
5.18	Conectar conta autenticada do Google para a <i>string</i>	94
5.19	Configurar Google Docs para a <i>string</i>	95
5.20	Fase de teste das respostas para a <i>string</i>	95
5.21	Palavras-chave, termos e sinônimos gerados pelo ChatGPT 4o.	96
5.22	Resultados gerados com uso de IA.	97
5.23	Arquivo Google Sheets com os artigos a serem analisados.	99
5.24	Selecionar Google Sheets no Zapier para gerar resumos.	99
5.25	Selecionar evento a ser realizado para gerar resumos.	100
5.26	Conectar conta autenticada do Google para gerar resumos.	100
5.27	Configuração da planilha no Zapier para gerar resumos.	101
5.28	Fase de teste da planilha para gerar resumos.	101
5.29	Selecionar o aplicativo da Open AI no Zapier para gerar resumos.	102
5.30	Selecionar evento a ser realizado para gerar resumos.	103
5.31	Conectar conta da Open AI para gerar resumos.	103
5.32	Configuração do <i>prompt</i> para gerar resumos.	104
5.33	Fase de teste do <i>prompt</i> para gerar resumos.	104
5.34	Selecionar o aplicativo do Google Docs para gerar resumos.	105
5.35	Selecionar evento a ser realizado para gerar resumos.	106
5.36	Conectar conta autenticada do Google para gerar resumos.	106
5.37	Configurar Google Docs para gerar resumos.	107

5.38	Fase de teste respostas para gerar resumos.	107
5.39	Resumo gerado pelo Chat GPT 4o.	108
5.40	Selecionar Google Sheets no Zapier para avaliação de artigos.	109
5.41	Selecionar evento a ser realizado para avaliação de artigos.	109
5.42	Conectar conta autenticada do Google para avaliação de artigos.	110
5.43	Configuração da planilha no Zapier para avaliação de artigos.	110
5.44	Fase de teste da planilha para avaliação de artigos.	111
5.45	Selecionar o aplicativo da Open AI no Zapier para avaliação de artigos. . .	112
5.46	Selecionar evento a ser realizado para avaliação de artigos.	112
5.47	Conectar conta da Open AI para avaliação de artigos.	113
5.48	Configuração do <i>prompt</i> para avaliação de artigos.	113
5.49	Fase de teste do <i>prompt</i> para avaliação de artigos.	114
5.50	Selecionar o aplicativo do Google Docs para avaliação de artigos.	115
5.51	Selecionar evento a ser realizado para avaliação de artigos.	115
5.52	Conectar conta autenticada do Google para avaliação de artigos.	116
5.53	Configurar Google Docs para avaliação de artigos.	116
5.54	Fase de teste respostas para avaliação de artigos.	117
5.55	Avaliação gerada pelo Chat GPT 4o.	117
5.56	Gráfico gerado pelo ChatGPT 4o.	119
5.57	Mapa de palavras gerado pelo ChatGPT 4o.	120

Lista de Tabelas

3.1	PICOC.	35
3.2	Critérios de Inclusão e Exclusão.	39
3.3	Resultado mapeamento da literatura após critérios de inclusão e exclusão.	39
3.4	Análise de qualidade dos artigos.	43
4.1	Análise das ferramentas de automação.	57
4.2	Análise das Ferramentas de LLMs.	61
4.3	Análise das Ferramentas de Análise de Texto.	64
4.4	Análise das Ferramentas de Fichamento.	70
4.5	Análise das Ferramentas de Geração de Gráfico.	73
4.6	Tabela Comparativa de Ferramentas de Mapa de Palavras.	76
4.7	Análise das Ferramentas de Edição de Documentos.	78
4.8	Análise das Ferramentas de Busca Acadêmica.	81
5.1	Critérios de Inclusão e Exclusão para a nova string.	98

Lista de Abreviações

DCC Departamento de Ciência da Computação

UFJF Universidade Federal de Juiz de Fora

IA Inteligência Artificial

1 Introdução

1.1 Apresentação do tema e contextualização

A expansão acelerada da Inteligência Artificial (IA) (NARCISO, 2024) está revolucionando diversas áreas do conhecimento, transformando profundamente a maneira como se realiza pesquisas e se acessa informações. Neste contexto, a busca por um processo automatizado para levantamento de literatura apoiado por inteligência artificial generativa (MARQUES, 2023) torna-se uma questão importante para a comunidade acadêmica e científica. A capacidade de sintetizar e analisar grandes volumes de dados de forma eficiente e precisa é relevante em uma era onde a quantidade de informações disponíveis cresce exponencialmente.

A inteligência artificial generativa, com suas técnicas de aprendizado de máquina e processamento de linguagem natural, oferece ferramentas poderosas para automatizar e otimizar a revisão de literatura (BRIZOLA; FANTIN, 2016). Essas tecnologias permitem não apenas a identificação rápida de estudos relevantes, mas também a geração de resumos e a extração de *insights* significativos, facilitando a compreensão e a aplicação do conhecimento existente.

Entretanto, a implementação de um processo automatizado para levantamento de literatura enfrenta desafios, incluindo questões de confiabilidade, viés e interpretação dos resultados gerados pela IA. A integração eficaz de ferramentas no processo de pesquisa requer uma abordagem multidisciplinar, envolvendo especialistas em computação, ciência da informação e áreas específicas do conhecimento.

A crescente demanda por profissionais capacitados em inteligência artificial reflete a importância dessas competências no mercado atual. A formação desses especialistas deve equilibrar habilidades técnicas, como programação e análise de dados, com habilidades interpessoais e éticas, preparando-os para lidar com os desafios e responsabilidades inerentes ao uso da IA na pesquisa.

A busca por um processo automatizado para levantamento de literatura apoiado

por inteligência artificial generativa é um passo importante para aprimorar a eficiência e a qualidade das pesquisas, impulsionando o desenvolvimento tecnológico e o progresso do conhecimento humano.

1.2 Descrição do problema

O avanço contínuo da Inteligência Artificial (IA) e da tecnologia computacional tem sido um fator-chave na transformação de diversos setores da sociedade. Nesse cenário, a busca por processos automatizados para o levantamento de literatura apoiado por IA generativa ganha destaque, prometendo revolucionar a forma como pesquisadores e acadêmicos acessam e analisam informações científicas. A IA generativa, com suas capacidades de processamento de linguagem natural e aprendizado de máquina, oferece uma abordagem inovadora para a síntese e organização de grandes volumes de dados de literatura, facilitando a identificação de tendências, padrões e lacunas no conhecimento existente.

A necessidade de um processo automatizado para levantamento de literatura é evidente diante do crescente volume de publicações e da complexidade das áreas de pesquisa. Tradicionalmente, o levantamento de literatura é uma tarefa manual, demorada e propensa a erros, limitando a eficácia e a abrangência das análises. A implementação de sistemas de IA generativa pode agilizar esse processo, permitindo a realização de buscas mais precisas, a extração de *insights* relevantes e a geração de resumos automatizados, otimizando o tempo e os recursos dos pesquisadores, apoiando seu trabalho.

Além disso, a adoção de ferramentas de IA na pesquisa bibliográfica tem o potencial de facilitar o acesso ao conhecimento e a pesquisa acadêmica, oferecendo a estudantes e profissionais de diferentes áreas e níveis de experiência a possibilidade de realizar levantamentos da literatura com maior profundidade e rigor. Isso é particularmente importante em um contexto onde a interdisciplinaridade e a colaboração entre diferentes campos do saber são cada vez mais valorizadas.

Contudo, a implementação de processos automatizados para levantamento de literatura apoiados por IA generativa também apresenta desafios. Questões relacionadas à qualidade e à confiabilidade dos dados, ao viés algorítmico e à interpretação dos resultados gerados pela IA são aspectos críticos que necessitam de atenção. Além disso, a capacitação

dos usuários para interagir adequadamente com essas ferramentas e a integração desses sistemas nos fluxos de trabalho acadêmicos são fatores essenciais para o sucesso de sua adoção.

De forma geral, a busca por um processo automatizado para levantamento de literatura apoiado por inteligência artificial generativa representa um passo significativo na evolução das práticas de pesquisa acadêmica. Ao superar as limitações dos métodos tradicionais e aproveitar o potencial da IA, é possível não apenas otimizar a revisão de literatura, mas também enriquecer a qualidade e o impacto das investigações científicas.

1.3 Justificativa/Motivação

A revisão de literatura (KITCHENHAM, 2004) é uma etapa importante em qualquer pesquisa, proporcionando uma base sólida para o desenvolvimento de novas hipóteses e a construção do conhecimento. No entanto, com o crescimento exponencial de publicações científicas, torna-se cada vez mais desafiador realizar um levantamento de literatura abrangente e eficiente. A IA generativa, com suas capacidades de aprendizado de máquina e processamento de linguagem natural, apresenta uma solução promissora para esse desafio.

A implementação de um processo automatizado para o levantamento de literatura apoiado por IA generativa oferece diversas vantagens. Primeiramente, a automação pode significativamente acelerar o processo de revisão, permitindo que pesquisadores acessem e analisem rapidamente um vasto conjunto de dados da pesquisa literária. Isso não apenas economiza tempo, mas também aumenta a abrangência da revisão, potencializando a descoberta de conexões e tendências relevantes.

Além disso, a IA generativa pode auxiliar na identificação de padrões e gerar percepções que podem passar despercebidas em uma análise manual. Isso enriquece a qualidade da revisão de literatura, fornecendo uma base mais sólida para a pesquisa subsequente. A capacidade de sintetizar e organizar informações complexas de forma coerente e acessível também é uma vantagem significativa, especialmente para pesquisadores que lidam com campos de estudo interdisciplinares ou emergentes.

Outro aspecto relevante é a facilidade ao acesso ao conhecimento. Um processo automatizado para levantamento de literatura pode tornar a pesquisa bibliográfica mais

acessível a estudantes e pesquisadores de diversas áreas e níveis de experiência. Isso promove a inclusão e a diversidade na comunidade científica, além de estimular a colaboração e o intercâmbio de ideias entre diferentes campos do saber.

1.4 Objetivos

O objetivo geral deste trabalho é otimizar a eficiência e precisão na identificação, análise e síntese de informações científicas relevantes em diversas áreas do conhecimento, assim desenvolvendo um processo automatizado para levantamento de literatura apoiado por inteligência artificial generativa.

Para atingir o objetivo geral deste trabalho, são propostos objetivos específicos que incluem a investigação das tecnologias de IA generativa mais adequadas para o processo, o desenvolvimento de um algoritmo de busca automatizado e a avaliação de mecanismos de análise de dados que utilizem ferramentas de IA para sintetizar e resumir as informações encontradas.

1.5 Hipótese

A hipótese central é que a implementação de técnicas de processamento de linguagem natural e aprendizado de máquina, integradas em uma plataforma de busca automatizada, resultará em uma melhoria significativa na eficiência e precisão na identificação e síntese de informações científicas relevantes.

Espera-se que o processo automatizado proposto seja capaz de adaptar-se a diferentes áreas de pesquisa, fornecendo resultados personalizados e relevantes para os usuários. A avaliação desta hipótese será realizada por meio de experimentos controlados, comparações com metodologias tradicionais e análises de usabilidade, visando avaliar o impacto do processo automatizado no contexto acadêmico e de pesquisa.

1.6 Resultados obtidos

Durante o 10^o Fórum de Gestão de Dados de Investigação, realizado em novembro de 2023 no Instituto Politécnico de Setúbal, Portugal, foram apresentados os artigos "Explorando a Automatização na Análise Estatística com Suporte da Inteligência Artificial Generativa na Gestão de Dados de Investigação" (ARAÚJO et al., 2023b) e "Explorando Automatização na Revisão de Literatura com Suporte de Inteligência Artificial Generativa na Gestão de Dados de Investigação" (ARAÚJO et al., 2023c). Esses trabalhos destacam a importância da abordagem proposta, oferecendo uma análise crítica sobre as implicações da integração da inteligência artificial na análise e gestão de dados de pesquisa. No mesmo período, o artigo "Em busca de um processo automatizado para levantamento de literatura apoiado por uma inteligência artificial generativa" (ARAÚJO et al., 2023a) foi publicado no CIACA, Conferência Ibero-Americana de Computação Aplicada, em Portugal, demonstrando a aplicação da IA Generativa em outras etapas do trabalho acadêmico.

1.7 Organização do trabalho

Este trabalho está estruturado em capítulos que proporcionam uma visão detalhada sobre o desenvolvimento e a implementação de um processo automatizado de levantamento de literatura apoiado por inteligência artificial generativa.

Este capítulo inicial, Introdução, contextualiza a pesquisa, apresentando a relevância do tema, os desafios na revisão de literatura e os objetivos e hipóteses do estudo.

No Capítulo 2, Fundamentação Teórica, são abordados conceitos essenciais como inteligência artificial, aprendizado de máquina e inteligência artificial generativa, além de questões éticas e regulamentações necessárias para o uso adequado dessas tecnologias.

O Capítulo 3, Referencial Teórico, detalha a metodologia de mapeamento sistemático da literatura, para a formulação de questões de pesquisa e definição de critérios de inclusão e exclusão. São apresentados os principais artigos e pesquisas encontradas na literatura.

A Metodologia, Capítulo 4, explica as etapas do processo automatizado de revisão da literatura, incluindo a integração das ferramentas Zapier, Google Sheets e ChatGPT, a

importância da engenharia de *prompt* e o papel da IA generativa na melhoria do processo.

No Capítulo 5, Resultados são apresentados e analisados os achados da pesquisa, com visualizações de dados que mostram a distribuição de artigos e a identificação dos principais autores.

O Capítulo final, Conclusões, sintetiza as contribuições do trabalho, discutindo as implicações dos resultados e sugerindo direções para futuras pesquisas. Este capítulo reflete sobre a eficácia do processo automatizado e seu impacto potencial na pesquisa acadêmica.

Esta estrutura visa oferecer uma compreensão clara e coesa do desenvolvimento e aplicação de um processo automatizado de levantamento de literatura, destacando a importância das tecnologias avançadas na pesquisa acadêmica.

2 Fundamentação Teórica

Este capítulo está estruturado para abordar as principais vertentes teóricas relacionadas ao tema, apresentando uma análise aprofundada dos conceitos fundamentais. Primeiramente, serão discutidos os conceitos-chave que definem o campo de estudo. Em seguida, serão examinadas as questões éticas e sociais que emergem com o desenvolvimento da inteligência artificial, *machine learning*, *textitdeep learning*, *large language models*, como privacidade, viés e uso indevido da tecnologia. Por fim, será destacada a importância de regulamentações adequadas para garantir que o impacto da inteligência artificial na sociedade seja positivo.

2.1 Inteligência Artificial

A Inteligência Artificial (IA) (LUSTOSA, 2024) é uma disciplina da ciência da computação que visa criar sistemas capazes de realizar tarefas que normalmente requerem inteligência humana. Essas tarefas incluem aprender a partir de experiências, reconhecer padrões, tomar decisões e compreender a linguagem. Desde sua concepção, a IA passou por várias fases de desenvolvimento, cada uma ampliando seu alcance e complexidade.

A jornada da IA começou nos anos 1950, marcada por programas capazes de jogar damas e xadrez. A conferência de Dartmouth em 1956 é frequentemente citada como o nascimento oficial da IA, quando o termo foi usado pela primeira vez pelo professor McCarthy (1981) e a proposta de que "qualquer aspecto da aprendizagem ou qualquer outra característica da inteligência pode, em princípio, ser tão precisamente descrito que uma máquina pode ser feita para simulá-lo". Esse período inicial de otimismo foi seguido por pausas nos avanços e estudos da IA, onde o financiamento e o interesse diminuíram devido às expectativas infladas e aos obstáculos técnicos significativos.

A revolução do aprendizado de máquina nos anos 1980 renovou o interesse na área, com o desenvolvimento de redes neurais que permitiam aos computadores aprender a partir de grandes quantidades de dados, assim como a pesquisa do professor Ferneda

(2006). O progresso na capacidade de processamento de computadores e a disponibilidade de grandes conjuntos de dados na década de 2000 aceleraram ainda mais os avanços da IA. Este período também testemunhou o surgimento dos algoritmos de aprendizado profundo, que imitam o funcionamento do cérebro humano e têm a capacidade de aprender, de forma autônoma, complexos padrões nos dados.

Recentemente, um dos desenvolvimentos mais notáveis no campo da IA tem sido o das inteligências artificiais generativas, que podem ser evidenciadas com diversas pesquisas, assim como a dos professores JOSKOWICZ (2024). Estas são formas de IA projetadas não só para analisar dados, mas para criar conteúdo novo e original. Operando principalmente através de redes neurais avançadas, esses sistemas aprendem a produzir obras que imitam estilos artísticos, escrita humana, e até mesmo compor músicas. Essa capacidade de geração não apenas expande as aplicações práticas da IA, mas também desafia as noções convencionais de criatividade e inovação tecnológica.

As implicações desses avanços são vastas e permeiam diversos setores da sociedade. No campo médico como na pesquisa de HIND Zineb SERHIER (2024), a IA pode ajudar a diagnosticar doenças com maior precisão. Na indústria, assim como no artigo Oktavian Reza Fuad Rachmadi (2023), pode otimizar cadeias de produção e automatizar tarefas. Na área de serviços, como no artigo Wu Xusheng Liu (2021), aprimora a interação com o cliente através de assistentes virtuais inteligentes. Conforme a tecnologia evolui, também surgem questionamentos éticos e sociais, como os impactos no mercado de trabalho e nas dinâmicas de poder globais, necessitando de uma governança cuidadosa da IA.

A inteligência artificial, representa um dos campos mais dinâmicos e transformadores da tecnologia moderna, continuando a evoluir e a redefinir os limites do possível na interação entre humanos e máquinas.

2.1.1 *Machine Learning*

O aprendizado de máquina (*Machine Learning*) (MARTINS, 2023) constitui uma subárea da inteligência artificial que se fundamenta na capacidade de sistemas computacionais aprenderem e evoluírem a partir da experiência sem serem explicitamente programados

para tal. Esse campo emprega métodos estatísticos e algoritmos para permitir que computadores realizem tarefas ao identificar padrões em grandes volumes de dados.

A importância do aprendizado de máquina pode ser observada em uma variedade de aplicações práticas que transformam significativamente setores e práticas cotidianas. Na saúde, algoritmos de *Machine Learning* são empregados no diagnóstico de doenças, análise de imagens médicas e na personalização de tratamentos para pacientes, aumentando a precisão das intervenções médicas e a eficiência dos cuidados de saúde, assim como apontado no artigo Santos (2018). No setor financeiro FAÇANHA (2019) essa tecnologia é utilizada para detectar atividades fraudulentas, automatizar negociações e personalizar serviços para clientes, oferecendo uma experiência mais segura e customizada.

Além dessas aplicações, o *Machine Learning* também revoluciona o campo da segurança cibernética, onde é usado para detectar e reagir a ameaças e vulnerabilidades de maneira proativa, assim como o estudo (SCHAEFFER-FILHO et al., 2023). No varejo, algoritmos preditivos são aplicados para otimizar os estoques e personalizar a experiência de compra, melhorando a satisfação do cliente e a eficiência operacional (MAESTRO, 2023). A otimização logística, outro campo beneficiado pelo *Machine Learning*, permite uma gestão mais eficaz da cadeia de suprimentos, reduzindo custos e tempos de entrega.

No âmbito teórico, o aprendizado de máquina desafia a compreensão tradicional de como máquinas podem executar tarefas complexas. Historicamente, a programação de computadores era limitada à execução de instruções explícitas fornecidas pelos programadores. No entanto, com o *Machine Learning*, sistemas são capazes de aprender com os dados, ajustando seus comportamentos de forma adaptativa e autônoma. Isso abre novos paradigmas em computação e interações homem-máquina, expandindo as fronteiras do que máquinas são capazes de realizar.

Entretanto, apesar dos avanços significativos e dos benefícios indiscutíveis, o aprendizado de máquina também apresenta desafios éticos e práticos (KAUFMAN, 2021). Questões como viés algorítmico, privacidade de dados e a falta de transparência nos processos decisórios automatizados são preocupações crescentes que exigem atenção contínua. A resposta a esses desafios inclui o desenvolvimento de algoritmos cada vez melhores, métodos de explicabilidade e regulações robustas para governar o uso ético da tecnologia.

Em resumo, o aprendizado de máquina é uma área de vital importância que está moldando o futuro das interações humanas, das indústrias e das tecnologias. À medida que a tecnologia avança, seu potencial para resolver problemas complexos e melhorar a qualidade de vida continua a expandir, tornando-se um campo relevante na era da informação digital.

2.1.2 *Deep Learning*

O *Deep Learning* (YANG, 2022), ou aprendizado profundo, é uma subcategoria do aprendizado de máquina que se baseia em redes neurais artificiais com várias camadas. Essas redes são projetadas para simular o modo como o cérebro humano analisa e entende as informações, o que permite que o modelo aprenda com quantidades substanciais de dados de uma forma que é tanto profunda quanto hierárquica.

A estrutura de uma rede de *Deep Learning* é composta por múltiplas camadas de nós, chamados neurônios, que processam as entradas de dados através de funções matemáticas. Esses neurônios e camadas são organizados de maneira que cada camada subsequente pode aprender e representar abstrações de nível cada vez mais alto com base nos dados recebidos da camada anterior. Esse modelo hierárquico de aprendizado é uma das principais características que diferenciam o *Deep Learning* de outras técnicas de aprendizado de máquina mais tradicionais, que podem não ser capazes de lidar com complexidades em níveis tão profundos.

A relevância do *Deep Learning* é destacada por sua capacidade de executar tarefas que seriam extremamente desafiadoras para os humanos e para outros tipos de sistemas computacionais. Por exemplo, em reconhecimento de imagem e processamento de vídeo, o *Deep Learning* permite que sistemas identifiquem objetos, pessoas, cenas e ações com precisão que muitas vezes excede a capacidade humana. Isso tem implicações significativas para áreas como segurança pública, onde o reconhecimento facial pode ser usado para identificar indivíduos em multidões, ou na medicina, onde o reconhecimento de padrões pode auxiliar no diagnóstico de doenças a partir de imagens médicas (VAMOS, 2022).

No campo da linguagem natural, o *Deep Learning* tem revolucionado a capacidade das máquinas de entender e gerar linguagem humana. Algoritmos baseados em *Deep*

Learning têm sido usados para desenvolver sistemas de tradução automática, assistentes virtuais e outras formas de interfaces homem-máquina que requerem uma compreensão profunda da linguagem natural. Essa capacidade de processar e compreender grandes volumes de texto em várias línguas torna o *Deep Learning* uma ferramenta indispensável para a globalização da tecnologia e comunicação.

Adicionalmente, o *Deep Learning* desempenha um papel crucial no desenvolvimento de veículos autônomos, onde é utilizado para interpretar complexos fluxos de dados sensoriais e tomar decisões de condução em tempo real (BARBOSA, 2020). Essa tecnologia não apenas melhora a segurança dos veículos, como também tem o potencial de transformar completamente a indústria de transporte, reduzindo acidentes, melhorando a eficiência do tráfego e diminuindo a pegada de carbono associada ao transporte rodoviário.

Apesar de seus muitos benefícios, o *Deep Learning* enfrenta desafios, como a necessidade de grandes conjuntos de dados para treinamento e a dificuldade em interpretar os modelos e suas decisões (HOSAKI; RIBEIRO, 2021). Questões éticas e sociais também surgem, particularmente em relação à privacidade, viés e uso indevido da tecnologia (NETO; MATTOS; FERNANDES, 2020). Conseqüentemente, é essencial que o desenvolvimento e a aplicação do *Deep Learning* sejam acompanhados de discussões éticas e regulamentações adequadas para garantir que seu impacto na sociedade seja positivo.

O *Deep Learning* é uma tecnologia poderosa e transformadora que está redefinindo as capacidades das máquinas e moldando o futuro da inteligência artificial. Com suas amplas aplicações e seu potencial disruptivo, o *Deep Learning* não apenas facilita avanços tecnológicos significativos, mas também levanta questões fundamentais sobre a interação entre tecnologia e sociedade.

2.1.3 IA Generativa

A inteligência artificial Generativa (TRINDADE, 2024) refere-se a um conjunto de técnicas de inteligência artificial que têm a capacidade de criar novos conteúdos, tais como texto, imagens, música e vídeos, que são indistinguíveis dos criados por humanos. Estas técnicas utilizam modelos de aprendizado de máquina, como as redes generativas adversárias e os modelos de *autoencoder*, para aprender a distribuição de dados de um conjunto de

treinamento e gerar novas instâncias de dados que se assemelham aos dados originais.

A importância da IA Generativa pode ser vista em várias aplicações práticas que transformam e facilitam a criação de conteúdo em diversos campos. Na arte e no design, por exemplo, artistas e designers estão utilizando essas tecnologias para explorar novas formas de expressão criativa, gerando obras únicas que podem complementar ou inspirar o trabalho humano (ARUDA, 2024). Na indústria do entretenimento, os modelos generativos são usados para desenvolver novos conteúdos para jogos, filmes e música, proporcionando experiências ricas e envolventes que seriam complexas e custosas para serem criadas exclusivamente por métodos tradicionais (ARUDA, 2024).

Além de contribuir para a criação artística e entretenimento, a IA Generativa tem um papel significativo no campo da pesquisa e desenvolvimento. No contexto científico, por exemplo, modelos generativos são aplicados para simular dados experimentais. Isso indica uma redução significativa no tempo e no custo associados ao desenvolvimento de novos tratamentos, permitindo uma resposta mais rápida às necessidades emergentes de saúde.

Na indústria da moda, a IA Generativa pode transformar o design de produtos ao automatizar e personalizar o processo de criação (CUTRIM; MACHADO; COSTA, 2023). Os modelos são capazes de gerar novos designs de roupas ou acessórios baseados nas preferências dos consumidores ou nas tendências emergentes, proporcionando uma produção mais ágil e alinhada com as demandas do mercado. Essa capacidade de personalização massiva tem o potencial de revolucionar a forma como os produtos são projetados, produzidos e comercializados.

Por outro lado, a utilização da IA Generativa também apresenta desafios éticos e práticos, como questões de direitos autorais e a possibilidade de produzir desinformação ou conteúdo ofensivo. Assim, a implementação responsável dessas tecnologias requer normas claras e mecanismos de controle para garantir que seu uso seja ético e benéfico.

A inteligência artificial generativa é uma área de crescente importância que oferece oportunidades substanciais para a inovação em muitos setores. A capacidade desses modelos de aprender com os dados existentes e gerar novos conteúdos abre portas para avanços em criatividade, eficiência e personalização. No entanto, o desenvolvimento e a

aplicação dessas tecnologias sejam podem ser acompanhados de uma reflexão cuidadosa sobre as implicações éticas e sociais para garantir que contribuam positivamente para a sociedade.

2.1.4 *Large Language Models - LLM*

Os *Large Language Models* (LLMs) (ZHAO, 2024) são modelos de aprendizado de máquina avançados projetados para entender, gerar e interagir com textos produzidos por humanos em larga escala. São treinados usando vastos conjuntos de dados textuais, abrangendo uma diversidade de fontes e idiomas, com o objetivo de capturar as nuances da linguagem natural. Esses modelos são baseados em arquiteturas de redes neurais profundas, que permitem que os LLMs processem sequências de palavras de forma eficiente, considerando o contexto amplo em suas análises e respostas.

A importância dos LLMs é multifacetada, refletindo-se em sua capacidade de revolucionar interações homem-máquina e automatizar tarefas que requerem compreensão linguística avançada. No campo da assistência virtual, por exemplo, LLMs permitem a criação de assistentes digitais que podem entender perguntas complexas e fornecer respostas úteis e contextualizadas, aproximando a comunicação entre humano e máquina da comunicação humana natural (LAZZARESCHI; GUERRA; NAKAOKA, 2023).

Na área de tecnologia da informação (MAESTRO, 2023) LLMs são utilizados para melhorar sistemas de busca, permitindo que compreendam melhor as intenções por trás das consultas dos usuários e proporcionem resultados mais precisos e relevantes. Isso não só melhora a experiência do usuário, mas também aumenta a eficiência na recuperação de informações.

Outra aplicação significativa dos LLMs é na área de tradução automática (DUQUE-PEREIRA; MOURA et al., 2023). A capacidade desses modelos de processar e entender múltiplas línguas torna possível a tradução de textos longos com um grau de fluidez e precisão que era difícil de alcançar com modelos anteriores. Isso tem um impacto profundo na comunicação global, facilitando o intercâmbio cultural e comercial entre regiões de diferentes idiomas.

Além dessas aplicações, os LLMs têm um papel significativo na geração de conteúdo,

desde a escrita de artigos e relatórios até a criação de poesia e prosa (ROSSONI; CHAT, 2022). A capacidade de gerar texto coerente e contextualmente apropriado permite que esses modelos auxiliem em tarefas criativas, oferecendo suporte a escritores e criadores de conteúdo com sugestões e edições automáticas.

No entanto, a expansão dos LLMs também traz desafios éticos e práticos. A precisão dos dados e o viés incorporado nos conjuntos de treinamento podem levar a resultados que perpetuam estereótipos ou discriminam certos grupos. Além disso, questões de privacidade e direitos autorais surgem quando esses modelos são alimentados com dados sensíveis ou protegidos por direitos autorais (NACIMENTO, 2024).

Por fim, os LLMs representam um avanço significativo na capacidade das máquinas de interagir com o texto humano de maneira significativa e útil. A importância desses modelos se estende além da tecnologia, influenciando áreas como comunicação, educação, e entretenimento. Enquanto a tecnologia continua a evoluir, é necessário abordar as questões éticas e garantir que seu desenvolvimento e aplicação beneficiem a sociedade como um todo.

2.1.5 Engenharia de *prompt*

A engenharia de *prompt* (LARGUESA, 2024) é uma técnica significativa no desenvolvimento e utilização de modelos de linguagem natural para gerar resultados precisos e relevantes. No contexto do levantamento automatizado de literatura, a engenharia de *prompt* desempenha um papel importante na geração de palavras-chave, sinônimos e resumos de artigos acadêmicos. Esta técnica envolve a formulação cuidadosa de consultas ou comandos (*prompts*) que são enviados ao modelo de linguagem, com o objetivo de orientar e otimizar suas respostas.

A importância da engenharia de *prompt* neste trabalho reside na capacidade de maximizar a eficiência e a precisão ao gerar conteúdos que atendam às necessidades específicas da pesquisa. Ao elaborar *prompts* claros e bem-estruturados, os pesquisadores podem direcionar o modelo a produzir palavras-chave altamente relevantes e sinônimos que aprimoram a *string* de busca, resultando em uma coleta de literatura mais abrangente e focada. Além disso, *prompts* bem formulados são essenciais para que o modelo possa

reunir informações dos artigos e gerar respostas de maneira concisa e coesa, capturando os principais pontos e contribuições de cada trabalho acadêmico. Isso não só economiza tempo, mas também garante que os resumos sejam úteis e informativos.

A engenharia de *prompt* também permite a mitigação de vieses e a melhora contínua do processo automatizado. Ao experimentar diferentes estruturas de *prompts* e analisar os resultados gerados, os pesquisadores podem ajustar e refinar suas abordagens, identificando quais formatos produzem as respostas mais precisas e relevantes. Este processo iterativo é necessário para adaptar o modelo a diferentes contextos e tópicos de pesquisa, garantindo que ele permaneça uma ferramenta eficaz e versátil. A engenharia de *prompt* é uma técnica indispensável para otimizar o uso de modelos de linguagem natural em tarefas complexas de pesquisa acadêmica, como o levantamento automatizado de literatura, melhorando significativamente a qualidade e a eficiência do trabalho realizado.

Além disso, a engenharia de *prompt* desempenha um papel vital no processo de automação de fluxos de trabalho entre diferentes aplicativos, facilitando a coleta e a organização de dados. Ao utilizar *prompts* cuidadosamente elaborados, é possível configurar o modelo para gerar respostas específicas que, em seguida, são automaticamente transferidas para plataformas de armazenamento e organização de dados. Essa integração não só acelera o processo de levantamento de literatura, mas também assegura que as informações coletadas sejam estruturadas de forma útil e acessível. *Prompts* bem formulados garantem que as interações entre o modelo de linguagem e as plataformas de automação sejam eficientes, resultando em um fluxo de trabalho mais coeso e produtivo para os pesquisadores.

Dessa forma, a engenharia de *prompt* não apenas aprimora a qualidade das respostas dos modelos de linguagem, mas também otimiza todo o processo automatizado de levantamento de literatura, desde a geração de conteúdo até a organização e armazenamento de dados, proporcionando uma solução robusta e integrada para pesquisas acadêmicas.

2.2 Automatização de processos em pesquisas acadêmicas

A automação de processos (JARDIM-FILHO, 2022) na pesquisa acadêmica refere-se ao uso de tecnologias avançadas para executar tarefas repetitivas e complexas que tradicionalmente requerem intervenção humana. Esse conceito abrange desde o gerenciamento de dados e análises estatísticas até a revisão de literatura e a organização de referências bibliográficas. As ferramentas e técnicas de automação empregadas são projetadas para aumentar a eficiência, reduzir erros e permitir que os pesquisadores se concentrem em aspectos mais criativos e significativos de seus trabalhos.

A importância da automação em pesquisa acadêmica pode ser observada em diversas facetas do processo de investigação. Primeiramente, na coleta e análise de dados, a automação permite manipular grandes volumes de informações com precisão e rapidez superior à capacidade humana. Isso é particularmente valioso em campos como a genética, epidemiologia e ciências ambientais, onde os conjuntos de dados podem ser extensos e complexos. Algoritmos automatizados podem realizar análises estatísticas, reconhecer padrões e até mesmo identificar anomalias que poderiam ser negligenciadas por um olhar humano.

Adicionalmente, a automação contribui significativamente para a eficácia da revisão de literatura, uma das etapas fundamentais em qualquer projeto de pesquisa. Ferramentas de automação são capazes de vasculhar múltiplas bases de dados para encontrar artigos relevantes, extrair informações chave e até mesmo sugerir materiais baseados em critérios de relevância predefinidos. Este processo não só economiza tempo, mas também aumenta a abrangência e a profundidade das revisões de literatura, garantindo que os pesquisadores estejam bem informados sobre os desenvolvimentos mais recentes em suas áreas de especialização.

No que diz respeito à redação e submissão de trabalhos acadêmicos, a automação também desempenha um papel importante. Softwares de gerenciamento de referências bibliográficas podem formatar citações e referências de acordo com variados estilos editoriais, reduzindo o esforço manual e o risco de erros (JESUS, 2023). Além disso, algumas

plataformas oferecem funcionalidades que ajudam na estruturação de manuscritos, na verificação de plágio e até na escolha da revista adequada para submissão, baseando-se na análise do conteúdo e no escopo das publicações.

No entanto, a implementação de automação na pesquisa acadêmica não está isenta de desafios. A dependência de ferramentas automatizadas pode levar a uma desvalorização das habilidades tradicionais de pesquisa, como o pensamento crítico e a capacidade de análise independente. Além disso, a qualidade dos resultados depende intrinsecamente da qualidade dos dados de entrada e dos algoritmos utilizados, o que requer uma constante verificação e atualização dos sistemas de automação para evitar a propagação de erros.

A automação de processos na pesquisa acadêmica representa uma evolução significativa na maneira como o conhecimento é gerado e disseminado. Suas contribuições para a eficiência, precisão e abrangência da pesquisa são indiscutíveis, embora seja importante que essas tecnologias sejam utilizadas de maneira complementar às competências humanas, garantindo a integridade e a inovação contínua no campo acadêmico.

2.2.1 Ferramentas e tecnologias que apoiam a IA

No contexto atual de desenvolvimento tecnológico, a inteligência artificial (IA) tem se beneficiado significativamente de uma variedade de ferramentas e plataformas que não só facilitam a criação e implementação de modelos de IA, mas também ampliam suas aplicações práticas. Ferramentas como ChatGPT, ChatPDF, Google Sheets, Zapier, e outras similares como Microsoft Power Automate, Airtable, e IBM Watson, são algumas das ferramentas que têm desempenhado papéis fundamentais em diversas esferas da automação, análise de dados, e interação humano-computador.

ChatGPT (2022) da OpenAI é um exemplo notável de um modelo de linguagem avançado que utiliza redes neurais profundas para processar e gerar texto de forma eficaz. Esta ferramenta avançada de processamento de linguagem natural é capaz de realizar tarefas como responder perguntas, gerar textos coerentes e complexos, e automatizar interações com o usuário, demonstrando uma capacidade impressionante de compreender e gerar linguagem humana de forma eficaz. O ChatGPT é frequentemente utilizado para potencializar *chatbots*, sistemas de suporte ao cliente, e até mesmo como assistente de

escrita, oferecendo uma interface altamente interativa e adaptável. O ChatGPT-4, da OpenAI, é um avançado modelo de linguagem natural que utiliza redes neurais profundas para entender e gerar texto com precisão. Seus *plugins* permitem integrar diversas aplicações e serviços, como acesso a bancos de dados, cálculos complexos e controle de dispositivos IoT, ampliando suas funcionalidades e tornando-o uma ferramenta poderosa para desenvolvedores, empresas e usuários finais. Outras ferramentas também vêm ganhando visibilidade, como o Gemini e o Claude 3. O (GEMINI, 2023), do Google DeepMind, é um modelo avançado de inteligência artificial que visa superar as capacidades dos LLMs anteriores, combinando processamento de linguagem natural com capacidades de aprendizado multimodal. Já o (CLAUDE, 2023), da Huawei, é uma plataforma de nuvem que oferece serviços integrados de IA, *big data* e Internet das Coisas (IoT) para melhorar a eficiência e inovação empresarial.

ChatPDF (2023), por sua vez, representa uma inovação no manejo de documentos em PDF, permitindo que usuários executem tarefas de manipulação de documentos por meio de comandos de texto simples. Esta ferramenta simplifica processos como a extração de texto, conversão de documentos e edição de informações, o que é importante em ambientes onde o processamento eficiente de grandes volumes de documentos é crítico, o ChatGPT inclui essa funcionalidade como um de seus *plugins*.

GoogleSheets (2006) se destaca como uma ferramenta de planilha poderosa que suporta extensas funcionalidades de análise de dados e colaboração em tempo real. A capacidade de integrar Google Sheets com *scripts* personalizados e APIs de IA permite automações complexas e análises profundas, facilitando a gestão de dados em grande escala. Essa integração é particularmente útil para analistas de dados e desenvolvedores que precisam de soluções rápidas e eficazes para o tratamento e visualização de dados.

Zapier (2011) é uma plataforma conhecida em automação que conecta aplicativos e automatiza fluxos de trabalho sem a necessidade de desenvolvimento de código. Esta ferramenta pode ser usada para vincular funcionalidades de IA, como as oferecidas pelo ChatGPT, a outras aplicações como sistemas de gestão de projetos, ou plataformas de *marketing* digital, criando automações que melhoram a eficiência operacional e reduzem a necessidade de intervenção manual repetitiva.

Além dessas ferramentas Microsoft Power Automate (2019) (anteriormente conhecido como Microsoft Flow) oferece capacidades semelhantes ao Zapier, mas com integração mais profunda no ecossistema Microsoft, permitindo automações dentro de aplicações como Office 365 e Microsoft Dynamics. Airtable (2023) funciona como uma plataforma de criação de banco de dados misto com funcionalidades de planilha, ideal para gerenciamento de projetos e CRM com uma forte capacidade de personalização e automação. IBM Watson (2023) é outro exemplo poderoso de IA aplicada, oferecendo serviços que vão desde a assistência virtual até análises de sentimentos e personalização de experiências de usuário.

A integração dessas ferramentas transformadoras não só enriquece o ecossistema de IA, mas também desempenha um papel significativo em democratizar a tecnologia de IA, tornando-a acessível a um público mais amplo que inclui não só desenvolvedores e técnicos, mas também profissionais de negócios e educadores. Enquanto continua-se a explorar e expandir as capacidades dessas ferramentas, também deve-se permanecer vigilantes em relação às implicações éticas, de segurança e de privacidade que acompanham a adoção em larga escala de tecnologias de IA, garantindo que seu desenvolvimento e aplicação sejam realizados de maneira responsável e benéfica para todos.

2.2.2 Integração de Ferramentas e Abordagens de Automatização

A integração de ferramentas e abordagens de automatização emerge como uma estratégia interessante no desenvolvimento e aplicação da tecnologia moderna, particularmente no campo da inteligência artificial (IA). Esse processo envolve a combinação sinérgica de diferentes softwares e plataformas para criar sistemas mais eficientes e capazes de realizar tarefas complexas com mínima intervenção humana. A importância desta integração reside na sua capacidade de otimizar processos, melhorar a produtividade e facilitar a inovação em várias indústrias.

Os benefícios da integração de ferramentas de automatização são vastos e significativos. Primeiramente, ela permite a automação de tarefas repetitivas, liberando profissionais para se concentrarem em atividades mais estratégicas e criativas. Por exemplo, a integração entre Google Sheets e Zapier pode automatizar a transferência de dados

entre diferentes aplicativos, garantindo que as informações estejam sempre atualizadas sem necessidade de intervenção manual. Da mesma forma, a combinação de ChatGPT com plataformas como Microsoft Power Automate facilita a criação de *chatbots* inteligentes que podem gerenciar perguntas frequentes e interações com clientes, melhorando o atendimento ao cliente enquanto reduz custos operacionais.

Além disso, a integração de ferramentas de automatização melhora a precisão dos dados ao reduzir erros humanos. Por exemplo, o uso de IA para processar e analisar grandes volumes de dados em Airtable pode ajudar a identificar *insights* e padrões que seriam difíceis de detectar manualmente. Isso é especialmente valioso em campos como a pesquisa de mercado e análises financeiras, onde decisões precisas e baseadas em dados são cruciais (CARVALHO, 2021).

No entanto, a integração de ferramentas de automatização também enfrenta várias dificuldades. A complexidade técnica é uma das principais barreiras, pois a integração eficaz muitas vezes requer conhecimento especializado em múltiplas plataformas e linguagens de programação. Além disso, a interoperabilidade entre diferentes sistemas pode ser um desafio, especialmente quando envolvem softwares proprietários ou plataformas que não foram projetadas para trabalhar conjuntamente. Isso pode resultar em custos adicionais e atrasos significativos em projetos de automação (OLIVEIRA, 2018).

Outra consideração importante é a questão da segurança da informação. A integração de várias ferramentas aumenta o risco de vulnerabilidades de segurança, especialmente se os dados estão sendo compartilhados entre diferentes plataformas na nuvem (SIRINO, 2018). A gestão de acessos e a proteção de dados sensíveis tornam-se, portanto, componentes críticos que requerem atenção constante.

Exemplos de integração eficaz de ferramentas de automatização podem ser vistos em diversas áreas. No setor educacional, ferramentas como IBM Watson podem ser integradas com sistemas de gestão de aprendizado para proporcionar experiências educacionais personalizadas e adaptativas (MIRANDA; FILHO, 2024). No setor de saúde, a integração de sistemas de IA para análise de imagens médicas com registros eletrônicos de saúde pode melhorar significativamente a precisão diagnóstica e a eficiência do tratamento (DALL'ALBA et al., 2018).

Em resumo, a integração de ferramentas e abordagens de automatização é importante para a evolução da tecnologia e sua aplicação em escala. Apesar dos desafios, os benefícios de melhorar a eficiência, precisão e capacidade de inovação são incontestáveis, tornando significativo a continuidade do desenvolvimento e aprimoramento das estratégias de integração tecnológica.

2.3 Conclusões do capítulo

Este capítulo apresentou uma análise detalhada dos conceitos fundamentais relacionados ao tema de estudo, destacando a importância de abordagens éticas e regulamentações adequadas no desenvolvimento e aplicação da inteligência artificial. A compreensão dessas bases teóricas é importante para sustentar a pesquisa e garantir que o uso da tecnologia resulte em benefícios significativos para a sociedade. Ao estabelecer um alicerce teórico sólido, este trabalho busca contribuir para o avanço do conhecimento e para a solução dos desafios contemporâneos enfrentados na área de inteligência artificial.

3 Referencial Teórico

Neste capítulo, será detalhada a aplicação do mapeamento sistemático da literatura, explicando a metodologia utilizada, incluindo o framework PICOC (População, Intervenção, Comparação, Desfecho e Contexto), que auxilia na formulação de questões de pesquisa e na definição de critérios de inclusão e exclusão dos estudos. Além de descrever a metodologia, serão discutidos os resultados obtidos a partir da revisão sistemática realizada, destacando as principais descobertas, tendências e lacunas identificadas na literatura. Esta abordagem sistemática e estruturada garante a relevância e a qualidade da literatura revisada, contribuindo significativamente para a robustez e precisão dos resultados da pesquisa.

3.1 Mapeamento sistemático da literatura

O mapeamento sistemático da literatura (DERMEVAL, 2020) é uma metodologia de pesquisa que visa identificar, avaliar e interpretar todas as pesquisas relevantes disponíveis sobre um determinado tema ou questão de pesquisa. Essa abordagem é amplamente utilizada em diversas áreas do conhecimento, incluindo as ciências sociais, saúde, engenharia e tecnologia da informação. O objetivo principal do mapeamento sistemático é proporcionar uma visão abrangente e objetiva do estado de um campo de estudo, identificando lacunas de pesquisa, tendências e padrões emergentes.

A importância do mapeamento sistemático da literatura reside em sua capacidade de fornecer uma base sólida para a tomada de decisões baseadas em evidências. Ao reunir e sintetizar as evidências disponíveis, os pesquisadores podem obter *insights* valiosos sobre o que já foi estudado, quais métodos foram utilizados e quais são as principais conclusões e limitações dos estudos existentes. Isso é particularmente útil para evitar a duplicação de esforços de pesquisa e para direcionar recursos para áreas onde há uma necessidade real de investigação.

O mapeamento sistemático da literatura está relacionado ao *framework*, PICOC,

utilizado nessa pesquisa, (SANTOS, 2007). PICOC é um acrônimo que representa os cinco elementos-chave de uma pergunta de pesquisa bem formulada em estudos de revisão sistemática e mapeamento sistemático da literatura: a População refere-se ao grupo de indivíduos que são o foco da pesquisa. A definição clara da população ajuda a delimitar o escopo do estudo e a identificar os participantes relevantes. A Intervenção descreve a ação ou tratamento que está sendo avaliado, devendo ser especificada de forma clara para que seja possível determinar sua eficácia. A Comparação refere-se ao grupo de controle ou à intervenção alternativa com a qual a intervenção principal será comparada, é importante para avaliar a eficácia relativa da intervenção. O Desfecho são os resultados que serão medidos para avaliar a eficácia da intervenção, devem ser claramente definidos e mensuráveis. Por fim, o Contexto, elemento importante que considera as circunstâncias ou condições sob as quais a pesquisa é conduzida.

A estrutura PICOC é significativa para delimitar o escopo da pesquisa, que é comumente utilizado para formular questões de pesquisa em estudos de revisão ou mapeamento sistemáticos da literatura. O PICOC ajuda a definir claramente os elementos-chave da questão de pesquisa, facilitando a busca por estudos relevantes e a análise dos resultados. Embora o mapeamento sistemático da literatura não se limite ao uso do PICOC, essa estrutura pode ser adaptada para auxiliar na definição do escopo do mapeamento e na identificação de critérios de inclusão e exclusão dos estudos.

A importância do mapeamento sistemático em trabalhos acadêmicos reside na sua capacidade de orientar o processo de revisão de literatura de maneira estruturada e eficiente. Ao definir claramente os elementos do PICOC, o pesquisador pode assegurar a relevância da pesquisa, especificando a população, intervenção, comparação, desfecho e contexto, garantindo que a questão de pesquisa seja relevante para o campo de estudo e para a comunidade científica. A estrutura PICOC ajuda na formulação de *strings* de busca precisas, aumentando a probabilidade de encontrar estudos relevantes e reduzindo o risco de viés de seleção. Ao delimitar os critérios de inclusão e exclusão com base nos elementos PICOC, o pesquisador pode realizar uma análise mais focada e comparativa dos estudos selecionados, contribuindo para a robustez das conclusões. A utilização do PICOC promove a transparência na metodologia de revisão, permitindo que outros pesquisadores

compreendam às escolhas feitas e, se necessário, repliquem o estudo. A estrutura PICOC facilita a síntese de evidências, permitindo a comparação entre diferentes estudos e a identificação de lacunas no conhecimento, o que pode orientar futuras pesquisas.

Para esse trabalho, foi desenvolvida a seguinte estrutura do PICOC, como é apresentado na Tabela 3.1, identificando-se a População como sendo o foco em revisões de literatura, o que implica um interesse em abordagens acadêmicas para a consolidação do conhecimento. A Intervenção é caracterizada pelo uso de mapeamento sistemático ou revisão sistemática, sugerindo uma metodologia estruturada para a coleta e análise de dados. O Controle não foi definido, o que pode indicar uma abordagem exploratória ou a ausência de um grupo de comparação direta. O Desfecho está centrado na utilização de ferramentas, aplicações ou softwares, apontando para o resultado prático do processo de revisão. Por fim, o Contexto é definido na utilização de um processo automatizado, salientando a busca por eficiência e inovação tecnológica na gestão da informação acadêmica.

Tabela 3.1: PICOC.

PICOC	Palavras-Chave
Population	Literature review
Intervention	Systematic mapping, systematic review
Control	Not defined
Outcome	Tool, application, software
Context	Automated process

A combinação desses elementos no PICOC evidencia uma metodologia que transcende a coleta de dados manual, buscando a integração de soluções de inteligência artificial para otimizar o processo de revisão de literatura. Este enfoque não só aumenta a capacidade de processamento e análise de grandes volumes de dados, mas também realça o potencial para descobertas mais ágeis e precisas dentro do campo acadêmico. A integração da IA no levantamento de literatura é, portanto, não apenas uma resposta à crescente complexidade e volume de dados, mas também uma estratégia para manter a relevância e a qualidade da pesquisa no cenário atual de produção científica (SOUZA; CERVENY, 2006).

3.1.1 Construção das *strings* de busca

A construção de *strings* de busca eficazes é um componente vital no âmbito da pesquisa acadêmica, em especial na realização de revisões sistemáticas de literatura. Uma *string* de busca apropriada deve ser capaz de capturar a essência de um campo de estudo, refletindo os conceitos e termos pertinentes que delimitam o escopo da investigação. As *strings* de busca direcionam as consultas aos repositórios de dados bibliográficos, e sua precisão influencia diretamente a qualidade e a relevância dos resultados obtidos (MARTINEZ, 2013).

Fontes de busca acadêmicas são essenciais para o avanço do conhecimento científico, proporcionando acesso a uma vasta gama de literatura especializada e de alta qualidade. Plataformas como IEEEExplore e Google Acadêmico são exemplos proeminentes nesse contexto. IEEEExplore, mantida pelo IEEE, oferece uma coleção abrangente de documentos em engenharia elétrica, ciência da computação e eletrônica, sendo uma referência para pesquisadores e profissionais. Google Acadêmico, por sua vez, é uma ferramenta gratuita que indexa uma ampla variedade de literatura acadêmica, facilitando a busca por artigos, teses e livros de diversas disciplinas. A acessibilidade e a eficiência dessas plataformas permitem que estudantes, pesquisadores e acadêmicos obtenham rapidamente informações relevantes e atualizadas, impulsionando a pesquisa e a inovação em várias áreas do conhecimento.

Para esse trabalho foram criadas duas *strings* de busca, a primeira foi construída seguindo um método tradicional sem o auxílio de inteligência artificial. Esta abordagem inicial, apesar de ser amplamente adotada, resultou na recuperação de nenhum artigo relevante. Isso reflete uma lacuna nas capacidades de busca convencionais, onde a definição de termos e a sua correlação com a literatura existente pode ser inadequada ou insuficiente para capturar a totalidade das publicações pertinentes. A deficiência na busca pode estar relacionada à escolha de palavras-chave limitadas ou à falta de termos sinônimos e relacionados que podem estar em uso na literatura acadêmica, a pesquisa foi realizada em março de 2024 e os seguintes resultados foram encontrados.

(“*literature review*”) AND (“*systematic mapping*”OR “*systematic review*”) AND (“*au-*

tomated process) AND (*“tool”OR “application”OR “program”OR “software”*)

Para superar essa limitação, foi empregado o método proposto nesse trabalho, com o apoio de inteligência artificial generativa, no caso, um modelo de linguagem como o ChatGPT (SANTOS, 2023). A IA foi utilizada para expandir a *string* de busca inicial, sugerindo termos adicionais e variações que poderiam estar associadas aos conceitos de interesse. O uso da IA permitiu a inclusão do termo “automation” na *strings* de busca, ampliando significativamente o escopo de pesquisa e resultando na identificação de 80 artigos relevantes. Essa melhoria na busca é atribuída à capacidade da IA de compreender e sugerir termos e conceitos contextuais que um pesquisador pode não considerar inicialmente.

(“literature review”) AND (“systematic mapping”OR “systematic review”) AND (“automated process”OR “automation”) AND (“tool”OR “application”OR “program”OR “software”)

A comparação das duas *strings* de busca revela a importância da inclusão da IA no processo de levantamento de literatura. Enquanto a abordagem tradicional pode ser restritiva e limitada pela interpretação humana e pelo conhecimento prévio, a IA pode oferecer uma perspectiva mais ampla e diversificada, cruzando fronteiras disciplinares e semânticas para reunir uma gama mais extensa de literatura relevante. Além disso, a IA pode ajudar a identificar lacunas de pesquisa e novos caminhos de investigação, contribuindo para a descoberta de conhecimento e para a evolução das áreas de estudo.

O sucesso da *strings* de busca ajustada com o auxílio da IA ressalta o potencial da tecnologia para aprimorar os métodos de revisão de literatura, tornando-os mais abrangentes e menos susceptíveis ao viés de seleção. Assim, a inclusão da IA no processo de revisão de literatura não é apenas uma melhoria técnica, mas uma evolução metodológica que reflete a necessidade de adaptação às complexidades do conhecimento contemporâneo e à sua rápida expansão. A utilização de ferramentas de IA no desenvolvimento de *strings* de busca pode ser considerada um avanço significativo na pesquisa acadêmica, promovendo a eficácia e a eficiência na identificação de informações relevantes e na construção

do conhecimento científico.

3.1.2 Critérios de inclusão e exclusão

A avaliação criteriosa de inclusão e exclusão em pesquisas acadêmicas que visam a automatização de levantamentos literários, especialmente quando apoiadas por inteligência artificial generativa, é um pilar no estabelecimento de um corpo de literatura robusto e relevante (LUNETTA; GUERRA, 2023). Os critérios de inclusão destinam-se a identificar estudos que ofereçam contribuições diretas e significativas ao tema em estudo, tais como estudos experimentais, estudos de caso, ou análises detalhadas. Isso assegura que a literatura revisada seja capaz de fornecer *insights* substanciais sobre a implementação e o impacto de processos automatizados na área de ciência da computação, oferecendo uma base empírica sólida para futuras investigações e desenvolvimentos tecnológicos.

Por outro lado, os critérios de exclusão são igualmente vitais para a integridade do levantamento da literatura. A exclusão de capítulos de livros, chamadas para congressos e materiais didáticos de nível básico garante que a pesquisa seja ancorada em fontes científicas rigorosas e especializadas. Da mesma forma, a exclusão de estudos que não estão integralmente acessíveis ou que não abordam o tema dentro dos domínios da ciência da computação elimina o risco de contaminação do conjunto de dados com informações tangenciais ou irrelevantes.

A definição desses critérios, é importante não apenas para a seleção de literatura relevante, mas também para a avaliação subsequente da qualidade dos resultados. Ao identificar artigos que não apenas mencionam o processo automatizado, mas que também apresentam avaliações de resultados e análises estatísticas, os pesquisadores podem assegurar que as conclusões e recomendações do levantamento da literatura sejam baseadas em dados sólidos e interpretações confiáveis.

Concluindo, a adoção de critérios de inclusão e exclusão rigorosos e bem definidos, como é mostrado na Tabela 3.2, é imperativa para a condução eficaz de uma revisão sistemática da literatura, especialmente quando se trata de explorar a intersecção da Ciência da Computação com processos automatizados e inteligência artificial. Essa metodologia

estratégica não apenas facilita a identificação de literatura pertinente, mas também garante a relevância e a validade das informações compiladas, o que é significativo para o avanço do conhecimento.

Tabela 3.2: Critérios de Inclusão e Exclusão.

Inclusão	Artigos contendo estudos experimentais, estudo de caso ou análises sobre automação no contexto de levantamento da literatura
	Estudos contendo análise, discussão ou implementação de automação do levantamento de literatura
Exclusão	Capítulos de livro, chamadas a congressos e materiais de ensino básico
	Estudos que não podem ser acessados por inteiro
	Estudos que não abordem o tema na área da Ciência da Computação

3.2 Resultados

Após serem estabelecidos critérios de inclusão, exclusão e qualidade visando identificar os artigos mais pertinentes para a pesquisa, são encontrados os resultados a serem analisados. Dos 319 artigos inicialmente identificados, 95 estavam disponíveis com acesso livre. Foi realizado então uma análise minuciosa desses artigos, combinando métodos automatizados e revisão manual, a fim de determinar sua relevância para o escopo do estudo. Após esse processo, foram selecionados cuidadosamente 7 artigos que atendiam aos critérios estabelecidos e contribuíam significativamente para a pesquisa, assim como apresentado na Tabela 3.3.

A análise dos artigos selecionados revelou uma variedade de abordagens e descobertas, destacando-se pela profundidade e relevância de seus conteúdos. A combinação de métodos automatizados de busca com uma revisão manual criteriosa permitiu uma avaliação abrangente da literatura científica disponível, resultando em uma seleção final que refletia os objetivos e necessidades da pesquisa.

Tabela 3.3: Resultado mapeamento da literatura após critérios de inclusão e exclusão.

Importação de estudos encontrados em bases de dados digitais	319 artigos
Artigos duplicados	0 artigos
Critérios de Inclusão e Exclusão	95 artigos
Artigos utilizados na pesquisa	7 artigos

Seguindo os resultados, a análise dos autores mais frequentes nas publicações



Figura 3.2: Publicações por ano.

Esses resultados não apenas destacam os principais contribuintes para a literatura científica, mas também indicam tendências temporais que podem orientar futuras pesquisas e investimentos. A análise detalhada dos autores e a distribuição temporal das publicações fornecem uma base sólida para entender a dinâmica e o crescimento da área, além de identificar possíveis lacunas e oportunidades para novas investigações.

3.2.1 Análise de qualidade dos artigos

A análise de artigos após o mapeamento da literatura é uma etapa importante na produção científica, pois permite uma compreensão profunda e crítica das tendências, lacunas e contribuições existentes no campo de estudo. O mapeamento da literatura, que envolve a identificação, categorização e síntese dos estudos relevantes, oferece uma visão panorâmica do conhecimento acumulado. No entanto, é a análise dos artigos que fornece *insights* detalhados e direciona a pesquisa futura de maneira significativa.

A análise dos artigos após o mapeamento da literatura possibilita a identificação de tendências e padrões emergentes no campo de estudo. Ao examinar as metodologias, resultados e conclusões dos estudos selecionados, os pesquisadores podem detectar temas recorrentes e novas direções de pesquisa. Isso é particularmente importante em

áreas dinâmicas, onde o conhecimento está em constante evolução. Compreender essas tendências auxilia na definição de agendas de pesquisa que sejam contemporâneas e relevantes.

Uma das contribuições mais significativas da análise de artigos é a identificação de lacunas no conhecimento. O mapeamento da literatura revela o que já foi estudado, mas a análise crítica expõe o que ainda não foi explorado ou está sub-representado. Essas lacunas representam oportunidades valiosas para pesquisas futuras. Ao focar nesses aspectos, os pesquisadores podem contribuir para o avanço do conhecimento e preencher os vazios existentes na literatura.

A análise dos artigos permite uma avaliação detalhada da qualidade da pesquisa existente. Aspectos como a robustez metodológica, a validade dos resultados e a relevância das conclusões podem ser rigorosamente avaliados. Isso é significativo para garantir que futuras pesquisas se baseiem em fundamentos sólidos e confiáveis. A crítica construtiva das metodologias empregadas nos estudos anteriores também pode inspirar melhorias e inovações nas abordagens de pesquisa.

Além disso, a análise detalhada dos artigos pode levar ao desenvolvimento de novas hipóteses e teorias. Ao sintetizar os achados de múltiplos estudos, os pesquisadores podem formular novas perguntas de pesquisa e teorias que expliquem melhor os fenômenos observados. Isso não só avança o conhecimento teórico, mas também orienta a pesquisa empírica subsequente.

Os *insights* derivados da análise de artigos são frequentemente aplicáveis na prática e na formulação de políticas. Em áreas como a saúde, educação e tecnologia, a tradução do conhecimento acadêmico para a prática é vital. A análise crítica dos estudos permite a identificação de práticas baseadas em evidências e a formulação de recomendações políticas informadas. Isso garante que as intervenções e políticas sejam baseadas nos melhores dados disponíveis, aumentando sua eficácia e impacto.

Ademais, a análise dos artigos após o mapeamento da literatura pode facilitar a colaboração interdisciplinar. Identificar conexões entre diferentes áreas de estudo pode abrir novas possibilidades de pesquisa colaborativa. Isso é particularmente relevante em áreas complexas que se beneficiam de abordagens multidisciplinares para resolver proble-

mas. Dessa forma, após o mapeamento da literatura foi realizada a análise de qualidade dos artigos e o total usado no estudo foram 7 artigos, e a análise foi feita de acordo com as informações propostas na Tabela 3.4. Os artigos avaliados na tabela serão apresentados nessa mesma ordem na seção de trabalhos relacionados.

Tabela 3.4: Análise de qualidade dos artigos.

Artigos	Automatizado	Avaliação	Análise
(AZAM, 2024)	Sim	Não	Não
(BARTLETT; KABIR; HAN, 2023)	Sim	Não	Não
(FAROOQ, 2023)	Sim	Não	Não
(IMRAN, 2023)	Sim	Não	Não
(MARSHALL, 2019)	Não	Sim	Sim
(DINTER, 2021)	Não	Não	Não
(WAGNER; LUKYANENKO; PARÉ, 2022)	Não	Sim	Não

3.3 Trabalhos relacionados

Nessa sessão serão apresentadas as obras e artigos relacionados com essa pesquisa, um processo automatizado para levantamento de literatura apoiado por inteligência artificial generativa. Os trabalhos foram encontrados através do levantamento da literatura, usando a *string* já descrita acima, gerada com inteligência artificial generativa e através de *snowballing*, que são artigos relacionados àqueles encontrados na *string* de busca. As técnicas de *snowballing*, incluindo *backward snowballing*, que examina referências anteriores e *forward snowballing* que identifica estudos posteriores que citam o trabalho, são usadas para garantir uma cobertura abrangente da literatura

A pesquisa conduzida por Azam (2024) introduz uma abordagem inovadora para a análise de circuitos integrados analógicos, focando na injeção de defeitos e simulação de falhas. Embora o estudo se concentre em aplicações específicas para circuitos integrados, as metodologias empregadas apresentam implicações significativas para o campo do levantamento de literatura apoiado por inteligência artificial generativa. A utilização de técnicas de simulação e modelagem para avaliar a robustez de circuitos integrados pode ser adaptada para automatizar o processo de revisão bibliográfica. Ao empregar algoritmos de inteligência artificial para simular cenários de pesquisa e modelar dados bibliográficos, é possível identificar padrões e tendências em vastos conjuntos de literatura científica. Essa

abordagem não apenas acelera o processo de levantamento de literatura, mas também aumenta a precisão e confiabilidade dos resultados obtidos. Além disso, a estratégia de injeção de defeitos proposta pelo autor pode ser aplicada para detectar inconsistências e erros em bases de dados bibliográficas. A implementação de algoritmos de inteligência artificial capazes de simular falhas em dados bibliográficos pode contribuir para a melhoria da qualidade das revisões de literatura, garantindo a integridade e a confiabilidade das informações científicas. Dessa forma, o trabalho oferece *insights* para o desenvolvimento de sistemas automatizados de levantamento de literatura apoiados por inteligência artificial generativa. A adaptação de técnicas de simulação e modelagem, originalmente aplicadas ao estudo de circuitos integrados, pode revolucionar a maneira como os pesquisadores conduzem revisões bibliográficas, tornando o processo mais eficiente, preciso e confiável.

A pesquisa realizada por Bartlett, Kabir e Han (2023) aborda a integração de sistemas de gerenciamento de processos de negócios com tecnologias de inteligência artificial (IA), destacando a importância dessa combinação para a melhoria da eficiência operacional e da tomada de decisões. A aplicação de IA em processos de negócios tem o potencial de automatizar tarefas repetitivas, fornecer análises preditivas e facilitar a adaptação a mudanças no ambiente de negócios. No contexto do levantamento de literatura apoiado por IA generativa, a abordagem proposta pode ser adaptada para otimizar o processo de revisão bibliográfica. A integração de sistemas de BPM baseados em IA no levantamento de literatura pode proporcionar uma estrutura para a automação de tarefas relacionadas à busca, seleção, análise e síntese de dados bibliográficos. Isso não apenas agiliza o processo de revisão, mas também aumenta a consistência e a precisão dos resultados. Além disso, a utilização de IA em sistemas de BPM pode melhorar a capacidade de identificar tendências emergentes e lacunas de conhecimento em grandes conjuntos de dados bibliográficos. A análise preditiva, um componente chave da IA, pode ser empregada para prever futuras direções de pesquisa e áreas de interesse, fornecendo *insights* valiosos para pesquisadores e decisores. A pesquisa também destaca a importância da adaptabilidade em sistemas de BPM baseados em IA. Essa característica é importante para o levantamento de literatura, pois o campo da ciência está em constante evolução. Sistemas de revisão bibliográfica que podem se adaptar dinamicamente a novas informações e mudanças no escopo da pesquisa

são cruciais para manter a relevância e a precisão das revisões.

O estudo realizado por FAROOQ (2023) introduz uma metodologia avançada para o desenvolvimento de software, focada na implementação de técnicas de Desenvolvimento Orientado por Comportamento. Essa metodologia visa aprimorar a colaboração entre os membros da equipe de desenvolvimento e os *stakeholders*, facilitando um entendimento compartilhado dos requisitos do sistema através da utilização de linguagem natural e cenários de teste preditivos. Embora o foco principal do trabalho seja a otimização do processo de desenvolvimento de software, suas implicações para o processo automatizado de levantamento de literatura, especialmente aqueles apoiados por inteligência artificial generativa, são significativas e merecem uma análise detalhada. No contexto do levantamento automatizado de literatura, a abordagem de BDD pode ser adaptada para desenvolver sistemas de IA que se alinham mais estreitamente com as necessidades dos pesquisadores. Especificamente, ao definir cenários de comportamento que descrevem as etapas desejadas e os resultados esperados do processo de revisão de literatura, os desenvolvedores podem criar algoritmos de IA que executam tarefas específicas de maneira mais eficiente, como a identificação de artigos relevantes, a extração de dados e a síntese de informações. Uma das contribuições mais valiosas do trabalho para o levantamento de literatura é a ênfase na clareza e na precisão da comunicação entre os envolvidos no desenvolvimento dos algoritmos de IA. Isso é especialmente importante quando se considera a complexidade e a diversidade dos dados bibliográficos. A utilização de linguagem natural e cenários bem definidos pode ajudar a garantir que os algoritmos de IA sejam desenvolvidos com um entendimento claro dos objetivos de pesquisa e das expectativas de análise, resultando em sistemas de levantamento de literatura mais alinhados com as necessidades acadêmicas. Além disso, a abordagem de BDD enfatiza a importância dos testes contínuos, o que é diretamente aplicável ao desenvolvimento de sistemas automatizados de levantamento de literatura. Ao implementar testes automatizados que verificam continuamente a precisão e a relevância dos resultados gerados pela IA, é possível manter a integridade e a confiabilidade do processo de revisão de literatura ao longo do tempo. Essa metodologia assegura que o sistema permaneça atualizado com as últimas publicações e tendências de pesquisa, adaptando-se dinamicamente às mudanças

nas bases de dados bibliográficas. Por fim, o estudo ilustra a potencialidade de métodos ágeis e colaborativos no aprimoramento de processos complexos, como o levantamento de literatura científica. A incorporação de técnicas de BDD no desenvolvimento de sistemas de IA para revisão de literatura pode não apenas melhorar a eficácia desses sistemas, mas também facilitar uma colaboração mais efetiva entre desenvolvedores de IA, bibliotecários e pesquisadores, garantindo que as ferramentas desenvolvidas atendam eficientemente às demandas do ambiente acadêmico e de pesquisa.

O estudo conduzido por IMRAN (2023) aborda a aplicação de técnicas de mineração de processos para aprimorar auditorias de processos, uma abordagem que extrai conhecimento de registros de eventos para descobrir, monitorar e melhorar processos reais. Embora o foco principal do artigo seja a melhoria de auditorias de processos, os conceitos e metodologias apresentados podem ser adaptados para o levantamento de literatura apoiado por inteligência artificial generativa. A mineração de processos, como abordada por Imran e colaboradores, envolve a análise de dados de eventos para reconstruir e otimizar processos existentes. No contexto do levantamento de literatura, essa técnica pode ser aplicada para analisar padrões e tendências em dados bibliográficos, facilitando a identificação de áreas de pesquisa emergentes, lacunas de conhecimento e relações entre diferentes estudos. A aplicação de algoritmos de mineração de processos pode automatizar a extração e síntese de informações relevantes a partir de vastas bases de dados bibliográficas, tornando o processo de revisão bibliográfica mais eficiente e preciso. Além disso, a pesquisa destaca a importância da visualização de processos para a compreensão e otimização de fluxos de trabalho. No levantamento de literatura, a visualização de padrões de publicação, citações e colaborações pode oferecer *insights* valiosos sobre a estrutura e a evolução de campos de pesquisa específicos. Ferramentas de visualização baseadas em mineração de processos podem auxiliar pesquisadores na identificação de tendências e na formulação de estratégias de pesquisa mais informadas. A abordagem também enfatiza a necessidade de monitoramento contínuo e adaptação de processos para manter sua eficácia. Da mesma forma, no levantamento de literatura, é significativo monitorar continuamente o desenvolvimento do conhecimento científico e adaptar as estratégias de busca e análise à medida que novas informações se tornam disponíveis. A integração de

técnicas de mineração de processos em sistemas de levantamento de literatura pode facilitar esse monitoramento e adaptação contínuos, garantindo que as revisões bibliográficas permaneçam atualizadas e relevantes.

A busca por métodos eficientes de revisão da literatura é importante para a produção de conhecimento científico de qualidade. Nesse contexto, os estudos sobre *Rapid Reviews*, presentes no artigo Marshall (2019), têm ganhado destaque por sua proposta de acelerar o processo de síntese de evidências. Por outro lado, a inteligência artificial generativa tem se mostrado uma ferramenta promissora para automatizar e aprimorar o levantamento de literatura. Assim, há uma relação entre o estudo e um processo automatizado para levantamento de literatura apoiado por inteligência artificial generativa. Os *Rapid Reviews* são uma abordagem que visa acelerar o processo de revisão da literatura, mantendo a qualidade e a confiabilidade das análises. No estudo analisado, foram simulados diferentes métodos de revisão rápida e observados os impactos dessas abordagens nas meta-análises de revisões sistemáticas. Os resultados apontaram variações significativas nos resultados das análises, com mudanças nos *odds ratios* e na significância estatística. Esses achados destacam a importância de avaliar cuidadosamente os métodos de revisão rápida, considerando os possíveis impactos na interpretação dos resultados e na tomada de decisões baseadas em evidências. A eficiência na síntese de evidências é um aspecto importante para a produção científica, e os *rapid reviews* representam uma tentativa de otimizar esse processo. Por outro lado, a inteligência artificial generativa tem revolucionado a forma como lida-se com grandes volumes de informações. Essa tecnologia utiliza algoritmos avançados para gerar conteúdo novo e relevante, o que pode ser aplicado no contexto do levantamento de literatura. Um processo automatizado apoiado por inteligência artificial generativa pode agilizar a identificação de estudos relevantes, a extração de dados e a análise de informações. A utilização de inteligência artificial generativa no levantamento de literatura pode contribuir significativamente para a eficiência e a precisão das revisões sistemáticas. Ao automatizar tarefas repetitivas e demoradas, essa abordagem permite que os pesquisadores foquem em aspectos mais analíticos e interpretativos do processo de revisão. A relação entre o estudo e o tema abordado nesse trabalho reside na busca pela eficiência e qualidade na produção de conhecimento científico. Enquanto

os *Rapid Reviews* buscam acelerar a síntese de evidências, a inteligência artificial generativa oferece ferramentas poderosas para automatizar e aprimorar o processo de revisão da literatura. Integrar os princípios dos *Rapid Reviews* com as capacidades da inteligência artificial generativa pode representar um avanço significativo na forma como se conduz pesquisas e se produz evidências científicas. A combinação dessas abordagens pode resultar em processos mais ágeis, precisos e confiáveis, contribuindo para o avanço da ciência e da prática baseada em evidências.

A automação de revisões sistemáticas de literatura tem se mostrado uma área de pesquisa em constante evolução, buscando otimizar e agilizar o processo de identificação, extração e análise de dados em estudos acadêmicos. Neste contexto, a utilização de técnicas de Inteligência Artificial (IA), como a Inteligência Artificial Generativa, tem se destacado como uma ferramenta promissora para a automatização de tarefas complexas, como o levantamento de literatura. Este artigo Dinter (2021) explora a relação entre a automação de revisões sistemáticas e um processo automatizado de levantamento de literatura apoiado por IA generativa, destacando os benefícios e desafios dessa abordagem inovadora. As revisões sistemáticas de literatura desempenham um papel significativo na síntese e análise de conhecimento em diversas áreas acadêmicas. No entanto, o processo manual de condução dessas revisões pode ser demorado, custoso e suscetível a erros humanos. Com o avanço da tecnologia, a aplicação de técnicas de IA, como o Processamento de Linguagem Natural e o Aprendizado de Máquina, tem revolucionado a forma como as revisões sistemáticas são realizadas. Nesse contexto, a IA generativa surge como uma abordagem inovadora para automatizar o levantamento de literatura, permitindo a geração de conteúdo de forma autônoma e criativa. A automação de revisões sistemáticas por meio de IA generativa envolve a utilização de algoritmos avançados capazes de analisar grandes volumes de dados textuais, identificar padrões e gerar novas informações de maneira inteligente. Essa abordagem permite acelerar o processo de busca e seleção de artigos relevantes, bem como a extração e síntese de dados, tornando as revisões sistemáticas mais eficientes e precisas. Além disso, a IA generativa pode auxiliar na identificação de lacunas na literatura e na geração de *insights* inovadores, contribuindo para o avanço do conhecimento em determinada área de estudo. Os benefícios da integração da IA genera-

tiva em processos automatizados de levantamento de literatura são inúmeros, incluindo a redução do tempo e dos custos envolvidos, a melhoria da qualidade e da precisão dos resultados, e a possibilidade de explorar grandes volumes de dados de forma mais eficiente. No entanto, alguns desafios também são enfrentados, como a necessidade de garantir a ética e a transparência no uso de algoritmos de IA, a validação dos resultados gerados e a adaptação contínua das técnicas às necessidades específicas de cada área de pesquisa. Em suma, a relação entre a automação de revisões sistemáticas e um processo automatizado de levantamento de literatura apoiado por IA generativa representa uma oportunidade única para aprimorar a forma como o conhecimento é produzido e disseminado na comunidade acadêmica. A integração de técnicas avançadas de IA nesses processos pode impulsionar a inovação, a eficiência e a qualidade das pesquisas realizadas, contribuindo para avanços significativos em diversas áreas do conhecimento.

A inteligência artificial generativa tem se destacado como uma ferramenta poderosa para automatizar e aprimorar o processo de levantamento de literatura. Neste artigo Wagner, Lukyanenko e Paré (2022), é explorada a relação entre a utilização da inteligência artificial generativa e a condução de revisões de literatura de forma automatizada. Discute-se como essa tecnologia inovadora pode acelerar a busca por informações relevantes, identificar padrões e tendências emergentes, e gerar *insights* valiosos para os pesquisadores. Ao analisar o artigo, destaca-se a importância da integração da IA generativa nesse contexto e seu potencial para transformar a maneira como as revisões de literatura são realizadas. O avanço da inteligência artificial generativa tem revolucionado a forma como os pesquisadores conduzem suas revisões de literatura. Essa tecnologia inovadora permite a criação de conteúdo novo e relevante com base em padrões identificados em conjuntos de dados existentes, oferecendo percepções valiosas e acelerando o processo de busca por informações relevantes. Neste contexto, é necessário avaliar como a IA generativa pode otimizar as etapas do levantamento de literatura, proporcionando uma abordagem automatizada e eficiente para a análise e interpretação de grandes volumes de documentos. No artigo, os autores ressaltam a importância da avaliação e validação dos métodos de IA aplicados às revisões de literatura, destacando a necessidade de pesquisas metodológicas e de um debate crítico na comunidade acadêmica. A IA generativa oferece

a capacidade de criar novos conteúdos com base em padrões identificados em conjuntos de dados existentes, o que pode ser extremamente útil na busca e seleção de informações relevantes para uma revisão de literatura. A integração de ferramentas de IA generativa no processo de levantamento de literatura promete tornar as revisões mais eficientes, abrangentes e inovadoras, proporcionando uma abordagem automatizada e inteligente para a análise de grandes volumes de documentos. Por fim, a inteligência artificial generativa representa uma revolução no processo de levantamento de literatura, oferecendo aos pesquisadores uma abordagem automatizada e eficiente para a análise e interpretação de informações. Portanto, é significativo explorar e desenvolver estratégias que aproveitem todo o potencial da IA generativa para aprimorar o processo de levantamento de literatura e promover a inovação científica em diversas áreas do conhecimento.

3.4 Conclusões do capítulo

Neste capítulo, foi detalhado a aplicação do mapeamento sistemático da literatura, explicando a metodologia utilizada, incluindo o framework PICOC (População, Intervenção, Comparação, Desfecho e Contexto), que auxilia na formulação de questões de pesquisa e na definição de critérios de inclusão e exclusão dos estudos. Através dessa abordagem, foi possível identificar, avaliar e sintetizar as evidências disponíveis, destacando as principais descobertas, tendências e lacunas na literatura existente.

A estrutura sistemática proporcionada pelo PICOC garantiu uma revisão de literatura robusta e precisa, importante para fundamentar a pesquisa e orientar futuras investigações. A combinação de métodos tradicionais com técnicas avançadas, como a inteligência artificial generativa, demonstrou ser eficaz na ampliação do escopo de pesquisa e na melhoria da qualidade dos resultados obtidos. Pode-se concluir que a metodologia adotada não só fortalece a relevância da pesquisa, mas também contribui significativamente para o avanço do conhecimento na área estudada.

4 Materiais e Métodos

O presente estudo visa desenvolver um processo automatizado para levantamento da literatura, utilizando um modelo de linguagem (*Large Language Models* - LLM) integrada a diversas ferramentas de produtividade através de uma plataforma de integração. A importância desse processo reside na necessidade crescente de otimização do tempo e dos recursos empregados na pesquisa acadêmica. A automação das etapas de geração de palavras-chave, pesquisa de artigos e sumarização de conteúdo pode significativamente acelerar o progresso de estudos e aumentar a precisão das informações coletadas.

O objetivo principal deste trabalho é criar um processo automatizado, que permita aos pesquisadores inserir uma questão de pesquisa, que então será processada por uma LLM para gerar palavras-chave e sinônimos relevantes. Essas palavras-chave serão utilizadas para aprimorar as buscas em bases de dados acadêmicas, potencializando a recuperação de artigos científicos pertinentes. Após a busca e a coleta dos artigos, o sistema facilitará a interação entre o pesquisador e a ferramenta de automação para a obtenção de resumos e respostas para conseguirem filtrar os artigos, que serão posteriormente consolidados em um documento. Além disso, será utilizado um módulo para o fichamento e a avaliação dos artigos coletados, garantindo que cada artigo seja devidamente identificado, resumido e avaliado com base em critérios estabelecidos de originalidade, relevância, metodologia, qualidade dos dados, clareza, coerência e revisão de literatura. Esse processo auxiliará na sistematização e na análise crítica dos artigos, proporcionando uma base sólida para o desenvolvimento da pesquisa.

A Figura 4.1 apresenta o fluxo de etapas essenciais para a implementação de um processo automatizado de levantamento de literatura. Cada passo define uma ferramenta crítica para a automação e otimização do trabalho acadêmico. Inicialmente, é necessário definir a ferramenta de automação, que será responsável por integrar e orquestrar as demais aplicações. Em seguida, escolhe-se a ferramenta de LLM (*Large Language Model*), que fornecerá a capacidade de processamento e análise de linguagem natural. A próxima etapa envolve a definição da ferramenta de análise de texto, que permitirá a extração e

a síntese de informações relevantes dos documentos. Posteriormente, define a seleção da ferramenta de fichamento, para organizar e gerenciar as referências bibliográficas. Adicionalmente, é importante definir a ferramenta de geração de gráficos, que será utilizada para visualizar o número de publicações por ano, proporcionando uma visão temporal do volume de produção científica sobre o tema. Esta ferramenta é importante para identificar tendências e padrões ao longo do tempo. A ferramenta de geração de mapa de palavras é outro elemento vital, pois possibilita a identificação dos autores mais proeminentes no assunto estudado, facilitando a compreensão das principais contribuições e influências no campo de pesquisa. A ferramenta de editoração de texto facilitará a consolidação e a apresentação final dos resultados. Esse fluxo estruturado assegura um processo coeso e eficiente, desde a coleta de dados até a produção de relatórios e artigos científicos.



Figura 4.1: Fluxograma das etapas a serem seguidas.

Essa metodologia visa não apenas otimizar o processo de levantamento de literatura, mas também garantir que os pesquisadores possam concentrar seus esforços na análise crítica dos dados coletados, ao invés de dedicarem tempo excessivo a tarefas mecânicas e repetitivas. A integração entre ferramentas de LLM, e as demais ferramentas escolhidas proporcionará uma automação eficiente e personalizada, adaptando-se às necessidades específicas de cada projeto de pesquisa.

Em resumo, a introdução de um processo automatizado para levantamento da literatura representa um avanço significativo na forma como os pesquisadores conduzem suas investigações. Ao implementar um fluxo de trabalho mais ágil e automatizado, espera-se não apenas reduzir o tempo de pesquisa, mas também melhorar a qualidade e a relevância das informações coletadas. Este estudo pretende demonstrar a viabilidade e os benefícios desse processo, contribuindo para a inovação nas metodologias de pesquisa acadêmica.

4.1 Ferramentas discutidas

A discussão de ferramentas na criação de um processo é um passo importante para garantir a eficácia e eficiência da automação desejada. Essa etapa envolve a avaliação detalhada das funcionalidades, compatibilidades e limitações de diferentes ferramentas disponíveis. Durante esta análise, considera-se a facilidade de integração, a curva de aprendizado, a robustez das funcionalidades oferecidas e o suporte disponível para cada ferramenta. As ferramentas que foram analisadas foram encontradas por meio de uma pesquisa *ad hoc* (SANTOS, 2023), permitindo uma seleção direcionada e precisa. A escolha das ferramentas certas deve alinhar-se aos objetivos específicos do processo e às necessidades dos usuários, garantindo que as soluções adotadas não apenas atendam aos requisitos técnicos, mas também proporcionem uma experiência de uso intuitiva e eficiente. Além disso, é importante considerar a escalabilidade das ferramentas escolhidas para assegurar que possam acompanhar o crescimento e a evolução das demandas do projeto ao longo do tempo. Por fim, a segurança e a conformidade com as regulamentações aplicáveis são aspectos cruciais que devem ser rigorosamente avaliados para garantir a proteção dos dados e a integridade do processo automatizado.

4.1.1 Análise de ferramentas

Para a análise das ferramentas utilizadas neste estudo, foi adotado a escala Likert (JOSHI et al., 2015) como método de avaliação. Essa escolha se deve à capacidade da escala de captar a percepção dos objetos de estudo de forma estruturada, permitindo mensurar suas avaliações e experiências de maneira objetiva e quantitativa.

A escala Likert foi utilizada para medir o grau de concordância dos respondentes com afirmações relacionadas às funcionalidades, eficiência, facilidade de uso e outros aspectos relevantes das ferramentas analisadas. Com base em uma escala de cinco pontos, variando de “muito bom” a “muito fraco”, será possível obter uma visão detalhada das preferências e avaliações dos usuários, facilitando a interpretação dos dados e contribuindo para a identificação de padrões e tendências nas respostas. Os critérios da escala são: Muito bom, Bom, Neutro, Fraco e Muito fraco.

No entanto, é importante destacar que os critérios específicos para a aplicação

desta escala Likert não foram encontrados de forma completa em uma única fonte da literatura. Para garantir a consistência e relevância dos critérios adotados, foi realizada uma análise de diversas literaturas que abordam o uso da escala Likert em diferentes contextos de pesquisa. A partir dessa análise, foram definidos os critérios mais adequados para a avaliação das ferramentas, considerando fatores como facilidade de uso, funcionalidade, desempenho e satisfação do usuário.

Essa abordagem garantiu uma fundamentação teórica sólida, assegurando que os critérios estabelecidos reflitam com precisão as dimensões essenciais para a análise das ferramentas em questão. A utilização da escala Likert proporciona uma base quantitativa consistente, permitindo identificar com clareza as percepções e preferências dos participantes.

Em conclusão, a utilização da escala Likert neste estudo proporciona uma avaliação quantitativa robusta das ferramentas analisadas, permitindo uma compreensão detalhada de suas funcionalidades e desempenho. A definição dos critérios a partir de múltiplas fontes bibliográficas assegura a relevância e precisão das métricas aplicadas. Dessa forma, a abordagem adotada facilita a identificação de padrões e tendências nas percepções dos usuários. Assim, a análise realizada se fundamenta em uma base teórica sólida, fortalecendo a confiabilidade dos resultados obtidos.

4.1.2 Ferramenta de automação

Uma ferramenta de automação é um software projetado para executar tarefas repetitivas de maneira independente, sem a necessidade de intervenção constante de um usuário. No contexto da revisão da literatura, sua importância é evidente, pois permite que os pesquisadores acelerem significativamente a coleta e a organização de dados bibliográficos. Automatizando processos como a busca de artigos, a formatação de referências e a organização de notas, a ferramenta de automação não apenas economiza tempo, mas também reduz a possibilidade de erros humanos, garantindo maior precisão e consistência. Além disso, facilita a atualização contínua das revisões com novas informações, mantendo a pesquisa sempre atualizada e relevante. A integração de diversas ferramentas proporciona uma gestão mais eficiente e colaborativa do processo de revisão.

Para o desenvolvimento de um processo automatizado de levantamento da literatura, foram consideradas diversas ferramentas de automação e integração. Entre as opções avaliadas, destacam-se Mendeley (2008), Integromat (2018) (atualmente conhecido como *Make*), MicrosoftPowerAutomate (2019), Zapier (2011) e Rayyan (2016). Cada uma dessas ferramentas possui características distintas que foram analisadas com base em critérios específicos de facilidade de uso, número de integrações disponíveis e flexibilidade.

O Mendeley é uma ferramenta para a gestão de referências e colaboração acadêmica, oferecendo funcionalidades robustas para organização e compartilhamento de pesquisas. No entanto, sua capacidade de integração automática com outras ferramentas externas é limitada, o que restringe seu uso em processos de automação mais complexos.

O Integromat (*Make*) é uma ferramenta de automação robusta que permite a criação de fluxos de trabalho complexos e personalizados, destacando-se por sua flexibilidade e vasta gama de integrações. No entanto, sua interface pode ser complexa e menos intuitiva, representando um desafio significativo para usuários com pouca ou nenhuma experiência em programação. Enquanto oferece recursos avançados e grande versatilidade, a curva de aprendizado íngreme pode limitar sua acessibilidade e usabilidade para novatos.

O Microsoft Power Automate (MS.P.A) é bem integrado ao ecossistema Microsoft, oferecendo funcionalidades robustas para automação dentro deste ambiente. No entanto, apresenta uma curva de aprendizado mais íngreme, o que pode dificultar sua adoção por usuários menos experientes. Além disso, seu suporte direto para integrações com aplicações fora do ambiente Microsoft é limitado, o que pode restringir sua eficácia na automação de processos que envolvem uma diversidade maior de ferramentas.

O Zapier é uma ferramenta de automação reconhecida por sua interface intuitiva e amigável, permitindo que usuários criem automações (*zaps*) com facilidade, mesmo sem experiência em programação. Oferece uma vasta gama de integrações, suportando mais de 3.000 aplicativos, incluindo Google Sheets, Google Docs e serviços de processamento de linguagem natural como o ChatGPT. Sua flexibilidade permite a automação eficiente de diversos processos, tornando-o ideal para otimizar o tempo e os recursos na pesquisa acadêmica.

O Rayyan é uma ferramenta para revisões sistemáticas e triagem de literatura,

oferecendo uma interface intuitiva e colaborativa que facilita a organização e categorização de artigos, especialmente em projetos com grandes volumes de dados. Embora sua integração com outras ferramentas seja limitada, dificultando a automação completa, o Rayyan se destaca na otimização do processo de triagem, sendo acessível para a maioria dos usuários e altamente eficaz para equipes de revisores.

Dessa forma, alguns aspectos foram definidos para a escolha da plataforma utilizada. Na escolha de uma ferramenta, é necessário considerar vários critérios para garantir a eficácia e a eficiência do processo. Primeiramente, a facilidade de uso é importante, pois a ferramenta deve ser intuitiva e acessível, permitindo que os usuários a operem sem necessidade de treinamento extensivo (DAVIS, 1989). A capacidade de integração é igualmente importante, pois a ferramenta deve se comunicar de forma eficaz com outras plataformas e sistemas utilizados no processo, como bases de dados acadêmicas, ferramentas de processamento de linguagem natural e software de gerenciamento de referências (VENKATESH et al., 2003). A curva de aprendizado associada à ferramenta é outro critério significativo, uma curva de aprendizado íngreme pode atrasar a implementação do processo automatizado e reduzir a produtividade inicial (AGARWAL; PRASAD, 1999). Além disso, a robustez das funcionalidades oferecidas pela ferramenta é vital para assegurar que ela possa lidar com as várias etapas do levantamento de literatura, desde a geração de palavras-chave até a consolidação e análise dos artigos coletados (PETTER; DELONE; MCLEAN, 2008). A escalabilidade da ferramenta também deve ser considerada, garantindo que ela possa crescer e se adaptar às necessidades futuras do projeto, acompanhando o aumento do volume de dados e a complexidade das tarefas (GILL et al., 2014). A segurança e a conformidade com as regulamentações aplicáveis são aspectos imprescindíveis, pois é necessário garantir a proteção dos dados sensíveis e a integridade do processo automatizado (SOLMS; NIEKERK, 2013). Por fim, o suporte técnico disponível para a ferramenta deve ser avaliado, já que um bom suporte pode resolver problemas rapidamente e minimizar o tempo de inatividade, garantindo a continuidade e a eficiência do processo (THONG, 1999). Esses critérios foram considerados para assegurar que a ferramenta escolhida apresente um bom desempenho. Os resultados podem ser evidenciados na Tabela 4.1. A análise desses fatores possibilitou a seleção de uma ferramenta que não apenas atende

às necessidades atuais do projeto, mas também possui potencial de adaptação futura. A escolha fundamentada em critérios técnicos sólidos garante a eficiência e a longevidade da solução implementada.

Tabela 4.1: Análise das ferramentas de automação.

Critério	Zapier	Mendeley	Integromat	MS.P.A	Rayyan
Facilidade de Uso	Muito bom	Neutro	Fraco	Neutro	Muito bom
Integrações	Muito bom	Fraco	Bom	Bom	Fraco
Curva aprendizado	Muito bom	Neutro	Fraco	Fraco	Muito bom
Funcionalidades	Muito bom	Fraco	Bom	Bom	Fraco
Escalabilidade	Muito bom	Ruim	Muito bom	Muito bom	Fraco
Segurança	Muito bom	Bom	Bom	Muito bom	Muito bom
Suporte técnico	Muito bom	Fraco	Bom	Bom	Fraco
Integração LLM	Muito bom	Bom	Muito bom	Bom	Fraco

Após essa análise, optou-se pelo Zapier para o processo de automação da revisão de literatura. O Zapier é reconhecido por possuir interface intuitiva e amigável, assim como representado na Figura 4.2, que facilita a criação de automações (*zaps*). Essa escolha foi fundamentada na capacidade do Zapier de integrar uma ampla variedade de aplicações, proporcionando uma solução flexível e robusta que pode ser adaptada às necessidades específicas de diferentes projetos de pesquisa. Além disso, a plataforma oferece suporte e documentação, o que contribui para uma implementação mais rápida e eficiente das automações necessárias.

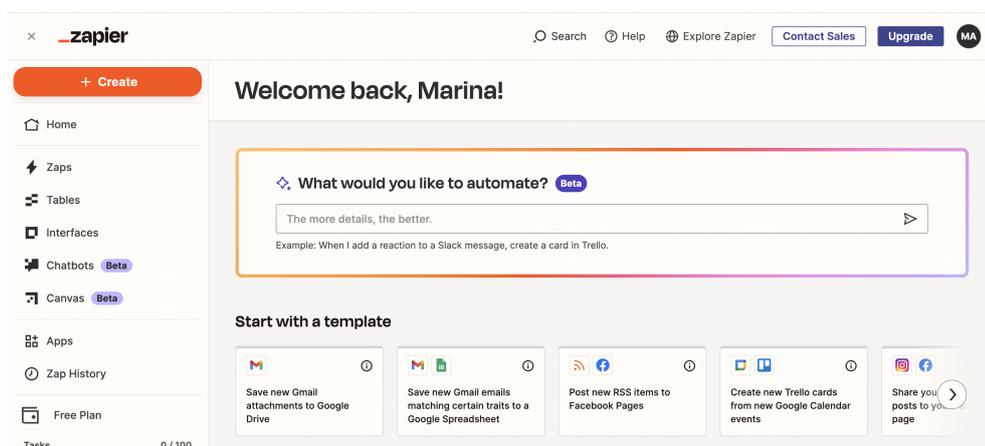


Figura 4.2: Interface do Zapier.

Além disso, o Zapier oferece uma vasta gama de integrações com mais de 3.000 aplicativos, incluindo ferramentas de planilhas, texto e diversos serviços de processamento

de linguagem natural, assim como é mostrado na Figura 4.3.

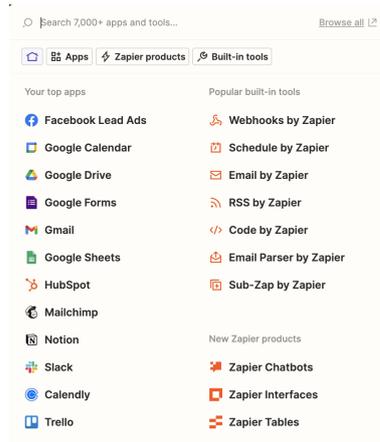


Figura 4.3: Aplicações que interagem com o Zapier.

O Zapier é uma plataforma de automação que permite a integração e a coordenação de diversas aplicações e serviços web, facilitando a realização de tarefas repetitivas sem a necessidade de intervenção manual. Os principais elementos do Zapier são os *zaps*, que são fluxos de trabalho automatizados configurados pelos usuários para conectar diferentes aplicativos. Cada *zap* é composto por um *trigger* (gatilho) que inicia o fluxo de trabalho e uma ou mais *actions* (ações) que são executadas em resposta ao gatilho. Por exemplo, um *zap* pode ser configurado para monitorar a atualização de uma célula específica de uma planilha (*trigger*) e, quando essa atualização ocorre, enviar os dados para uma LLM para processamento e retornar os resultados em um documento (*actions*). Essa flexibilidade e capacidade de integração tornam o Zapier uma ferramenta poderosa para automatizar processos complexos, melhorando a eficiência e reduzindo a possibilidade de erros humanos.

Em resumo, a escolha do Zapier é justificada por sua facilidade de uso, ampla compatibilidade com diversas plataformas e eficiência na criação de fluxos de trabalho automatizados, fatores essenciais para a realização de uma revisão de literatura automatizada eficiente e precisa.

4.1.3 Ferramenta de LLM

Para o processo de automação de resumos de literatura, consideramos diversas LLMs (*Large Language Models*) de destaque no mercado. Entre as opções avaliadas, destacam-

se ChatGPT (2022), Gemini (2023), LLaMa (2023), Claude (2023), Consensus (2022), Perplexity (2022) e SciSpace (2014). Cada uma dessas ferramentas possui características distintas que foram analisadas com base em critérios específicos, como facilidade de uso, precisão, treinamento, escalabilidade, velocidade, flexibilidade, segurança, suporte, compatibilidade, capacidade de contexto, personalização e frequência de atualização.

O ChatGPT, desenvolvido pela OpenAI, é amplamente reconhecido por sua capacidade avançada de processamento de linguagem natural, precisão e coerência na geração de texto. É robusto em lidar com uma ampla gama de tópicos e estilos de escrita, demonstrando desempenho consistente e confiável em tarefas complexas de compreensão e síntese de texto. Além disso, possui uma comunidade de desenvolvedores ativa e extensa documentação de suporte, facilitando a integração com ferramentas de automação como o Zapier. O ChatGPT é frequentemente atualizado com melhorias baseadas em *feedback* e avanços tecnológicos, garantindo que os usuários tenham acesso contínuo às últimas capacidades de IA. Sua integração via API é bem documentada e suportada, permitindo uma implementação relativamente simples e eficaz com outras plataformas.

O Gemini, desenvolvido pelo Google, também é um LLM poderoso. No entanto, seu acesso e integração podem ser mais restritos e menos amigáveis para usuários que necessitam de configurações rápidas e eficientes. Embora ofereça alta precisão e uma gama extensiva de treinamentos, a flexibilidade e a facilidade de uso podem ser pontos de limitação em comparação com o ChatGPT.

O LLaMA, desenvolvido pela Meta, oferece capacidades importantes, mas ainda está em estágios de desenvolvimento onde a maturidade e a estabilidade necessárias para aplicações críticas podem não estar plenamente disponíveis. A capacidade de contexto e a compatibilidade do LLaMA são moderadas, o que pode limitar sua eficácia em alguns cenários de automação.

O Claude, desenvolvido pela Anthropic, é uma LLM inovadora. No entanto, seu acesso pode ser mais restrito e menos amigável para usuários que buscam configurações rápidas e intuitivas. Embora Claude ofereça alta precisão e seja treinado em uma vasta quantidade de dados, a flexibilidade e a facilidade de uso podem ser pontos de limitação em comparação com o ChatGPT. Essas características podem fazer com que Claude seja

mais adequado para contextos específicos onde a precisão técnica é prioritária, mas menos ideal para usuários que necessitam de uma interface mais acessível e amigável.

O Consensus é uma ferramenta para consultas científicas, construída sobre uma base robusta de processamento de linguagem natural. Destaca-se por sua capacidade de fornecer respostas baseadas em evidências diretamente a partir de artigos revisados por pares, oferecendo precisão e relevância nas informações apresentadas. Apesar de ser uma ferramenta poderosa para a síntese de conhecimento científico, o Consensus ainda apresenta limitações na integração com outras plataformas de automação, o que pode restringir seu uso em fluxos de trabalho mais complexos. No entanto, para usuários que buscam respostas precisas e contextualizadas no campo acadêmico, o Consensus é uma solução valiosa, especialmente para consultas rápidas e específicas.

O Perplexity é uma ferramenta de pesquisa baseada em LLMs que se destaca pela precisão e profundidade das respostas geradas. Oferece uma interface intuitiva e amigável, que facilita a exploração de informações complexas e a obtenção de *insights* detalhados. No entanto, apesar de sua eficácia na geração de respostas contextualizadas, o Perplexity pode enfrentar desafios em termos de integração com outras ferramentas de automação, o que limita seu uso em processos que exigem uma maior conectividade entre plataformas. Ainda assim, o Perplexity é uma boa escolha para usuários que necessitam de respostas rápidas e precisas em uma ampla gama de tópicos.

O SciSpace, anteriormente conhecido como Typeset, é uma ferramenta poderosa que combina funcionalidades de automação com capacidades de processamento de linguagem natural para auxiliar pesquisadores na exploração e compreensão de literatura científica. Oferece uma vasta gama de recursos para anotar, organizar e compreender artigos, tornando-o um assistente valioso no trabalho acadêmico. No entanto, embora ofereça uma excelente integração com LLMs e seja ideal para análise detalhada de textos científicos, sua interface e facilidade de uso podem não ser tão intuitivas quanto outras opções disponíveis, o que pode representar um desafio para usuários que buscam uma experiência mais direta e acessível. Mesmo assim, o SciSpace é altamente eficaz para quem precisa de uma solução avançada e integrada para gestão de pesquisas.

Na escolha de uma ferramenta de LLM (*Large Language Model*) para um processo

automatizado de levantamento da literatura, diversos critérios são cruciais para garantir a eficácia e a precisão do processo. A facilidade de uso é um fator importante, pois a ferramenta deve ser intuitiva e acessível para pesquisadores que podem não ter experiência técnica avançada (DEVLIN et al., 2018). A precisão do modelo é igualmente importante, pois determina a qualidade das palavras-chave geradas e a relevância dos artigos encontrados, assegurando que os resultados da pesquisa sejam válidos e úteis (BROWN et al., 2020). A flexibilidade da ferramenta também é significativa, permitindo ajustes e personalizações para diferentes áreas de estudo e necessidades específicas dos pesquisadores, o que é vital para atender às diversas demandas do campo acadêmico (RAFFEL et al., 2020). A capacidade de integração do LLM com outras ferramentas de automação, como plataformas de gerenciamento de referências e bases de dados acadêmicas, é vital para criar um fluxo de trabalho coeso e eficiente, facilitando a transferência de dados e a coordenação entre diferentes sistemas (WOLF et al., 2020). A segurança é um critério imprescindível, garantindo que os dados sensíveis dos pesquisadores e as informações coletadas sejam protegidos contra acessos não autorizados, evitando violações de privacidade e mantendo a integridade dos dados (DEY; BHATT; ASHOUR, 2018). Esses critérios foram considerados para assegurar que a ferramenta de LLM escolhida não apenas atenda às necessidades técnicas do projeto, mas também proporcione uma experiência de uso eficiente e segura, maximizando a qualidade e a relevância dos resultados obtidos. Os critérios analisados para a escolha da LLM estão representados na Tabela 4.2.

Tabela 4.2: Análise das Ferramentas de LLMs.

Critérios	Facilidade	Precisão	Flexibilidade	Integração	Segurança
ChatGPT	Muito bom	Muito bom	Muito bom	Muito bom	Muito bom
Gemini	Neutro	Muito bom	Neutro	Fracó	Muito bom
LLaMA	Neutro	Muito bom	Neutro	Fracó	Muito bom
Claude	Neutro	Muito bom	Neutro	Neutro	Muito bom
Consensus	Muito bom	Muito bom	Neutro	Fracó	Muito bom
Perplexity	Muito bom	Muito bom	Muito bom	Fracó	Muito bom
SciSpace	Neutro	Muito bom	Neutro	Muito bom	Muito bom

A escolha do ChatGPT para o processo de automação de resumos de literatura, em detrimento dos outros LLMs, como Gemini e LLaMA, baseia-se em várias considerações detalhadas. Primeiramente, o ChatGPT é amplamente reconhecido por sua capacidade avançada de processamento de linguagem natural, precisão e coerência na

geração de texto, bem como sua robustez em lidar com uma ampla gama de tópicos e estilos de escrita. O ChatGPT tem demonstrado um desempenho consistente e confiável em tarefas complexas de compreensão e síntese de texto, tornando-o ideal para a elaboração de respostas detalhadas e informativas.

O ChatGPT é a ferramenta de inteligência artificial empregada para gerar palavras-chave, sinônimos e filtrar os artigos acadêmicos, através de perguntas geradas pelo usuário. Sua capacidade de processamento de linguagem natural permite que ele compreenda a questão de pesquisa inserida em uma ferramenta de planilha e produza uma lista de palavras-chave que aprimoram a *string* de busca. Esse passo é significativo, pois a qualidade das palavras-chave influencia diretamente a relevância e a abrangência dos artigos retornados nas buscas acadêmicas. Posteriormente, o ChatGPT é utilizado para analisar os títulos e resumos dos artigos coletados, através de perguntas geradas pelo usuário que ajudam os pesquisadores a rapidamente entenderem o conteúdo e a relevância dos artigos para o seu estudo.

Além disso, o ChatGPT possui uma comunidade de desenvolvedores ativa e extensa documentação de suporte, facilitando a integração com ferramentas de automação como o Zapier. Adicionalmente, o ChatGPT é frequentemente atualizado com melhorias baseadas em *feedback* e avanços tecnológicos, garantindo que os usuários tenham acesso contínuo às últimas capacidades de IA. Sua integração via API é bem documentada e suportada, permitindo uma implementação relativamente simples e eficaz com outras plataformas.

Em resumo, a escolha do ChatGPT é justificada por sua excelência técnica, facilidade de integração, confiabilidade e suporte, fatores essenciais para garantir uma automação eficiente e precisa na revisão de literatura acadêmica.

4.1.4 Ferramenta de análise de texto

Para o processo de automação de levantamento de literatura, diversas ferramentas de análise de texto amplamente utilizadas no mercado foram consideradas. Entre as opções avaliadas, destacam-se ChatGPT (2022), ChatPDF (2023) e AskYourPDF (2023). Cada uma dessas ferramentas possui características distintas que foram analisadas com base

em critérios específicos, como facilidade de uso, capacidades de análise textual, funcionalidades de anotação, integração com outras plataformas, custo, flexibilidade, segurança, suporte técnico e frequência de atualização, que serão analisadas a seguir.

O ChatGPT é uma ferramenta avançada de inteligência artificial desenvolvida pela OpenAI, que facilita a compreensão e análise de grandes volumes de texto. Pode ser utilizado para gerar resumos, responder a perguntas específicas e fornecer *insights* detalhados sobre o conteúdo de documentos. A capacidade do ChatGPT de interagir em linguagem natural torna a ferramenta extremamente acessível, permitindo que os usuários façam perguntas complexas e recebam respostas precisas. Sua flexibilidade e capacidade de personalização são pontos fortes, especialmente para pesquisadores que precisam de uma solução robusta e adaptável. Além disso, a forte comunidade de suporte e a frequência de atualizações garantem que a ferramenta permaneça atualizada e eficaz.

ChatPDF é uma ferramenta especializada em transformar documentos PDF em formatos interativos, permitindo a extração de informações e a realização de análises detalhadas. Oferece funcionalidades de anotação direta nos documentos e uma interface intuitiva que facilita a navegação e a marcação de trechos importantes. A integração com plataformas de armazenamento em nuvem e sua compatibilidade com diversos dispositivos tornam o ChatPDF uma opção conveniente para pesquisadores que trabalham com grandes volumes de documentos em PDF. Suas funcionalidades avançadas de busca e extração de dados permitem uma análise eficiente e precisa de textos acadêmicos.

AskYourPDF é uma ferramenta que permite a interação direta com documentos PDF, facilitando a busca e a extração de informações específicas. Através de uma interface simples e intuitiva, os usuários podem fazer perguntas sobre o conteúdo do PDF e obter respostas rápidas e precisas. Essa ferramenta é especialmente útil para pesquisas que envolvem a análise de grandes quantidades de documentos, pois permite uma navegação rápida e eficiente. A capacidade de AskMyPDF de lidar com múltiplos idiomas e sua integração com outras plataformas de análise de texto a tornam uma escolha versátil e poderosa.

Essas ferramentas foram analisadas com base em sua capacidade de atender às necessidades específicas dos pesquisadores, oferecendo soluções eficientes para a análise e

o gerenciamento de textos. A facilidade de uso é significativa, pois a ferramenta deve ser intuitiva para que os pesquisadores possam se concentrar na análise dos dados sem enfrentar uma curva de aprendizado íngreme (SHNEIDERMAN, 2021). As funcionalidades de anotação permitem uma interação direta com os documentos, facilitando a marcação de trechos importantes, adição de comentários e organização de ideias, o que é significativo para a análise detalhada dos textos (LUNSFORD; EDE, 2020). A integração com outras plataformas é vital para garantir que a ferramenta possa interagir de forma eficiente com outras soluções de software utilizadas pelos pesquisadores, poupando tempo e minimizando erros na entrada de dados (TENOPIR; KING, 2022). O suporte à colaboração é igualmente importante, pois permite que múltiplos pesquisadores trabalhem simultaneamente no mesmo projeto, promovendo a troca de informações e ideias de forma dinâmica (JOHNSON; MACDONALD, 2019). Finalmente, a capacidade de organização e exportação de análises é crucial para manter as informações estruturadas e facilitar a criação de relatórios e resumos em diferentes formatos, atendendo às diversas exigências de publicações acadêmicas (WHITE; MCCAIN, 2020). Esses critérios foram considerados para selecionar uma ferramenta de análise de texto que atendam às exigências técnicas do projeto, os critérios analisados para a escolha da ferramenta de análise de texto estão representados na Tabela 4.3.

Tabela 4.3: Análise das Ferramentas de Análise de Texto.

Critério	ChatGPT	ChatPDF	AskYourPDF
Facilidade de Uso	Muito bom	Muito bom	Muito bom
Anotações	Muito bom	Bom	Bom
Integração	Muito bom	Bom	Bom
Colaboração	Muito bom	Bom	Bom
Organização e Exportação	Muito bom	Bom	Bom

A escolha do ChatGPT como ferramenta de análise de texto para um processo automatizado de levantamento da literatura baseia-se em sua facilidade de uso, capacidades de análise textual, funcionalidades de anotação, integração com outras plataformas, suporte à colaboração e capacidade de organização e exportação de análises. O ChatGPT oferece uma interface intuitiva, permitindo que os usuários se concentrem na análise dos dados sem enfrentar dificuldades técnicas. Suas funcionalidades de anotação avançadas permitem uma interação direta com os documentos, facilitando a marcação de trechos

importantes, adição de comentários e organização de ideias, o que é significativo para uma análise detalhada e precisa dos textos.

A integração do ChatGPT com outras plataformas permite a importação automática de dados de diversas fontes, poupando tempo e minimizando erros na entrada de dados. Esse recurso é vital para manter uma coleção de informações atualizada e precisa. O suporte à colaboração do ChatGPT permite que múltiplos pesquisadores trabalhem simultaneamente no mesmo projeto, promovendo uma troca de informações eficiente e dinâmica. Essa característica é importante para projetos de pesquisa em grupo, onde a coordenação e a comunicação são cruciais para o sucesso.

Além disso, a capacidade de organização e exportação de análises do ChatGPT é robusta, permitindo a criação de relatórios e resumos em diferentes formatos, atendendo às diversas exigências de publicações acadêmicas. Essa funcionalidade facilita a manutenção de uma estrutura organizada das informações, o que é importante para a produção de trabalhos acadêmicos de alta qualidade.

Em resumo, a escolha do ChatGPT se justifica por suas características abrangentes e sua capacidade de integrar-se perfeitamente com outras ferramentas, proporcionando um fluxo de trabalho coeso, eficiente e automatizado. Esta combinação maximiza a qualidade e a precisão dos resultados obtidos, atendendo às necessidades técnicas e colaborativas dos projetos acadêmicos, facilitando o processo de levantamento de literatura de maneira eficiente e organizada.

4.1.5 Ferramenta de fichamento

Para o processo de automação de levantamento de literatura, diversas ferramentas de fichamento amplamente utilizadas no mercado foram consideradas. Entre as opções avaliadas, destacam-se Mendeley (2008), GoogleSheets (2006), Zotero (2006), EndNote (1988), OneNote (2003), ResearchRabbit (2021), ConnectPapers (2021), SemanticScholar (2015), Elicit (2021), oamg (2020) e RDiscovery (2021). Cada uma dessas ferramentas possui características distintas que foram analisadas com base em critérios específicos, como facilidade de uso, organização de referências, funcionalidades de anotação, integração com bases de dados acadêmicas, custo, flexibilidade, segurança, suporte técnico, com-

patibilidade com processadores de texto, capacidade de gerenciamento de bibliografias e frequência de atualização, como será descrito adiante.

O Mendeley é uma ferramenta gratuita de gestão de referências e automação que facilita a organização, o compartilhamento e a descoberta de pesquisas. Permite o armazenamento de PDFs e outros documentos, além de oferecer funcionalidades de anotação direta nos documentos e a organização de bibliotecas pessoais com *tags* e pastas. A integração nativa com diversas bases de dados acadêmicas e sua compatibilidade com aplicativos de terceiros tornam o processo de gerenciamento de referências mais fluido e eficiente. Adicionalmente, Mendeley automatiza diversas tarefas, como a formatação de citações e bibliografias, o que poupa tempo e minimiza erros. A facilidade de uso do Mendeley e sua forte comunidade de suporte são fatores que contribuem para sua popularidade entre pesquisadores.

O Google Sheets não é uma ferramenta especificamente destinada ao fichamento de dados, mas pode ser adaptada para esse propósito. Para pesquisas, sua integração com o Zapier permite automatizar processos, o que o torna uma opção viável. Por isso, foi analisado como uma alternativa eficiente para essa finalidade. O Google Sheets oferece uma plataforma flexível que permite a organização detalhada de informações essenciais, como títulos, autores, resumos e palavras-chave. Sua interface intuitiva facilita a categorização e manipulação de dados, tornando-o uma ferramenta prática para pesquisadores que buscam sistematizar informações de forma eficiente. Além disso, a funcionalidade de colaboração em tempo real do Google Sheets possibilita que vários membros de uma equipe de pesquisa trabalhem simultaneamente na mesma planilha, inserindo e atualizando dados de maneira contínua e sem risco de duplicação. A capacidade de automatizar tarefas repetitivas através de fórmulas e *scripts* também torna o Google Sheets uma opção interessante para aqueles que desejam otimizar o processo de fichamento. Com sua integração com outras ferramentas e a possibilidade de exportação em diversos formatos, o Google Sheets se revela uma solução acessível e eficiente para o gerenciamento e organização de informações acadêmicas.

Zotero, uma ferramenta gratuita e de código aberto, ajuda a coletar, organizar, citar e compartilhar pesquisas. Permite a captura automática de citações de páginas da

web, suporta uma variedade de formatos de arquivo e se integra bem com processadores de texto para a criação de bibliografias automáticas. A flexibilidade e capacidade de personalização do Zotero são pontos fortes, especialmente para usuários que precisam de uma solução robusta e adaptável. Além disso, o Zotero possui uma interface intuitiva que facilita a gestão de grandes volumes de referências.

EndNote é uma ferramenta comercial conhecida por suas funcionalidades avançadas e robustez. Permite a importação de referências de bases de dados *online*, a organização em grupos personalizados e a inserção automática de citações em documentos de texto. Embora ofereça uma ampla gama de funcionalidades, seu custo pode ser um fator limitante para alguns usuários, e a curva de aprendizado pode ser mais íngreme em comparação com Mendeley e Zotero. No entanto, EndNote é amplamente utilizado em instituições acadêmicas e de pesquisa devido à sua eficiência e capacidade de lidar com bibliografias extensas.

OneNote, uma ferramenta de anotações digitais da Microsoft, pode ser utilizada para fichamento, permitindo a organização de notas, referências e ideias em *notebooks*, seções e páginas. Sua integração com o ecossistema Microsoft e a capacidade de sincronização em tempo real, tornam o OneNote conveniente para muitos pesquisadores. Embora não seja uma ferramenta de gestão de referências tradicional, sua flexibilidade e facilidade de uso a tornam uma opção valiosa para organizar informações de pesquisa.

O Research Rabbit é uma ferramenta inovadora para a descoberta e organização de pesquisas, oferecendo aos pesquisadores uma maneira visual e intuitiva de explorar redes de artigos científicos relacionados. Permite a criação de coleções personalizadas de artigos, com atualizações em tempo real à medida que novos trabalhos relevantes são publicados. Além disso, o Research Rabbit facilita a colaboração ao permitir que os usuários compartilhem suas coleções e *insights* com outros pesquisadores. Embora suas integrações com outras ferramentas sejam limitadas, sua interface amigável e a capacidade de visualizar conexões entre trabalhos tornam-no uma ferramenta valiosa para quem busca uma maneira mais dinâmica de explorar a literatura científica.

O Connect Papers é uma ferramenta especializada que permite aos pesquisadores explorar visualmente as conexões entre artigos científicos relacionados. Cria mapas de

citações que facilitam a identificação de trabalhos relevantes em uma área de pesquisa específica, ajudando os usuários a entender a evolução de um tópico ao longo do tempo. A simplicidade da interface do Connect Papers o torna acessível, mesmo para usuários com pouca experiência em ferramentas de análise de citações. No entanto, sua funcionalidade é mais limitada em comparação com outras plataformas de gerenciamento de referências, sendo ideal como um complemento para pesquisadores que já utilizam outras ferramentas para organizar suas bibliotecas.

O Semantic Scholar é uma ferramenta gratuita que utiliza inteligência artificial para ajudar os pesquisadores a descobrir e organizar literatura acadêmica. Oferece funcionalidades avançadas de pesquisa, incluindo a capacidade de filtrar resultados por impacto, citações e relevância. Com sua interface intuitiva, o Semantic Scholar facilita a organização de bibliotecas pessoais e a rastreabilidade de tópicos de interesse ao longo do tempo. Além disso, a plataforma destaca os principais conceitos e referências de cada artigo, tornando o processo de revisão da literatura mais eficiente. Apesar de suas capacidades avançadas, a integração com outras ferramentas de automação pode ser limitada, mas sua eficácia na descoberta de artigos científicos é indiscutível.

O Elicit é uma ferramenta orientada por IA que auxilia na revisão de literatura científica, permitindo a extração automática de informações de artigos acadêmicos. Sua capacidade de formular perguntas específicas e obter respostas baseadas em evidências faz do Elicit uma escolha ideal para quem precisa organizar grandes volumes de literatura de maneira eficiente. A plataforma facilita o processo de triagem de artigos e a síntese de informações chave, embora sua integração com outras ferramentas de gerenciamento de referências e automação seja limitada. No entanto, para usuários que buscam uma maneira rápida e precisa de analisar literatura científica, o Elicit é uma ferramenta valiosa que complementa outras plataformas de pesquisa.

O OA.MG é uma plataforma de busca e descoberta de artigos acadêmicos de acesso aberto, oferecendo aos pesquisadores uma forma eficiente de acessar literatura científica sem barreiras de pagamento. A interface simplificada do OA.MG facilita a busca e organização de artigos, sendo uma excelente opção para pesquisadores que procuram maximizar o acesso a publicações científicas. Embora não ofereça funcionalidades avançadas

de automação ou integração com outras ferramentas, sua especialização em conteúdos de acesso aberto e a possibilidade de criar listas de leitura personalizadas fazem do OA.MG uma ferramenta útil para a descoberta e o fichamento de pesquisas.

O R Discovery é uma ferramenta que personaliza a descoberta de literatura científica, utilizando algoritmos de *machine learning* para recomendar artigos relevantes com base nas preferências e histórico de leitura do usuário. Com uma interface simples e foco em facilitar o acesso a artigos científicos, o R Discovery ajuda a manter os pesquisadores atualizados com as últimas publicações em suas áreas de interesse. Apesar de suas funcionalidades avançadas de recomendação, a integração com outras ferramentas de gerenciamento de referências pode ser limitada, mas o R Discovery se destaca como uma solução eficiente para a descoberta contínua de novos artigos científicos e a curadoria de conteúdos relevantes.

Essas ferramentas foram analisadas com base em sua capacidade de atender às necessidades específicas dos pesquisadores, oferecendo soluções eficientes para a organização e o gerenciamento de referências e anotações. A facilidade de uso é importante, pois a ferramenta deve ser intuitiva para que os pesquisadores possam se concentrar na análise dos dados sem enfrentar uma curva de aprendizado íngreme (SHNEIDERMAN, 2000). As funcionalidades de anotação permitem uma interação direta com os documentos, facilitando a marcação de trechos importantes, adição de comentários e organização de ideias, o que é significativo para a análise detalhada dos textos (LUNSFORD; EDE, 1990). A integração com bases de dados acadêmicas é vital para garantir que a ferramenta possa importar referências de forma automática e eficiente, poupando tempo e minimizando erros na entrada de dados (TENOPIR, 2003). O suporte à colaboração é igualmente importante, pois permite que múltiplos pesquisadores trabalhem simultaneamente no mesmo projeto, promovendo a troca de informações e ideias de forma dinâmica (JOHNSON; JOHNSON, 1991). Finalmente, a capacidade de organização e exportação de referências é aconselhável para manter as informações estruturadas e facilitar a criação de bibliografias e citações em diferentes formatos, atendendo às diversas exigências de publicações acadêmicas (WHITE; MCCAIN, 1998). Esses critérios foram considerados para selecionar uma ferramenta que atenda às exigências técnicas do projeto. Os critérios

analisados para a escolha da ferramenta de fichamento estão representados na Tabela 4.4.

Tabela 4.4: Análise das Ferramentas de Fichamento.

Crítérios	Facilidade	Anotações	Integração	Colaboração	Exportação
Mendeley	Muito bom	Muito bom	Muito bom	Bom	Bom
Google Sheets	Muito bom	Bom	Muito bom	Muito bom	Bom
Zotero	Muito bom	Bom	Muito bom	Bom	Bom
EndNote	Neutro	Muito bom	Muito bom	Bom	Muito bom
OneNote	Muito bom	Neutro	Fraco	Muito bom	Ruim
Research Rabbit	Muito bom	Neutro	Neutro	Muito bom	Bom
Connect Papers	Muito bom	Neutro	Neutro	Bom	Bom
Semantic Scholar	Muito bom	Neutro	Neutro	Bom	Muito bom
Elicit	Muito bom	Bom	Fraco	Bom	Bom
OA.MG	Muito bom	Neutro	Neutro	Bom	Bom
R Discovery	Muito bom	Neutro	Neutro	Bom	Bom

A escolha do Google Sheets como ferramenta de fichamento e análise de artigos para um processo automatizado de levantamento da literatura baseia-se em sua versatilidade, facilidade de uso, e robustas funcionalidades de colaboração, organização de dados e principalmente por sua conexão direta com o Zapier, plataforma de automação escolhida. O Google Sheets oferece uma interface intuitiva que permite aos usuários se concentrarem na análise dos dados sem enfrentar dificuldades técnicas, promovendo uma experiência fluida na organização e manipulação das informações.

Uma das características mais notáveis do Google Sheets é sua capacidade de integração com outras ferramentas e bases de dados acadêmicas, o que facilita a importação automatizada de referências e minimiza erros na entrada de dados. Este recurso é importante para manter uma coleção de informações atualizada e precisa, além de permitir que o processo de levantamento da literatura seja conduzido de maneira eficiente. A possibilidade de colaboração em tempo real, permitindo que múltiplos pesquisadores trabalhem simultaneamente no mesmo projeto, é outro ponto forte do Google Sheets, promovendo uma troca dinâmica e eficaz de informações, para o sucesso de projetos de pesquisa em grupo.

Além disso, o Google Sheets permite uma organização flexível e exportação de dados em diversos formatos, atendendo às diferentes exigências de publicações acadêmicas. Essa funcionalidade facilita a manutenção de uma estrutura organizada das referências, o que é importante para a produção de trabalhos acadêmicos de alta qualidade.

A conexão do Google Sheets com o Zapier adiciona uma camada significativa de automação ao processo de levantamento de literatura. Zapier é uma plataforma de automação que permite integrar o Google Sheets com uma vasta gama de outras aplicações, facilitando a automação de tarefas repetitivas. Com o Zapier, é possível configurar fluxos de trabalho automáticos que sincronizam dados inseridos no Google Sheets com outras ferramentas, como aplicativos de processamento de texto ou sistemas de gerenciamento de referências, criando registros automáticos de referências ou atualizações automáticas de bibliografias. Essa integração aumenta a eficiência e produtividade, reduzindo o tempo gasto em tarefas manuais e permitindo que os pesquisadores se concentrem mais na análise crítica e no desenvolvimento de suas pesquisas.

Em resumo, a escolha do Google Sheets se justifica por suas características abrangentes e sua capacidade de integrar-se perfeitamente com outras ferramentas através do Zapier, proporcionando um fluxo de trabalho coeso, eficiente e automatizado. Essa combinação maximiza a qualidade e a precisão dos resultados obtidos, atendendo às necessidades técnicas e colaborativas dos projetos acadêmicos, facilitando o processo de levantamento de literatura de maneira eficiente e organizada.

4.1.6 Ferramenta de geração de gráficos

Para o processo de automação, consideramos diversas ferramentas de geração de gráficos amplamente utilizadas no mercado. Essa ferramenta será utilizada para criar gráficos que mostram as publicações por ano, o que facilitará a visualização e análise da produção acadêmica ao longo do tempo. Entre as opções avaliadas, destacam-se GoogleSheets (2006), MicrosoftExcel (2006), AppleNumbers (2005) e ChatGPT (2022). Cada uma dessas ferramentas possui características distintas que foram analisadas com base em critérios específicos, como facilidade de uso, colaboração em tempo real, funcionalidades, integrações, custo, flexibilidade, segurança, suporte, compatibilidade, capacidade de contexto, personalização e frequência de atualização, como será descrito posteriormente.

O Google Sheets (Sheets) é uma ferramenta baseada na nuvem que facilita a colaboração em tempo real entre múltiplos usuários. Permite o acesso e a edição simultânea de documentos por diversos colaboradores, garantindo que as atualizações sejam refletidas

instantaneamente para todos os envolvidos. Além disso, sua integração nativa com outras ferramentas do Google Workspace e sua compatibilidade com uma vasta gama de aplicativos de terceiros, como Zapier e ChatGPT, tornam o processo de automação mais fluido e eficiente e a capacidade de gerar gráficos facilitam o processo de automação, tornando-o mais fluido e eficiente.

O Microsoft Excel (Excel) é uma ferramenta poderosa e amplamente utilizada, conhecida por suas funcionalidades extensivas e flexibilidade. No entanto, sua versão *desktop* não oferece a mesma facilidade de colaboração em tempo real sem a necessidade de configurações adicionais no OneDrive. A versão online do Excel melhora essa capacidade, e a ferramenta também se destaca na geração de gráficos, proporcionando uma solução robusta para visualização de dados, mas ainda pode ser menos intuitiva para alguns usuários em comparação com o Google Sheets.

O Apple Numbers (A.Numbers) é uma ferramenta mais limitada em termos de compatibilidade e integração com ferramentas de automação de terceiros. Embora seja intuitiva e gratuita, sua funcionalidade, capacidade de colaboração e geração de gráficos não são tão robustas quanto as oferecidas pelo Google Sheets e Microsoft Excel.

O ChatGPT é uma ferramenta inovadora que facilita a criação automatizada de gráficos e a análise de dados em planilhas. Permite que usuários descrevam textualmente o tipo de gráfico desejado, processa os dados e gera visualizações automaticamente, sem a necessidade de conhecimento técnico avançado. Além disso, o ChatGPT automatiza tarefas repetitivas, mantendo as visualizações atualizadas e melhorando a eficiência da análise de dados. Sua capacidade de integração com outros sistemas amplia suas aplicações, tornando-o uma solução poderosa para otimizar o fluxo de trabalho e apoiar decisões baseadas em dados.

Na escolha de uma ferramenta de geração de gráfico para um processo automatizado de levantamento da literatura, diversos critérios são fundamentais para assegurar a eficiência e a precisão do processo. A facilidade de uso é importante, pois a ferramenta deve ser intuitiva para permitir que os pesquisadores se concentrem na análise dos dados sem enfrentar uma curva de aprendizado íngreme (BEVAN, 1995). A capacidade de colaboração em tempo real é igualmente importante, garantindo que múltiplos usuários

possam trabalhar simultaneamente no mesmo documento, facilitando a coordenação e a troca de informações (GUTWIN; GREENBERG, 1998). A disponibilidade na nuvem é vital, permitindo acesso fácil e seguro de qualquer lugar, o que é significativo para equipes de pesquisa distribuídas geograficamente (MARINESCU, 2022). As funcionalidades avançadas, como ferramentas de análise de dados e visualização, são necessárias para manipular grandes volumes de informação e extrair *insights* significativos (FEW, 2006). A integração com outras ferramentas é importante, possibilitando que a planilha se conecte facilmente a plataformas de automação, bases de dados acadêmicas e softwares de processamento de linguagem natural, criando um fluxo de trabalho coeso e eficiente (LAUDON; LAUDON, 2004). Esses critérios foram considerados para selecionar uma ferramenta de geração de gráfico que atendam às exigências técnicas do projeto. Os critérios analisados para a escolha da ferramenta de geração de gráfico estão representados na Tabela 4.5.

Tabela 4.5: Análise das Ferramentas de Geração de Gráfico.

Critério	Sheets	Excel	A.Numbers	ChatGPT
Facilidade de Uso	Muito bom	Neutro	Neutro	Muito bom
Colaboração	Muito bom	Bom	Neutro	Muito bom
Nuvem	Muito bom	Muito bom	Muito bom	Muito fraco
Funcionalidades	Bom	Muito bom	Fraco	Muito bom
Integrações	Muito bom	Muito bom	Fraco	Muito bom

A escolha do ChatGPT como ferramenta para a geração de gráficos em planilhas foi baseada em sua capacidade única de interpretar comandos textuais e criar visualizações de dados de forma automatizada e dinâmica. Diferentemente das ferramentas tradicionais de planilhas, que exigem um conhecimento técnico mais avançado para a criação de gráficos, o ChatGPT permite que usuários simplesmente descrevam o gráfico desejado e ele gera a visualização correspondente, simplificando o processo e tornando-o acessível para todos os níveis de usuários.

Além disso, o ChatGPT é altamente flexível e versátil, podendo ser integrado a diversos fluxos de trabalho automatizados, o que o torna uma escolha ideal para processos que requerem rápida adaptação e personalização. Sua habilidade de automatizar tarefas complexas, como a geração e atualização de gráficos com base em dados que mudam constantemente, garante que as visualizações estejam sempre atualizadas sem a necessidade de intervenção manual constante. Isso não só economiza tempo, mas também reduz a

possibilidade de erros, aumentando a eficiência e a precisão das análises.

Portanto, a escolha do ChatGPT é justificada por sua simplicidade de uso, capacidade de automação e integração com outras ferramentas e processos, oferecendo uma solução poderosa e inovadora para a geração de gráficos em ambientes de planilhas.

4.1.7 Ferramentas de Mapa de Palavras

Para o processo de automação, foram consideradas diversas ferramentas de mapa de palavras amplamente utilizadas. Essas ferramentas são essenciais para gerar mapas visuais que destacam os autores mais proeminentes em determinado assunto. Através da análise de frequência e coocorrência de termos, essas ferramentas permitem identificar as figuras mais influentes e as relações entre diferentes pesquisadores, facilitando a compreensão das dinâmicas acadêmicas no campo de estudo.. Entre as opções avaliadas, encontram-se Miro (2011), MindMeister (2007), XMind (2006), Lucidchart (2008) e ChatGPT (2022). Cada uma dessas ferramentas possui características distintas que foram analisadas com base em critérios específicos, como facilidade de uso, funcionalidades, integrações e compatibilidade.

Miro é uma plataforma colaborativa que permite a criação de mapas de palavras e *mind maps*. Sua interface intuitiva e as diversas funcionalidades colaborativas fazem do Miro uma escolha popular entre equipes que buscam trabalhar de maneira sincronizada. A integração com outras plataformas possibilita a automação de tarefas como a criação de novos mapas, adição de conteúdo e notificações, o que facilita a organização e gestão de ideias em projetos colaborativos. No entanto, sua curva de aprendizado pode ser um pouco acentuada para novos usuários.

MindMeister (MindM.) é uma ferramenta especializada em *mind mapping online* que se destaca por sua simplicidade e eficácia na organização de ideias. Sua integração com outras plataformas permite a criação de novos mapas de palavras a partir de gatilhos em outras ferramentas, como Google Sheets ou Trello, oferecendo uma abordagem flexível e personalizável para a automação de processos criativos. Contudo, sua limitação em termos de funcionalidades avançadas pode ser um ponto negativo para usuários que buscam uma maior variedade de opções.

XMind é uma alternativa robusta e amplamente utilizada para *mind mapping*, conhecida por suas funcionalidades ricas e interface de usuário bem estruturada. A possibilidade de integração permite a criação de fluxos de trabalho customizados, que automatizam tarefas como a criação de novos arquivos ou a edição de mapas existentes. XMind se destaca pela sua flexibilidade na organização de informações, mas a falta de integração direta com algumas plataformas populares pode limitar sua aplicabilidade em certos cenários.

Lucidchart (Lucid), embora seja tradicionalmente mais voltado para a criação de diagramas e fluxogramas, também permite a elaboração de mapas de palavras. Sua integração com outras ferramentas facilita a automação de processos relacionados à criação e atualização de diagramas, o que pode ser útil para visualizações mais complexas e detalhadas. No entanto, Lucidchart pode não ser a melhor escolha para quem busca uma ferramenta exclusivamente para mapas de palavras, devido ao seu foco mais amplo em outros tipos de diagramas.

Por fim, o ChatGPT surge como uma solução inovadora e flexível para a criação de mapas de palavras. Sua capacidade de gerar e organizar conteúdo com base em *prompts* textuais oferece uma abordagem única para a criação de mapas de palavras de maneira dinâmica e personalizada. A integração permite que o ChatGPT seja utilizado em fluxos de trabalho automatizados, onde pode gerar conteúdo e estruturar ideias conforme necessário. Embora não seja uma ferramenta tradicional de mapas de palavras, sua versatilidade e capacidade de adaptação a diferentes contextos o tornam uma escolha poderosa para projetos que exigem flexibilidade e inovação.

Na escolha da ferramenta para gerar o mapa de palavras para um processo automatizado, vários critérios foram levados em consideração, incluindo a facilidade de uso (NIELSEN, 1994), a capacidade de colaboração (OLSON et al., 1992), as funcionalidades disponíveis (NUNAMAKER et al., 1991), as integrações com outras plataformas (SMITH; FARNHAM; DRUCKER, 2000) e a flexibilidade (PREECE et al., 1994) para atender às necessidades específicas do projeto. Esses critérios foram considerados para selecionar uma ferramenta de mapa de palavras que atendam às exigências técnicas do projeto, os critérios analisados para a escolha da ferramenta de planilha estão representados na

Tabela 4.6.

Tabela 4.6: Tabela Comparativa de Ferramentas de Mapa de Palavras.

Critério	Miro	MindM.	XMind	Lucid	ChatGPT
Facilidade uso	Muito bom	Muito bom	Muito bom	Neutro	Muito bom
Funcionalidades	Muito bom	Neutro	Muito bom	Muito bom	Muito bom
Integrações	Muito bom	Muito bom	Fraco	Muito bom	Muito bom
Flexibilidade	Muito bom	Neutro	Muito bom	Neutro	Muito bom
Colaboração	Muito bom	Bom	Bom	Neutro	Muito bom

Entre as ferramentas avaliadas, o ChatGPT destacou-se como a escolha preferida devido à sua capacidade única de gerar conteúdo textualmente orientado de maneira automatizada, oferecendo uma solução versátil e eficiente para a criação de mapas de palavras em diversos contextos. Devido à sua capacidade de gerar conteúdo de alta qualidade de forma personalizada, integrando-se eficazmente em fluxos de trabalho automatizados e atendendo às exigências técnicas do projeto, ele foi escolhido para ser usado nessa pesquisa.

4.1.8 Ferramenta de editoração de texto

Para o processo de automação, consideramos diversas ferramentas de edição de documentos amplamente utilizadas no mercado. Entre as opções avaliadas, destacam-se Google Docs (2006), Microsoft Word (1983) e ZohoWriter (2022). Cada uma dessas ferramentas possui características distintas que foram analisadas com base em critérios específicos, como facilidade de uso, colaboração em tempo real, funcionalidades, integrações e compatibilidade.

Google Docs é uma ferramenta baseada na nuvem que permite a edição simultânea de documentos por múltiplos usuários. Sua robusta funcionalidade de colaboração em tempo real, juntamente com a capacidade de comentar e sugerir edições, facilita uma colaboração eficiente e transparente. Além disso, a integração perfeita com outras ferramentas do Google Workspace e sua compatibilidade nativa com uma vasta gama de aplicativos de terceiros, incluindo plataformas de automação como Zapier, simplificam a criação de fluxos de trabalho automatizados.

Microsoft Word é uma ferramenta poderosa e amplamente utilizada, conhecida por suas funcionalidades avançadas de edição e formatação. No entanto, sua versão *desk-*

top não suporta a colaboração em tempo real com a mesma facilidade que o Google Docs, a menos que esteja integrada ao OneDrive. A versão *online* do Word melhora essa capacidade, mas ainda pode ser menos intuitiva para alguns usuários em comparação com o Google Docs.

Zoho Writer é uma alternativa viável com boas funcionalidades de edição e colaboração. Contudo, possui uma base de usuários menor e menos integrações diretas com ferramentas populares. Embora ofereça suporte para colaboração em tempo real, suas integrações e compatibilidade não são tão extensivas quanto as do Google Docs.

Na escolha de uma ferramenta de texto para um processo automatizado de levantamento da literatura, vários critérios são fundamentais para garantir a eficiência e a precisão do processo. A facilidade de uso é importante, pois a ferramenta deve ser intuitiva e acessível para pesquisadores, permitindo que se concentrem na análise e redação sem enfrentar uma curva de aprendizado íngreme (NIELSEN, 1994). Além disso, a escalabilidade da ferramenta é um aspecto significativo, garantindo que o sistema possa crescer e se adaptar conforme as necessidades do projeto evoluem. A colaboração em tempo real é igualmente importante, pois facilita o trabalho conjunto de múltiplos pesquisadores no mesmo documento, promovendo a coordenação e a troca de informações de forma dinâmica e eficiente (OLSON et al., 1992). As funcionalidades avançadas, como ferramentas de formatação, revisão e controle de versões, são necessárias para permitir uma manipulação detalhada dos documentos e assegurar a qualidade e a consistência do conteúdo produzido (NUNAMAKER et al., 1991). A integração com outras ferramentas, como plataformas de automação, bases de dados acadêmicas e software de gerenciamento de referências, é vital para criar um fluxo de trabalho coeso e eficiente, facilitando a transferência de dados e a coordenação entre diferentes sistemas (SMITH; FARNHAM; DRUCKER, 2000). Finalmente, a compatibilidade com diferentes formatos de arquivo e dispositivos garante que os documentos possam ser facilmente acessados, editados e compartilhados em diversos ambientes de trabalho, proporcionando flexibilidade e continuidade no processo de pesquisa (PREECE et al., 1994). Esses critérios foram considerados para selecionar uma ferramenta de texto atenda às exigências técnicas do projeto, resultados representados na Tabela 4.7.

Tabela 4.7: Análise das Ferramentas de Edição de Documentos.

Critério	Google Docs	Microsoft Word	Zoho Writer
Facilidade de Uso	Muito bom	Muito bom	Neutro
Colaboração	Muito bom	Bom	Bom
Funcionalidades	Muito bom	Muito bom	Muito bom
Integrações	Muito bom	Muito bom	Neutro
Compatibilidade	Muito bom	Muito bom	Neutro

A escolha do Google Docs para o processo de automação, em detrimento do Microsoft Word e do Zoho Writer, é fundamentada em sua robusta funcionalidade de colaboração em tempo real e sua integração perfeita com outras ferramentas do Google Workspace. O Google Docs permite que múltiplos usuários editem e comentem simultaneamente em um documento, facilitando uma colaboração eficiente e transparente. Além disso, sua compatibilidade nativa com uma vasta gama de aplicativos de terceiros, incluindo plataformas de automação como Zapier, simplifica a criação de fluxos de trabalho automatizados.

Portanto, o Google Docs é preferido por sua acessibilidade, capacidade de colaboração em tempo real e ampla compatibilidade com outras ferramentas, tornando-o ideal para processos automatizados em um ambiente colaborativo.

O Google Docs é utilizado como a ferramenta de consolidação e armazenamento das respostas geradas. Este processo garante que todas as informações geradas estejam centralizadas em um único documento, facilitando a revisão e a análise crítica por parte dos pesquisadores. O Google Docs oferece uma plataforma flexível e acessível para edição e formatação de texto, além de permitir colaboração em tempo real, o que é significativo para equipes de pesquisa que trabalham de forma conjunta.

4.1.9 Ferramenta de busca acadêmica

As ferramentas de busca acadêmica desempenham um papel importante no avanço da ciência e no desenvolvimento do conhecimento em diversas áreas. Permitem que pesquisadores, estudantes e profissionais acessem de maneira rápida e eficiente uma vasta quantidade de literatura científica, incluindo artigos revisados por pares, conferências, patentes e livros. Em um ambiente acadêmico cada vez mais competitivo e globalizado, a capacidade de encontrar, avaliar e utilizar informações relevantes é significativo para a

produção de pesquisa de alta qualidade. Essas ferramentas não apenas facilitam o acesso a dados e descobertas anteriores, mas também promovem a interconectividade entre diferentes áreas do conhecimento, permitindo abordagens interdisciplinares e inovadoras. Além disso, as plataformas de busca oferecem recursos avançados de análise, como métricas de citação e impacto, que são essenciais para a avaliação da relevância e influência dos trabalhos acadêmicos. As ferramentas de busca acadêmica são indispensáveis para a disseminação do conhecimento científico, contribuindo significativamente para o progresso da pesquisa e a resolução de desafios complexos em diversas disciplinas.

O IEEEXplore (2000) é uma plataforma digital mantida pelo *Institute of Electrical and Electronics Engineers* (IEEE), que oferece acesso a uma vasta coleção de artigos, conferências, padrões técnicos e livros nas áreas de engenharia elétrica, ciência da computação e eletrônica. Essa ferramenta é amplamente utilizada por pesquisadores e profissionais em áreas tecnológicas, sendo uma fonte de alta relevância para acesso a recursos especializados.

O GoogleScholar (2004) é uma ferramenta de busca gratuita que indexa uma ampla variedade de literatura acadêmica em diversas disciplinas. Ele agrega conteúdos de diferentes fontes, incluindo artigos de periódicos, livros, teses e resumos. Apesar de sua abrangência, a qualidade e a autoridade das fontes podem variar, o que exige uma avaliação cuidadosa por parte do usuário.

Desenvolvido pelo *National Center for Biotechnology Information* (NCBI), o PubMed (1996) é uma base de dados especializada em biomedicina e áreas relacionadas, como ciências da vida e saúde. Ela oferece acesso a uma vasta coleção de artigos de revistas científicas, incluindo aqueles indexados no MEDLINE, e é considerada uma ferramenta importante para pesquisadores na área médica e biomédica.

O WebOfScience (1997), mantido pela *Clarivate Analytics*, é uma das bases de dados mais antigas e respeitadas, oferecendo acesso a um vasto acervo de artigos revisados por pares em múltiplas disciplinas. Além disso, essa plataforma é amplamente utilizada para análise de citação, fornecendo métricas detalhadas sobre o impacto e a interconectividade dos trabalhos científicos, sendo significativa para a avaliação da produção acadêmica.

A ACM Digital Library (1997), operada pela *Association for Computing Machinery* (ACM), é uma das mais importantes plataformas para a área de ciência da computação, oferecendo acesso a periódicos, conferências e artigos técnicos. A ACM DL é muito utilizada para pesquisadores em computação e disciplinas correlatas, fornecendo acesso a recursos de alta qualidade e relevância.

Conhecida também como *Engineering Index*, a EICompindex (1969) é uma base de dados abrangente para literatura em engenharia, cobrindo uma ampla gama de disciplinas, incluindo civil, mecânica, elétrica e química. Essa plataforma é amplamente utilizada para pesquisas técnicas e científicas, fornecendo uma rica coleção de informações para engenheiros e pesquisadores.

O ScienceDirect (1997), operado pela *Elsevier*, é uma das maiores coleções de literatura científica revisada por pares, abrangendo diversas áreas do conhecimento, como ciências, tecnologia, medicina, ciências sociais e humanidades. A plataforma oferece acesso a artigos, capítulos de livros e outras publicações de alta qualidade, sendo uma fonte indispensável para pesquisadores em diversas disciplinas.

Por fim, o SCOPUS (2004), também mantido pela *Elsevier*, é uma das maiores bases de dados de resumos e citações de literatura revisada por pares, cobrindo uma ampla gama de disciplinas, incluindo ciências, tecnologia, medicina, ciências sociais, artes e humanidades. Scopus é frequentemente utilizada para análise bibliométrica e estudos de impacto, sendo uma ferramenta para a avaliação da pesquisa científica global.

Cada uma dessas ferramentas oferece recursos valiosos para a busca e análise de literatura científica, conforme mostra a Tabela 4.8, sendo importante escolher a plataforma mais adequada de acordo com a área de pesquisa e as necessidades específicas do estudo. Neste trabalho, foi utilizado a plataforma IEEE Xplore como principal ferramenta de busca acadêmica devido à sua facilidade de importação dos artigos em formato CSV. Essa funcionalidade permite a organização eficiente dos dados coletados, facilitando tanto a análise quanto a integração dos resultados em sistemas de gerenciamento de referências e ferramentas de análise bibliométrica. A escolha do IEEE Xplore também se justifica pela sua ampla cobertura nas áreas de engenharia elétrica, ciência da computação e eletrônica, garantindo o acesso a uma base robusta e relevante de literatura científica

para o desenvolvimento deste estudo.

Tabela 4.8: Análise das Ferramentas de Busca Acadêmica.

Critérios	Conteúdo	Indexação	Recursos de busca	Exportação
IEEEExplore	Muito bom	Muito bom	Muito bom	Muito bom
Google Scholar	Muito bom	Neutro	Neutro	Fraco
PubMed	Muito bom	Muito bom	Muito bom	Muito bom
Web of Science	Muito bom	Muito bom	Muito bom	Muito bom
ACM DL	Muito bom	Muito bom	Muito bom	Muito bom
EICompindex	Muito bom	Muito bom	Muito bom	Muito bom
Science Direct	Muito bom	Muito bom	Muito bom	Muito bom
Scopus	Muito bom	Muito bom	Muito bom	Muito bom

4.2 Considerações do capítulo

Esse capítulo apresentou as ferramentas que serão utilizadas para integrar o processo automatizado, por meio do Zapier, uma plataforma de automação que conecta diferentes aplicativos e serviços, permitindo a automação de tarefas sem a necessidade de conhecimento em programação. O Zapier monitora as alterações no Google Sheets e, baseado em gatilhos predefinidos, executa ações como enviar a questão de pesquisa para o ChatGPT, retornar as palavras-chave geradas, e transferir as respostas geradas. Essa automação não só economiza tempo, mas também garante que o processo seja realizado de forma consistente e eficiente, minimizando a possibilidade de erros.

A importância dessa integração reside na capacidade de cada ferramenta complementar as funcionalidades das outras, criando um fluxo de trabalho coeso e eficiente. O ChatGPT é utilizado tanto para a geração de gráficos quanto para a criação de mapas de palavras, aplicando sua inteligência artificial para aprimorar buscas, resumir artigos, e visualizar dados de forma dinâmica, o Google Sheets atua como ferramenta de fichamento, organizando e gerenciando as referências bibliográficas de forma eficiente. O Google Docs consolida os resultados em um formato acessível e colaborativo e o Zapier automatiza a comunicação entre essas ferramentas, garantindo que o processo ocorra sem interrupções.

A integração do ChatGPT, Google Sheets, Google Docs, Zapier e IEEEExplore cria um processo robusto e eficiente para levantamento de literatura. Cada ferramenta desempenha um papel específico e significativo, e sua combinação permite a automatização

de tarefas que tradicionalmente demandariam tempo significativo e esforço manual. Esta abordagem não apenas otimiza o processo de pesquisa, mas também melhora a qualidade e a relevância dos dados coletados, proporcionando aos pesquisadores mais tempo para análise crítica e desenvolvimento de suas investigações.

5 Estudo de caso

Um estudo de caso (VENTURA, 2007) é importante em um trabalho científico, pois permite uma análise detalhada e contextualizada de aplicações práticas, proporcionando uma compreensão mais profunda dos fenômenos estudados. Neste trabalho sobre automação na revisão de literatura, o estudo de caso ilustra como a integração de ferramentas como Zapier, ChatGPT, Google Sheets e Google Docs pode transformar o processo de coleta e síntese de informações acadêmicas, assim como é representado na Figura 5.1. Ao analisar um cenário real, onde um pesquisador utiliza essas tecnologias para automatizar a organização de trabalhos acadêmicos e a análise dos mesmos, o estudo de caso demonstra concretamente os benefícios tangíveis, como a redução de erros manuais e o aumento da eficiência operacional. Assim, o estudo de caso valida a metodologia proposta, oferece evidências empíricas sobre a eficácia das soluções e amplia a compreensão dos desafios e oportunidades da automação no contexto acadêmico.



Figura 5.1: Processo automatizado para revisão da literatura.

5.1 Procedimentos detalhados

O processo automatizado para levantamento de literatura é composto por uma série de etapas cuidadosamente planejadas, cada uma desempenhando um papel significativa na eficiência e eficácia da pesquisa. A automatização desse processo, especialmente com o uso de inteligência artificial generativa, representa um avanço significativo na forma como

a busca acadêmica é conduzida. A integração de ferramentas como Zapier, ChatGPT, Google Sheets e Google Docs permite a automação de tarefas que, tradicionalmente, exigiriam considerável tempo e esforço manual.

Além de economizar tempo, a utilização de IA generativa na busca acadêmica melhora a precisão e abrangência dos resultados, garantindo que termos sinônimos e variações terminológicas sejam considerados, algo que seria difícil de alcançar manualmente. Essa abordagem não apenas otimiza o processo, mas também aumenta a qualidade da revisão ou mapeamento da literatura, assegurando que estudos relevantes e atuais sejam incluídos na análise. A automatização e o uso de IA generativa transformam o levantamento de literatura em um processo mais eficaz, confiável e menos propenso a erros humanos.

5.1.1 Questão de pesquisa inicial

Neste trabalho, foi elaborada uma *string* de busca de forma manual, sem o auxílio de inteligência artificial, com o objetivo de recuperar artigos relevantes para a pesquisa. Essa abordagem, apesar de tradicional e amplamente utilizada na academia, não resultou na recuperação de artigos significativos, destacando uma limitação inerente às estratégias de busca convencionais. A eficácia da pesquisa bibliográfica depende fortemente da definição precisa e abrangente da *string* de busca, que deve capturar todos os termos relevantes e seus sinônimos, além de considerar variações terminológicas usadas na literatura acadêmica. A *string* de busca elaborada no início da pesquisa foi:

(“literature review”) AND (“systematic mapping” OR “systematic review”) AND (“automated process”) AND (“tool” OR “application” OR “program” OR “software”)

A aplicação da *string* de busca resultou na recuperação de 155 artigos na base de dados IEEEExplore, como pode ser observado na Figura 5.2. Esse número inclui tanto artigos de acesso aberto quanto artigos restritos. Importante destacar que esse conjunto de artigos foi identificado antes da aplicação dos critérios de inclusão e exclusão, que são fundamentais para refinar a seleção dos trabalhos mais relevantes ao escopo da pesquisa. A etapa

subsequente envolve a análise desses critérios para assegurar que apenas os estudos que atendem aos requisitos específicos do estudo sejam considerados, garantindo a qualidade e a pertinência da revisão da literatura.

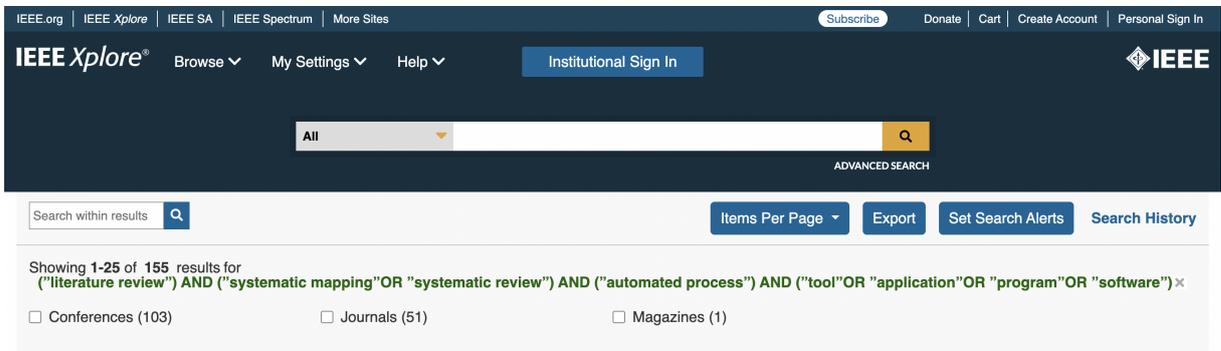


Figura 5.2: Resultados gerados sem uso de IA.

A importância da *string* de busca reside em sua capacidade de direcionar a recuperação de documentos que sejam pertinentes ao tema em estudo. No entanto, uma *string* de busca mal formulada pode resultar na exclusão de materiais importantes, devido à ausência de termos sinônimos ou relacionados que são utilizados na literatura. Portanto, a elaboração cuidadosa da *string* de busca é necessária para assegurar que a pesquisa bibliográfica seja abrangente e precisa, capturando ao máximo as publicações relevantes ao tema investigado.

5.1.2 Configuração inicial da automação

O processo de automação para a revisão sistemática da literatura foi desenvolvido por meio do Zapier, que é uma ferramenta de automação para conectar diferentes aplicativos e automatizar fluxos de trabalho. O Zapier permite que tarefas repetitivas e demoradas sejam automatizadas, eliminando a necessidade de intervenções manuais frequentes. Essa combinação de ferramentas não apenas economiza tempo, mas também minimiza a possibilidade de erros humanos, garantindo um fluxo de trabalho mais eficiente e confiável. Ao entrar na plataforma, a tela inicial já apresenta uma *trigger* que será o ponto de partida, disparo do processo e uma *action*, que é a ação que será realizada, conforme a Figura 5.3. Além disso, a interface intuitiva do Zapier facilita a configuração e monitoramento das automações, mesmo para usuários sem conhecimentos avançados de programação.

Isso permite uma rápida adaptação do processo às necessidades específicas do projeto. A flexibilidade da ferramenta também possibilita a integração com uma vasta gama de aplicativos, ampliando as possibilidades de automação para diferentes etapas da revisão sistemática.

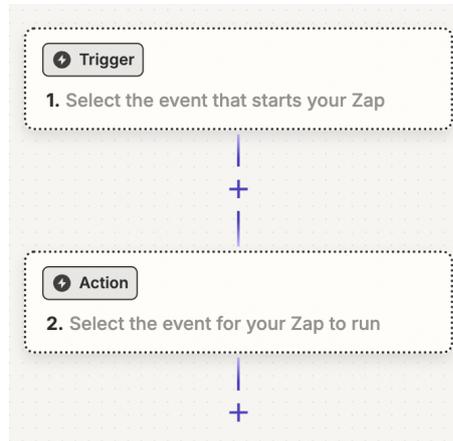


Figura 5.3: Tela inicial do Zapier.

O processo inicia-se com a inserção da questão de pesquisa no Google Sheets, conforme a Figura 5.4, que serve como o ponto de partida da automação.

H	I	J	K	L	M	N	O	P
("literature review") AND ("systematic mapping" OR "systematic review") AND ("automated process") AND ("tool" OR "application" OR "program" OR "software")								

Figura 5.4: Questão de pesquisa inicial no Google Sheets.

O Google Sheets, por ser uma ferramenta de fácil colaboração permite que todos os pesquisadores presentes no trabalho tenham acesso e consigam modificar a *string* original de busca. Dessa forma, além da *string*, a tabela PICOC está presente no arquivo, conforme a Figura 5.5, sendo usada para criar a *string* original.

	A	B	C	D	E	F
1	Picoc	Population	Intervention	Control	Outcome	Context
2	Palavras - chave	Revisão da literatura	Mapeamento sistemático, revisão sistemática	Não definido	Ferramenta, aplicação, software	Processo automatizado

Figura 5.5: PICOC no Google Sheets.

A escolha do Google Sheets como ponto inicial do processo no Zapier foi motivada por uma limitação técnica encontrada no Google Docs. Durante o desenvolvimento do fluxo de trabalho automatizado, constatou-se que o Zapier não conseguia ler uma única

linha de dados diretamente do Google Docs, o que inviabilizava sua utilização como ferramenta inicial no processo. O Google Sheets, por outro lado, demonstrou ser totalmente compatível com as necessidades de leitura e automação requeridas pelo Zapier, permitindo a integração e manipulação eficiente dos dados necessários para o processo automatizado. Essa compatibilidade garantiu a continuidade do trabalho sem interrupções, tornando o Google Sheets a escolha mais viável para iniciar o fluxo de trabalho. Além disso, o Google Sheets tem a capacidade de facilitar a colaboração em tempo real e organizar os dados de forma estruturada, garantindo uma base sólida para a automação subsequente no Zapier.

Dessa forma, a configuração inicial do Google Sheets no Zapier é o primeiro passo para o processo de automatização. Nessa etapa, a planilha já criada especificamente para o projeto de pesquisa, contendo a célula designada para a inserção da questão de pesquisa, que será monitorada pelo Zapier. A configuração do Zapier envolve a criação de um *zap*, que consiste em um *trigger*, e uma ou mais *actions*. O *trigger* detecta quando a célula da questão de pesquisa é preenchida ou alterada, e as *actions* subsequentes enviam a questão ao ChatGPT, armazenando então as respostas, conforme os passos:

- Primeiramente, selecionar o aplicativo do Google Sheets dentro do Zapier como o aplicativo de origem, conforme a Figura 5.6;

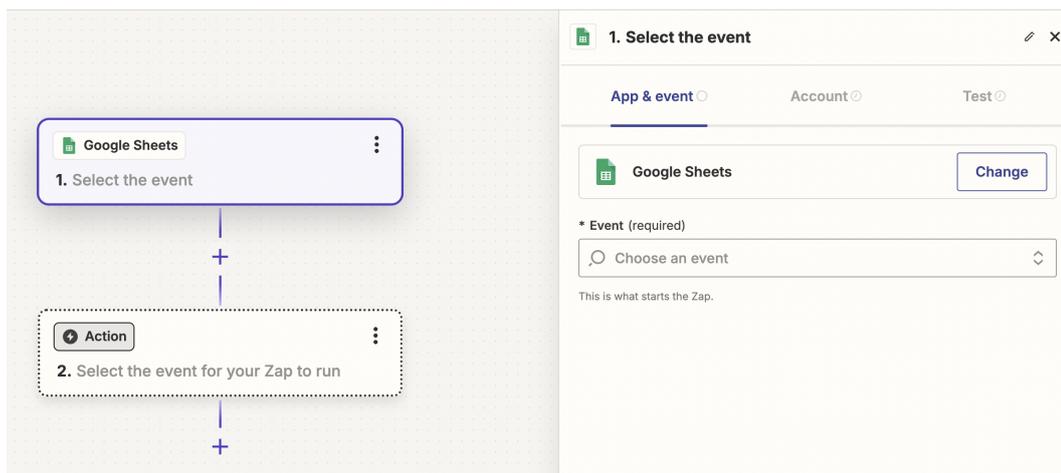


Figura 5.6: Questão de pesquisa inicial no Google Sheets.

- Com o Google Sheets selecionado, escolher "New or Updated Spreadsheet Row" como evento, refere-se a um gatilho que inicia um fluxo de trabalho automatizado sempre

que uma nova linha é adicionada ou uma linha existente é atualizada na planilha, conforme a Figura 5.7;

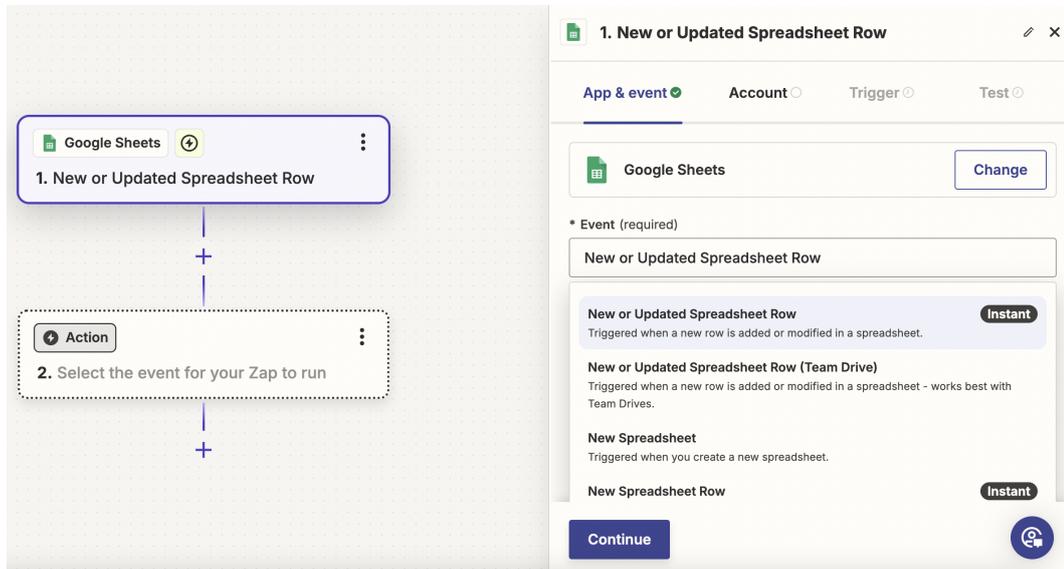


Figura 5.7: Selecionar evento a ser realizado para a *string*.

- Com o Google Sheets selecionado é necessário conectar a conta autenticada do Google para permitir o acesso do Zapier aos dados da planilha, conforme a Figura 5.8;

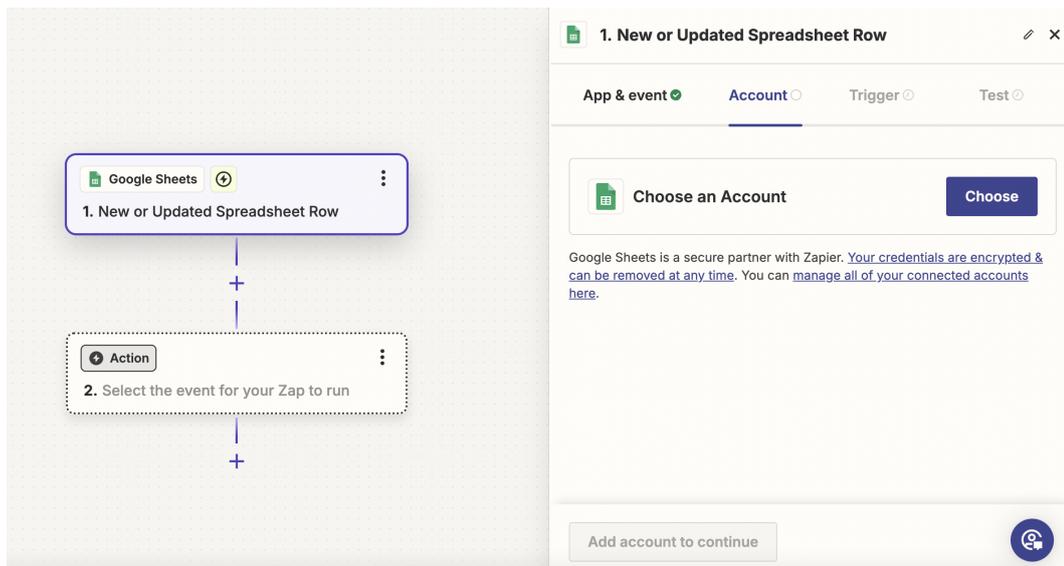


Figura 5.8: Conectar conta autenticada do Google para a *string*.

- O passo a seguir é configurar a planilha, preenchendo as lacunas *spreadsheet* que é a planilha a ser utilizada, *worksheet* a página da planilha que contém a questão de

pesquisa e *trigger column* que é a coluna a ser analisada, nesse caso somente a da *string* de busca inicial, conforme a Figura 5.9;

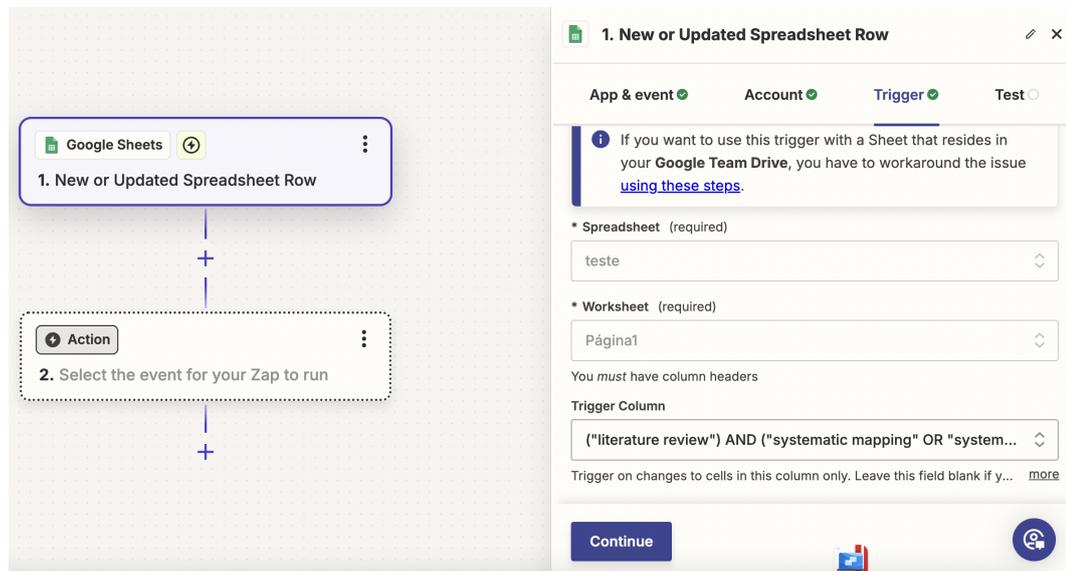


Figura 5.9: Configuração da planilha no Zapier para a *string*.

- Por fim, a fase de teste verifica se a planilha, página e coluna estão certas para poder dar continuidade no processo, de acordo com a Figura 5.10.

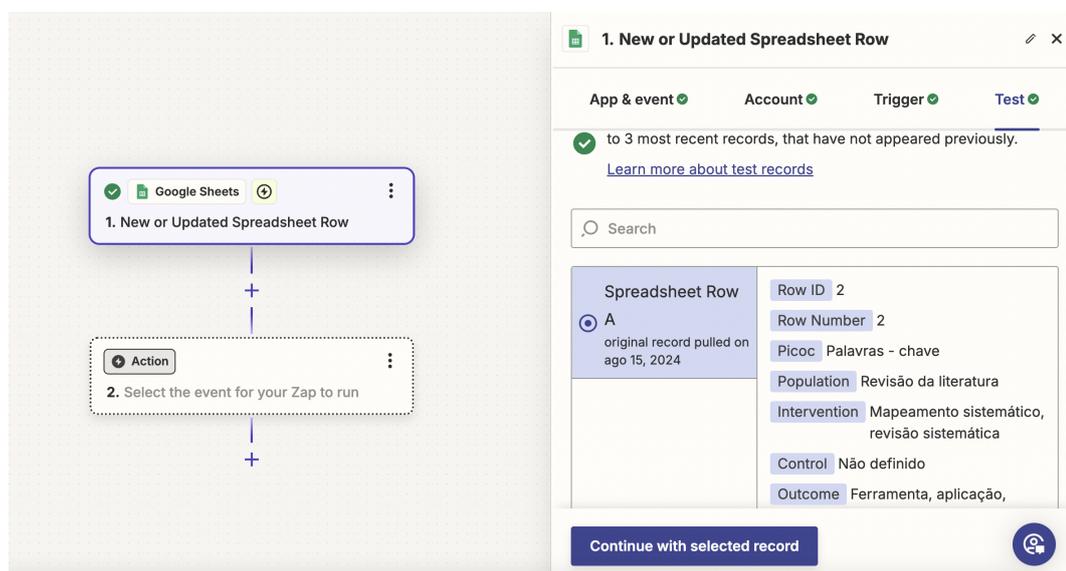


Figura 5.10: Fase de teste da planilha para a *string*.

5.1.3 Geração de palavras-chave, termos e sinônimos

Com a questão de pesquisa inserida no Google Sheets, a próxima etapa é a geração de palavras-chave, termos e sinônimos. Quando o Zapier detecta uma atualização na célula designada *trigger*, aciona um *zap* que envia a questão de pesquisa ao ChatGPT *action*. O ChatGPT processa a questão e gera uma lista de palavras-chave e sinônimos relevantes, essenciais para aprimorar a *string* de busca. Esse passo é importante, pois palavras-chave bem definidas aumentam a precisão e a relevância da busca pelos trabalhos acadêmicos. Além disso, o ChatGPT pode adaptar as palavras-chave ao contexto específico da questão, aumentando a eficácia da pesquisa em diversas bases de dados. Em seguida, as palavras-chave geradas podem ser revisadas e ajustadas manualmente, se necessário, para garantir que todas as variáveis relevantes sejam consideradas. Esse processo automatizado não apenas economiza tempo, mas também assegura que a geração de termos de busca seja feita de maneira sistemática e consistente, reduzindo o risco de omissões. Esse passo será detalhado a seguir:

- Primeiramente, selecionar o aplicativo da OpenAI dentro do Zapier, conforme a Figura 5.11;

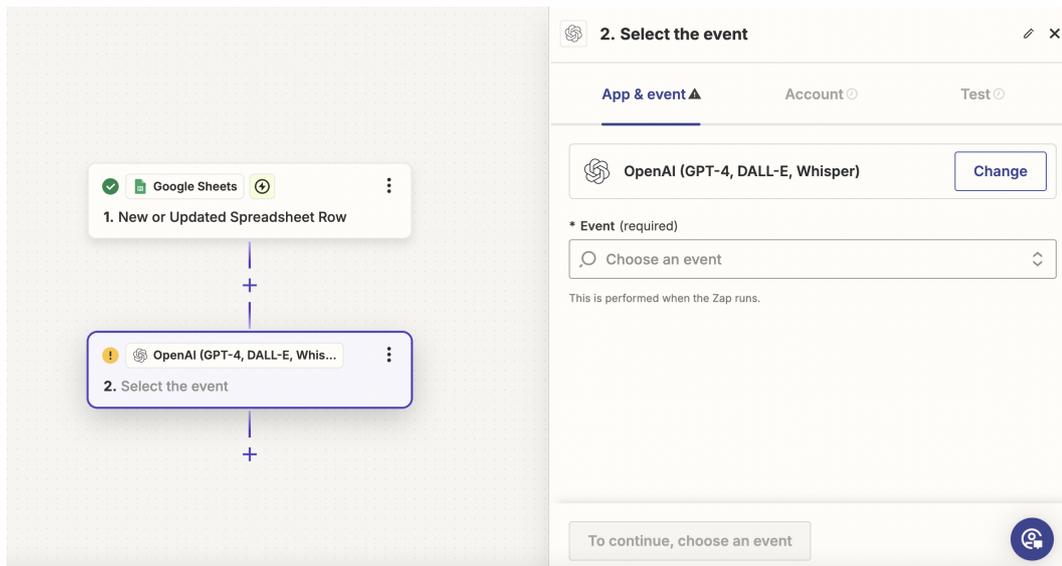


Figura 5.11: Selecionar o aplicativo da Open AI no Zapier para a *string*.

- Com o Open AI selecionado, escolher "Send Prompt" como evento, que por sua vez irá enviar a questão de pesquisa para receber uma resposta, como exibido na Figura

5.12;

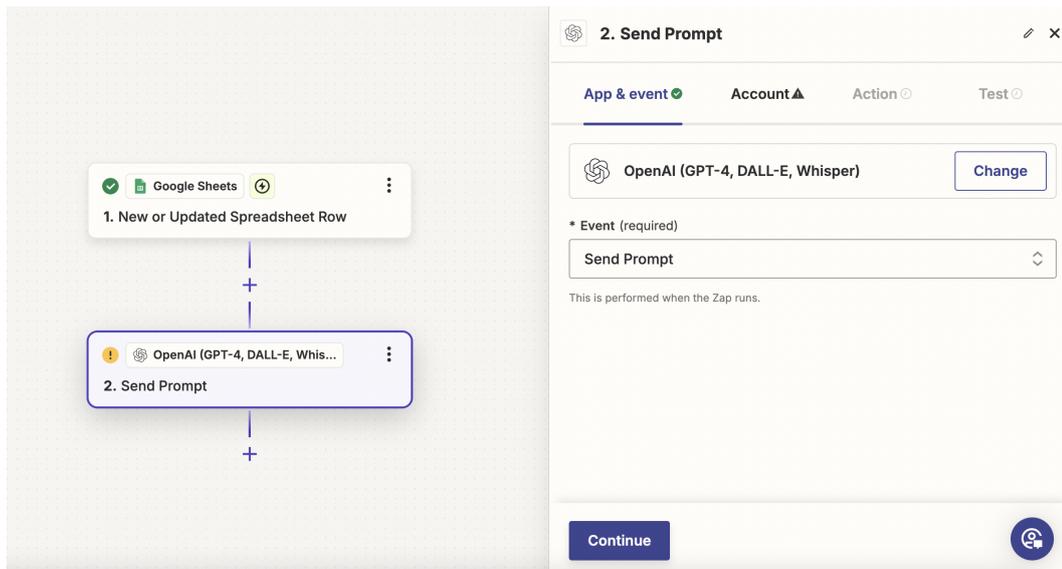


Figura 5.12: Selecionar evento a ser realizado no Open AI para a *string*.

- Com o Open AI selecionado é necessário conectar a conta autenticada da Open AI para permitir que o Zapier consiga fazer a conexão, nesse caso o ChatGPT 4o, como representado na Figura 5.13;

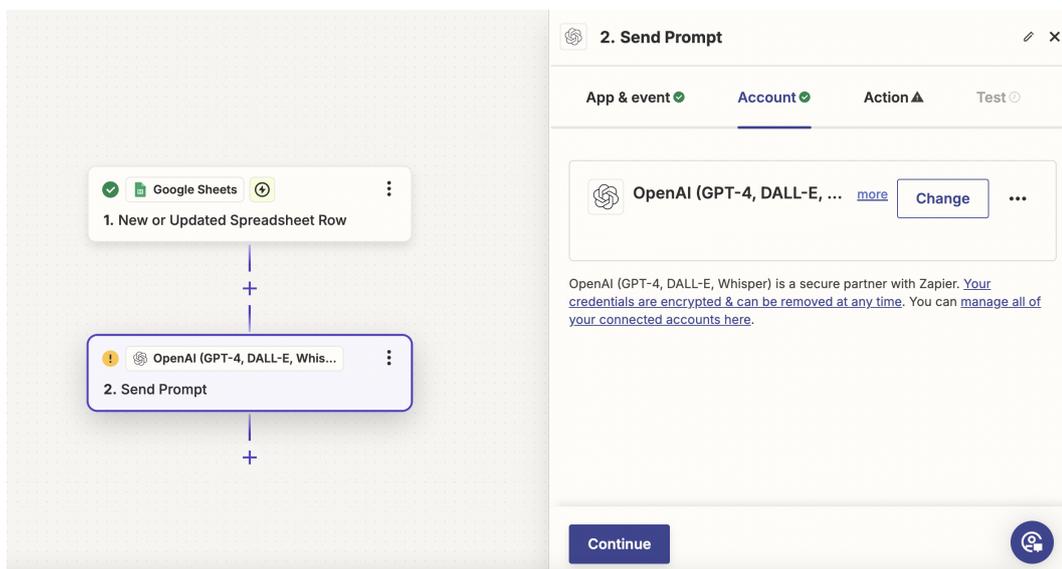


Figura 5.13: Conectar conta da Open AI para a *string*.

- Com a conta conectada, o proximo passo será configurar o *prompt*, que será a ação a ser realizada. Nessa etapa será enviada ao ChatGPT 4o a questão inicial da pesquisa

e o *prompt* será configurado para retornar sinônimos, palavras-chave e novos termos, assim como na Figura 5.14;

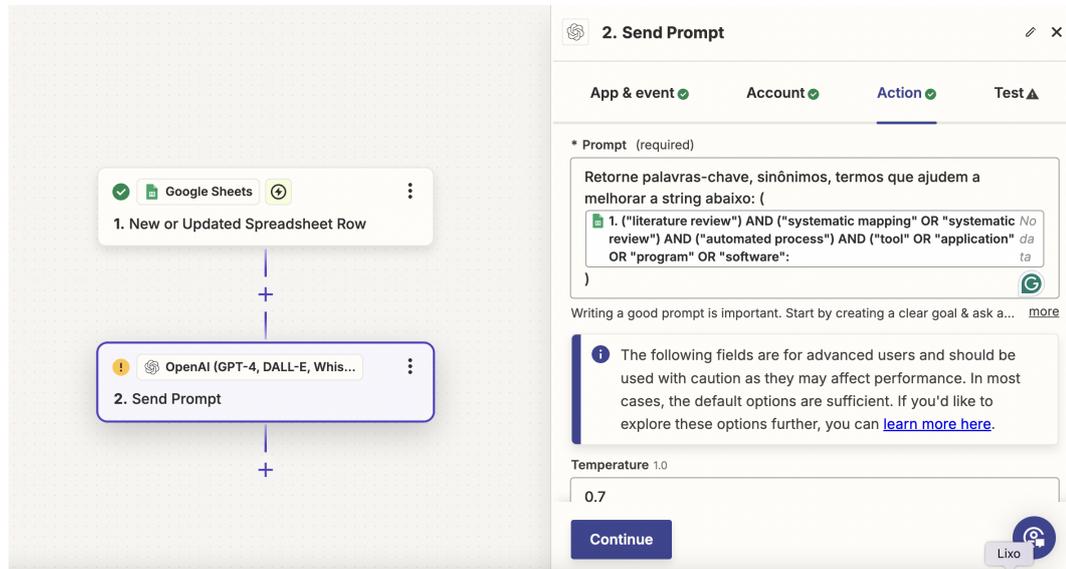


Figura 5.14: Configuração do *prompt* para a *string*.

- Por fim, a fase de teste verifica se o *prompt* foi enviado corretamente para que gere as respostas corretas, assim como retrata a Figura 5.15.

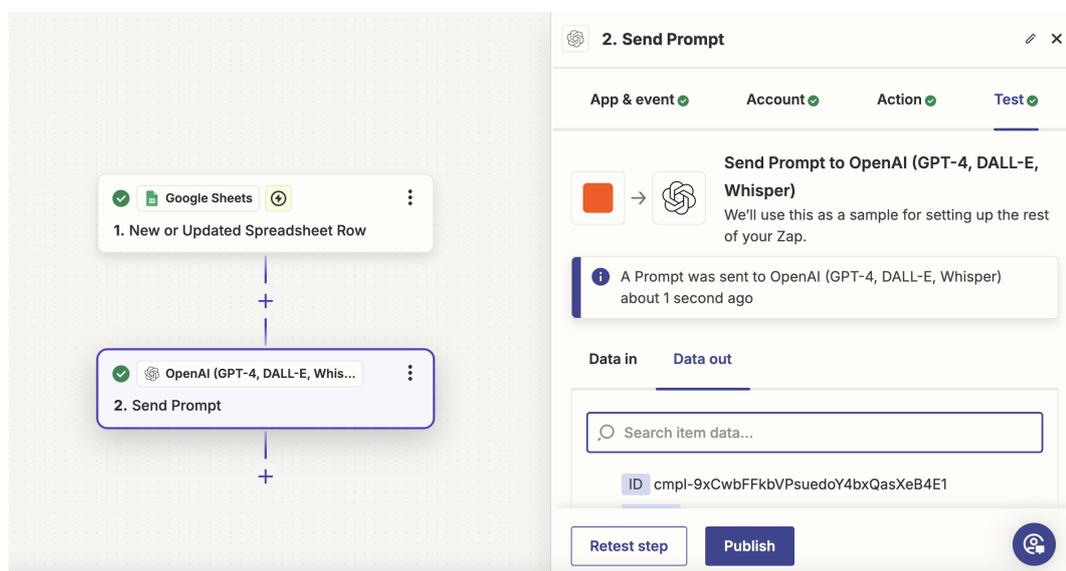


Figura 5.15: Fase de teste do *prompt* para a *string*.

5.1.4 Registro das palavras-chave, termos e sinônimos

A terceira etapa do processo consiste em registrar as palavras-chave, termos e sinônimos gerados pelo ChatGPT 4o em um documento do Google Docs. Essa também é uma ação configurada no Zapier, o final da primeira etapa do processo: pegará a *string* no Google Sheets, enviará para o ChatGPT 4o e, por fim, retornará as respostas no Google Docs, automatizando todo o processo. Quando o ChatGPT 4o processa o *prompt*, as respostas geradas são enviadas ao Google Docs conforme os passos a seguir. Além disso, o Google Docs servirá como um repositório centralizado onde todas as palavras-chave e termos relevantes estarão acessíveis para revisões futuras. Isso facilita a colaboração entre membros da equipe de pesquisa, que podem consultar e editar o documento conforme necessário. A integração entre essas ferramentas garante que o processo seja ágil e organizado, permitindo que os pesquisadores concentrem seus esforços na análise dos resultados. A automação desse fluxo de trabalho não só economiza tempo, mas também assegura que todas as etapas sejam executadas com precisão e consistência, minimizando a chance de erros.

- Primeiramente, selecionar o aplicativo do Google Docs dentro do Zapier, conforme a Figura 5.16;

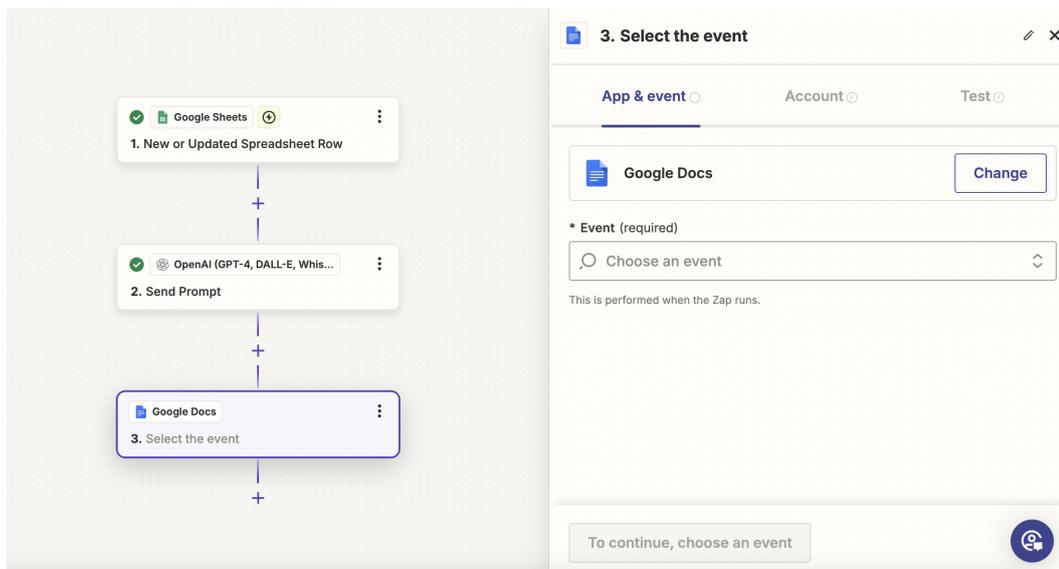


Figura 5.16: Selecionar o aplicativo do Google Docs para a *string*.

- Com o Google Docs selecionado, escolher "Create document from text" como evento,

que por sua vez irá criar um documento com as respostas que forem geradas pelo ChatGPT 4o, como representa a Figura 5.17;

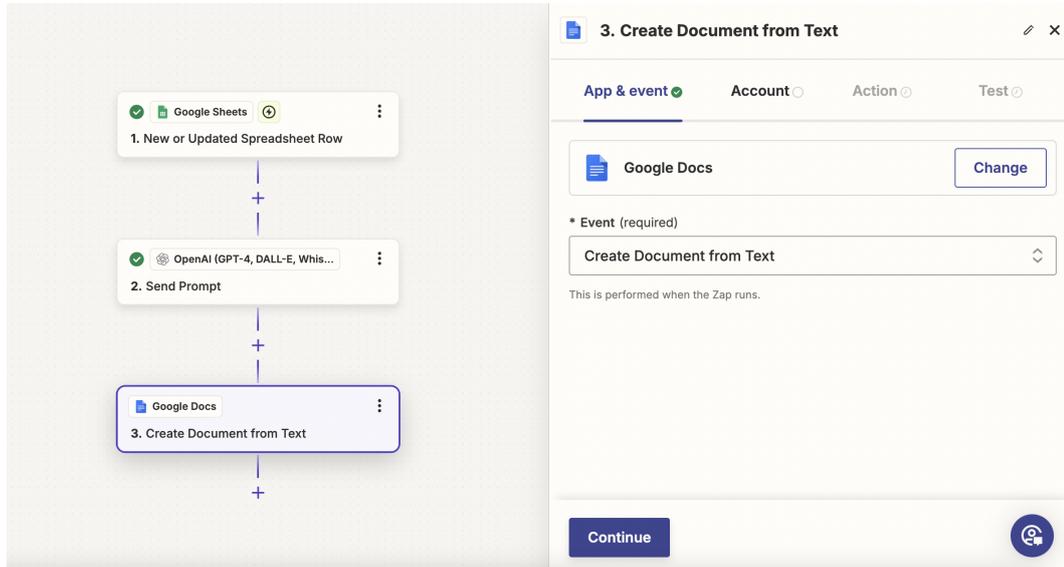


Figura 5.17: Selecionar evento a ser realizado para a *string*.

- Com o Google Docs selecionado é necessário conectar a conta autenticada do Google para permitir que o Zapier retorne as respostas, conforme a Figura 5.18;

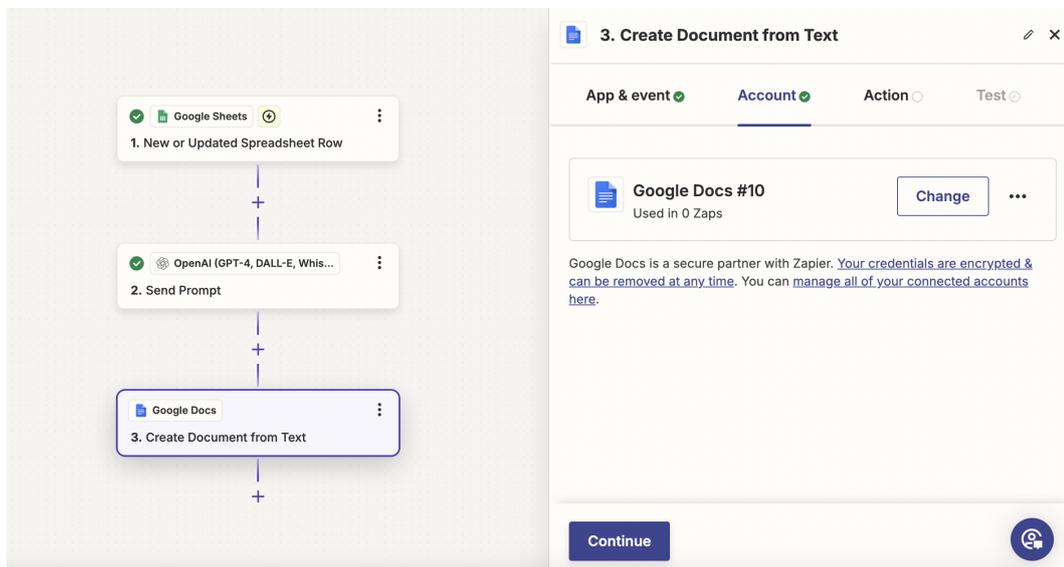


Figura 5.18: Conectar conta autenticada do Google para a *string*.

- Com a conta conectada, o próximo passo será configurar a ação a ser realizada. Assim, nessa etapa, será selecionada a resposta que foi gerada pelo ChatGPT 4o e anexada em um novo documento no Google Docs. Para isso, será necessário nomear

o documento a ser criado e selecionar somente a resposta gerada, como exibido na Figura 5.19;

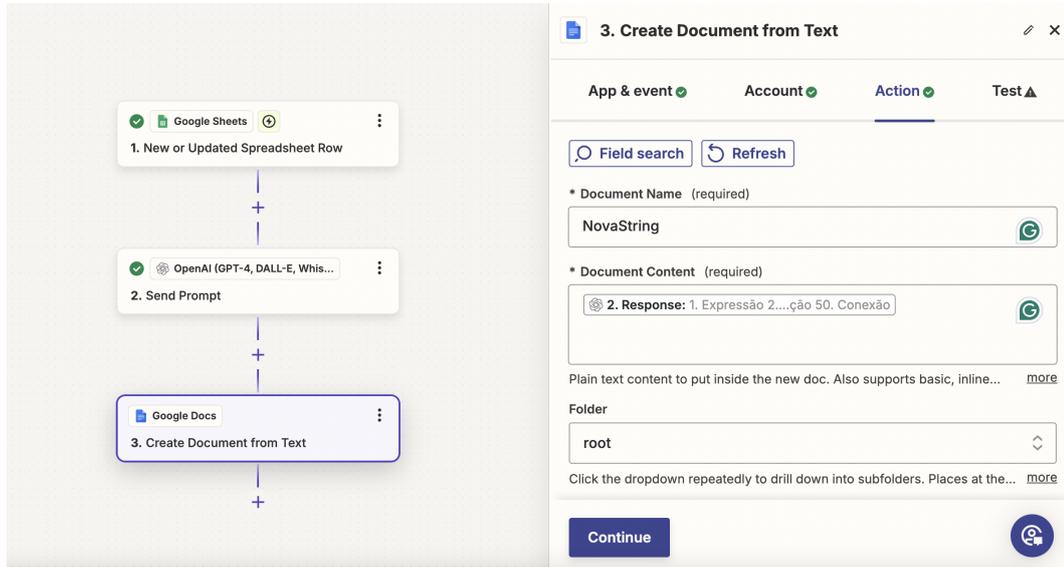


Figura 5.19: Configurar Google Docs para a *string*.

- A fase de teste verifica se a resposta foi anexada corretamente no Google Docs, assim como retrata a Figura 5.20;

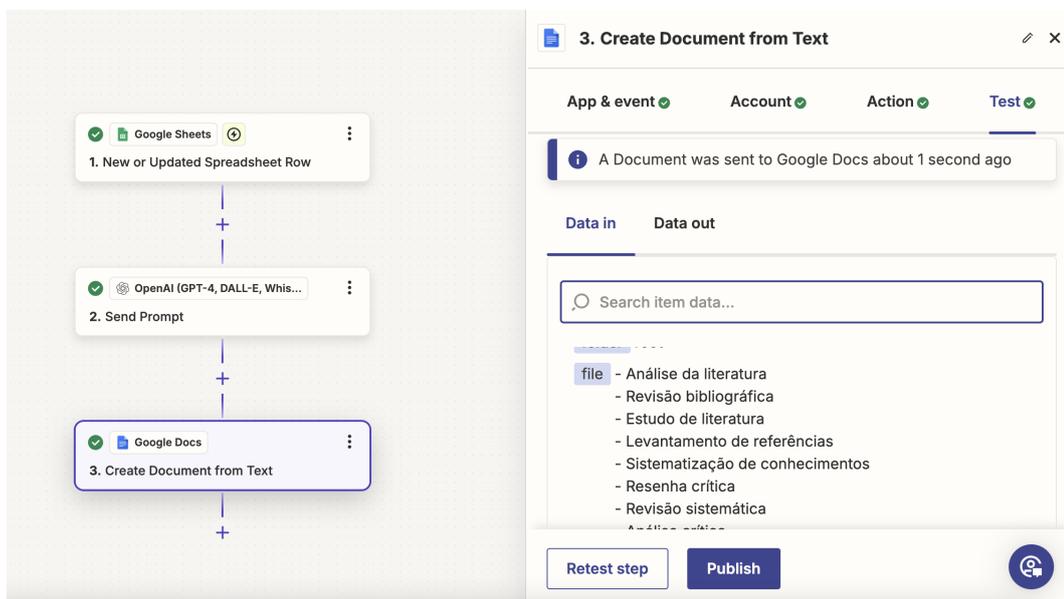


Figura 5.20: Fase de teste das respostas para a *string*.

- Por fim, ao abrir a conta do Google, conectada anteriormente, será possível verificar o novo documento e as palavras-chave, termos e sinônimos que foram gerados pelo

ChatGPT 4o, assim como a Figura 5.21, que indica o fim da primeira etapa do processo.

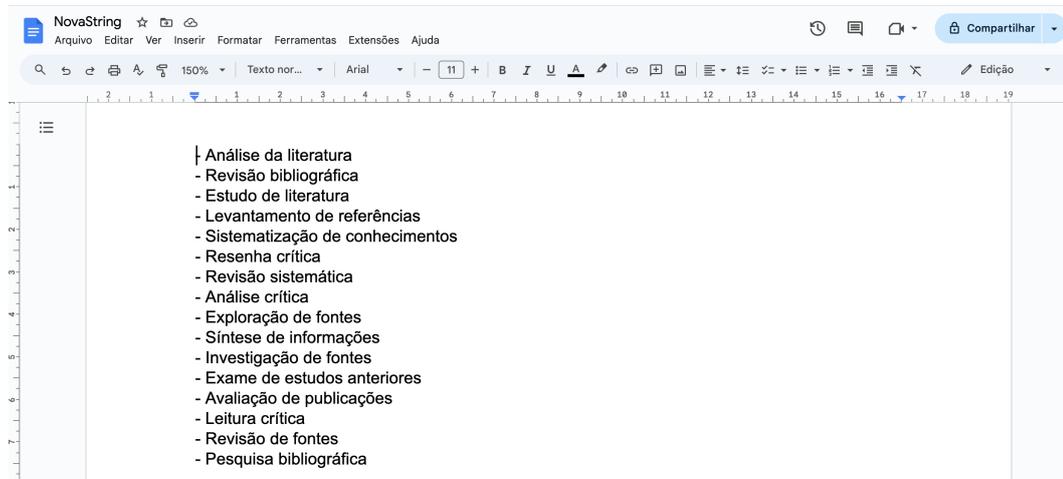


Figura 5.21: Palavras-chave, termos e sinônimos gerados pelo ChatGPT 4o.

5.1.5 Nova *string* de busca

Com as palavras-chave geradas pelo ChatGPT 4o, que utiliza inteligência artificial para identificar termos relevantes, é possível criar de forma manual uma nova *string* de busca mais abrangente. Essa nova *string* pode incorporar novos termos, palavras-chave e sinônimos que podem ter sido previamente omitidos, ampliando o alcance da pesquisa acadêmica.

A utilização do ChatGPT para gerar essas palavras-chave permite identificar termos que estão em uso na literatura atual, mas que poderiam não ter sido considerados na busca inicial. A partir dessas sugestões, a *string* de busca é manualmente ajustada, incorporando os novos termos e sinônimos, o que aumenta a precisão e a abrangência dos resultados obtidos.

Esse processo de refinamento da *string* de busca, auxiliado pela IA, melhora significativamente a capacidade de capturar uma gama mais ampla de publicações relevantes, contribuindo para uma revisão da literatura mais completa e informada. Dessa forma, a *string* foi ajustada para obtenção de novos resultados na pesquisa:

(“literature review”) AND (“systematic mapping” OR “systematic review”) AND (“automated process” OR “automation”) AND (“tool” OR “application” OR “program” OR “soft-

ware”)

Com a nova *string*, é feita a pesquisa de artigos acadêmicos utilizando as palavras-chave geradas pelo ChatGPT. Embora essa etapa seja manual, a precisão das palavras-chave facilita significativamente o processo, resultando em resultados mais relevantes. Para essa pesquisa foi utilizada a base de dados IEEE Xplore, pela sua capacidade de integração e exportação dos arquivos, e obteve-se um resultado de 319 artigos sem passar pelos critérios de inclusão e exclusão, assim como pode-se observar na Figura 5.22.

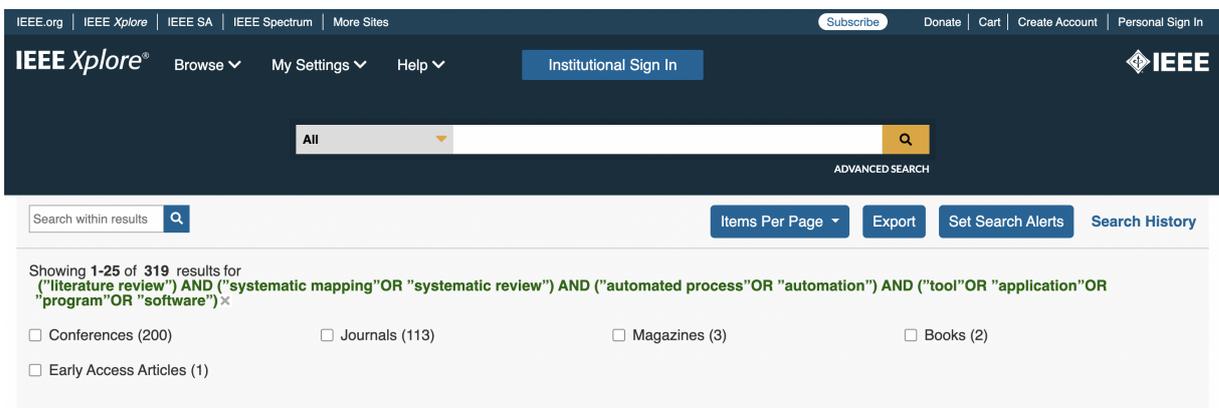


Figura 5.22: Resultados gerados com uso de IA.

A comparação entre as duas *strings* de busca revela diferenças importantes na quantidade e qualidade dos artigos retornados. A *string* antiga, ao focar em termos como *literature review*, *systematic mapping*, *systematic review* e *automated process*, provavelmente resultou em um número menor de artigos, com uma abordagem mais específica e direta para o uso de ferramentas e software em revisões sistemáticas. A ausência do termo *automation* limitou os resultados a estudos que mencionavam explicitamente processos automatizados, proporcionando uma coleção mais homogênea e talvez mais relevante ao contexto de ferramentas específicas.

A nova *string* de busca, ao incluir *automation*, ampliou o escopo e aumentou significativamente a quantidade de artigos retornados. Essa expansão foi positiva, pois permitiu abranger uma diversidade maior de temas e abordagens, possibilitando a descoberta de estudos relevantes que poderiam ter sido omitidos com uma busca mais restrita. A maior diversidade de resultados traz a oportunidade de explorar diferentes aspectos

e aplicações da automação em processos de revisão de literatura, enriquecendo o panorama da pesquisa. Embora isso possa introduzir artigos com um foco menos específico em ferramentas, essa variedade pode ser valiosa, permitindo uma visão mais completa e abrangente das tendências e práticas no campo da automação em revisões sistemáticas. Assim, a triagem dos artigos, apesar de mais exigente, pode resultar em uma seleção final mais rica e alinhada com os objetivos da pesquisa.

Além disso, é necessário que o pesquisador filtre no IEEEExplore os artigos pelos critérios de inclusão e exclusão que são fundamentais para assegurar a qualidade de uma revisão sistemática da literatura, eliminando fontes não científicas ou irrelevantes, como capítulos de livros, chamadas para congressos, materiais didáticos básicos e estudos inacessíveis ou fora do escopo da Ciência da Computação. Definições claras desses critérios não apenas direcionam a seleção de literatura relevante, mas também garantem a integridade e confiabilidade das análises, assegurando que as conclusões da pesquisa sejam baseadas em dados sólidos. A aplicação rigorosa desses critérios, como demonstrado na Tabela 5.1, é importante para o sucesso da pesquisa em áreas como ciência da computação, processos automatizados e inteligência artificial.

Tabela 5.1: Critérios de Inclusão e Exclusão para a nova string.

Inclusão	Artigos contendo estudos experimentais, estudo de caso ou análises sobre automação no contexto de análises estatísticas
	Estudos contendo análise, discussão ou implementação de automação na análise de dados
Exclusão	Capítulos de livro, chamadas a congressos e materiais de ensino básico
	Estudos que não podem ser acessados por inteiro
	Estudos que não abordem o tema na área da Ciência da Computação

5.1.6 Pesquisa de artigos acadêmicos

Nessa etapa os artigos encontrados, depois de passar pelos critérios de inclusão e exclusão, são então baixados pelo IEEEExplore, e suas referências, títulos e *links* são inseridos em uma aba específica de uma planilha do Google Sheets. Essa aba é estruturada para conter todas as informações necessárias sobre cada artigo, facilitando a gestão e organização das referências coletadas. Dessa forma, a Figura 5.23 representa a tabela que já passou pela avaliação dos pesquisadores.

	A	B	C	D	E	F	G	H	I	J	K	L	M	N
1	Document Title	Authors	Author Affiliations	Publication Title	Date Added To Xp	Publication Year	Volume	Issue	Start Page	End Page	Abstract	ISSN	ISBNs	DOI
2	Prioritizing DevOps	M. Zohaib, A. Alsang	Software Engineerin	IEEE Access	23 May 2024	2024	12		71109	71130	The DevOps paradigm	2169-3536		10.1109/ACCESS.2024.0410101
3	Dynamic Security	T. Sutter, T. Kehler	Institute of Comput	IEEE Access	25 Apr 2024	2024	12		57261	57287	Dynamic analysis is	2169-3536		10.1109/ACCESS.2024.0409101
4	Behind the Intent	E. A. AlOmar, M. W.	School of Systems a	IEEE Transactions o	17 Apr 2024	2024	50	4	668	694	Background: Code	1939-3520		10.1109/TSE.2023.3300001
5	Analog Defect Inje	S. Azam, N. Dall'Ora	Department of Com	IEEE Transactions o	22 Dec 2023	2024	43	1	16	29	Since the last centu	1937-4151		10.1109/TCAD.2023.3300001
6	Digital Twin Fram	B. Caesar, K. Barton	Institute of Autom	IEEE Access	20 Nov 2023	2023	11		127364	127387	To remain competi	2169-3536		10.1109/ACCESS.2023.3300001
7	A Review on Busin	L. Bartlett, M. A. Ka	School of Computin	IEEE Access	26 Oct 2023	2023	11		116786	116819	Business Process M	2169-3536		10.1109/ACCESS.2023.3300001
8	Behavior Driven De	M. S. Farooq, U. Or	Department of Artif	IEEE Access	25 Aug 2023	2023	11		88008	88024	Behavior Driven Dev	2169-3536		10.1109/ACCESS.2023.3300001
9	Advancing Process	M. Imran, S. Hamid	Department of Infor	IEEE Access	11 Jul 2023	2023	11		68340	68357	This systematic liter	2169-3536		10.1109/ACCESS.2023.3300001
10	Identifying Factors	G. Melo; N. Nascim	School of Comput	IEEE Access	13 Jun 2023	2023	11		56437	56452	The need to support	2169-3536		10.1109/ACCESS.2023.3300001
11	IoT Capabilities Co	K. Halba; E. Griffo	École doctorale Mat	IEEE Access	30 Mar 2023	2023	11		29959	30007	As billions of IoT de	2169-3536		10.1109/ACCESS.2023.3300001
12	A Systematic Liter	N. Adnan; S. N. H. S	Faculty of Informati	IEEE Access	11 May 2023	2023	11		44806	44827	The rise of the Indus	2169-3536		10.1109/ACCESS.2023.3300001
13	A Systematic Liter	A. Barua; M. U. Ahm	School of Innovatio	IEEE Access	16 Feb 2023	2023	11		14804	14831	Multimodal machine	2169-3536		10.1109/ACCESS.2023.3300001
14	Self-Organization	L. A. Estrada-Jimene	UNINOVA—Centre d	IEEE Access	3 Feb 2023	2023	11		10107	10136	The concept of smar	2169-3536		10.1109/ACCESS.2023.3300001
15	Blockchain Enable	A. Gurzhi; A. K. M. J	Software Engineerin	IEEE Access	4 Aug 2022	2022	10		79584	79605	Digital transformati	2169-3536		10.1109/ACCESS.2022.3300001
16	Student Retention	D. A. Shafiq; M. Mar	School of Computer	IEEE Access	15 Jul 2022	2022	10		72480	72503	Student retention is	2169-3536		10.1109/ACCESS.2022.3300001
17	Operationalizing M	A. B. Kollweit; J. Li	Norwegian Universit	2022 IEEE/ACM 1st	30 Jun 2022	2022			1	8	Deploying machine learning (ML) models	978-1-4503-9319-5		10.1145/3526073.3526073
18	Robot-Based Inter	K. D. Bartl-Pokorny	ElHW-Chair of Emb	IEEE Access	21 Dec 2021	2021	9		165433	165450	Children with autism	2169-3536		10.1109/ACCESS.2021.3300001
19	More Than Two De	A. Shaikh; A. Hafeez	College of Comput	IEEE Access	26 Oct 2021	2021	9		142461	142474	Error checking is es	2169-3536		10.1109/ACCESS.2021.3300001
20	Efficient Automate	D. Bavsikar; S. Ahir	Symbiosis Institute	IEEE Access	21 May 2021	2021	9		72894	72936	The unstructured da	2169-3536		10.1109/ACCESS.2021.3300001
21	Analysis of Navigat	S. Khan; S. Nasir; H	Department of Com	IEEE Access	15 Feb 2021	2021	9		26712	26734	Over the last few de	2169-3536		10.1109/ACCESS.2021.3300001
22	Using Blockchain	J. A. Garcia-Garcia;	Escuela Técnica Sup	IEEE Access	12 Aug 2020	2020	8		142312	142336	Blockchain Technol	2169-3536		10.1109/ACCESS.2020.3300001
23	NFV Data Centers	R. Souza; K. Dias; S	Centro de Inform??	IEEE Access	19 Mar 2020	2020	8		51713	51735	Recently, the widesp	2169-3536		10.1109/ACCESS.2020.3300001
24	Systematic Litera	L. G. D. O. Vêras; F.	Associate Laborator	IEEE Access	24 Apr 2019	2019	7		50933	50953	Path planning is on	2169-3536		10.1109/ACCESS.2019.3300001

Figura 5.23: Arquivo Google Sheets com os artigos a serem analisados.

Com a planilha no Google Sheets, um novo processo será iniciado no Zapier. Na página inicial do Zapier, será configurada uma nova *trigger*, tendo o Google Sheets como o ponto de partida. Esse processo automatizado será acionado sempre que houver uma atualização na planilha, garantindo que as etapas subsequentes sejam executadas de forma eficiente. Para configurar este processo, o pesquisador deve:

- Primeiramente, selecionar o aplicativo do Google Sheets dentro do Zapier como o aplicativo de origem, conforme a Figura 5.24;

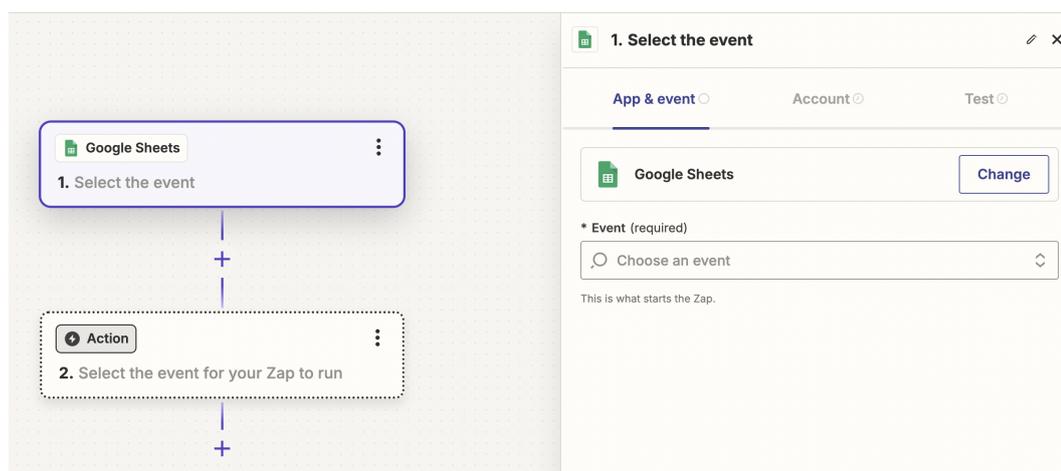


Figura 5.24: Selecionar Google Sheets no Zapier para gerar resumos.

- Com o Google Sheets selecionado, escolher "New or Updated Spreadsheet Row" como evento, refere-se a um gatilho que inicia um fluxo de trabalho automatizado sempre

que uma nova linha é adicionada ou uma linha existente é atualizada na planilha, conforme a Figura 5.25;

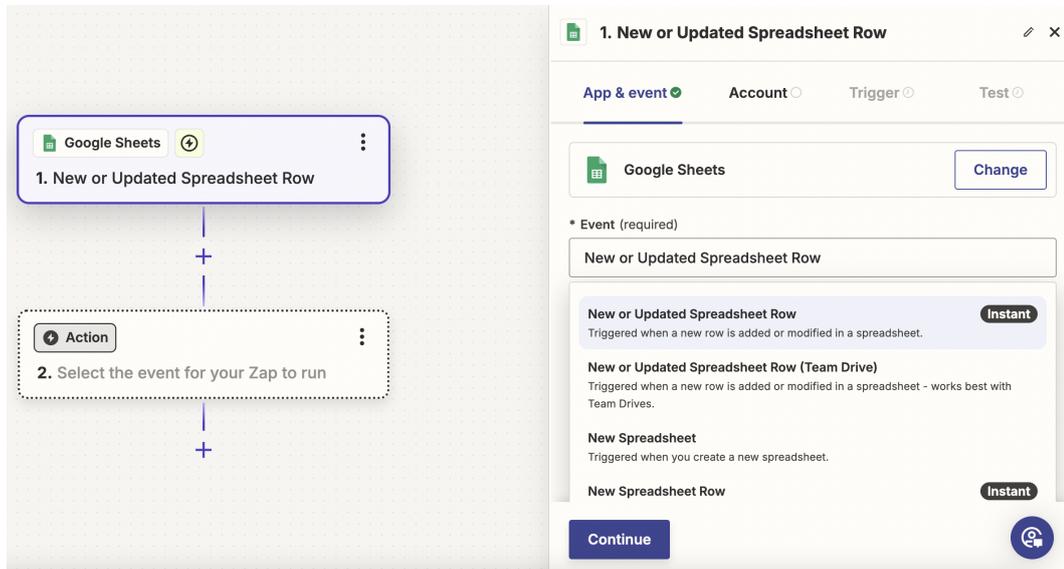


Figura 5.25: Selecionar evento a ser realizado para gerar resumos.

- Com o Google Sheets selecionado é necessário conectar a conta autenticada do Google para permitir o acesso do Zapier aos dados da planilha, conforme a Figura 5.26;

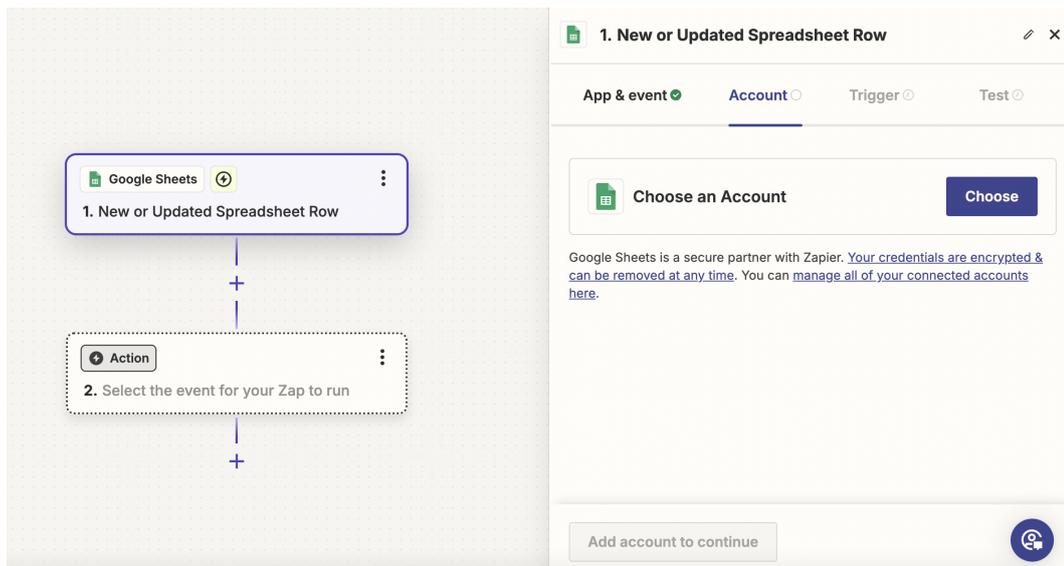


Figura 5.26: Conectar conta autenticada do Google para gerar resumos.

- O passo a seguir é configurar a planilha, preenchendo as lacunas *spreadsheet* que é a planilha a ser utilizada, *worksheet* a página da planilha que contém a os artigos

que serão pesquisados pesquisa e *trigger column* que é a coluna a ser analisada, conforme a Figura 5.27;

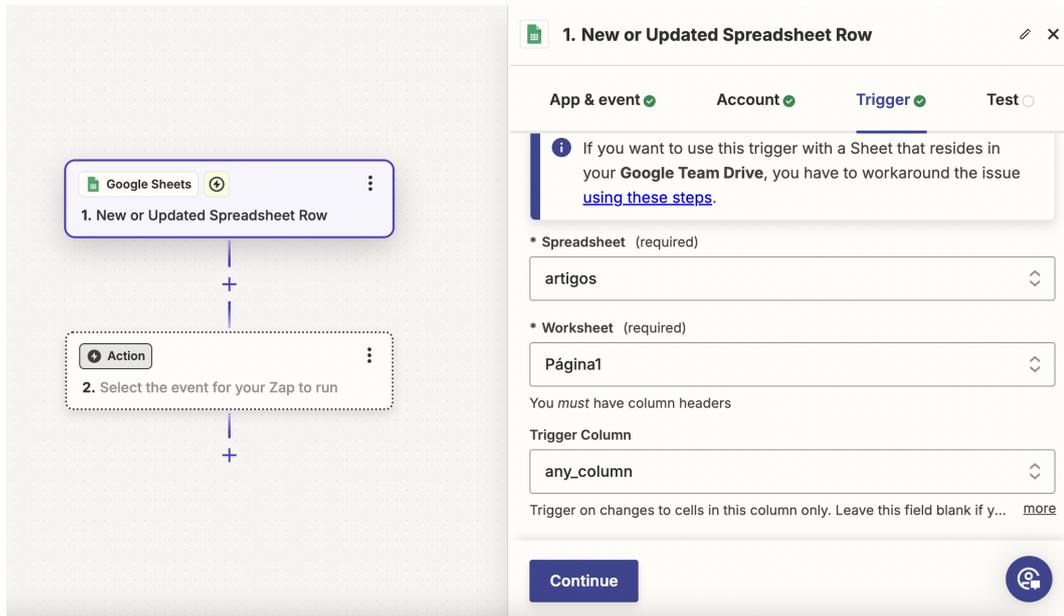


Figura 5.27: Configuração da planilha no Zapier para gerar resumos.

- Por fim, a fase de teste verifica se a planilha, página e coluna estão certas para poder dar continuidade no processo, de acordo com a Figura 5.28.

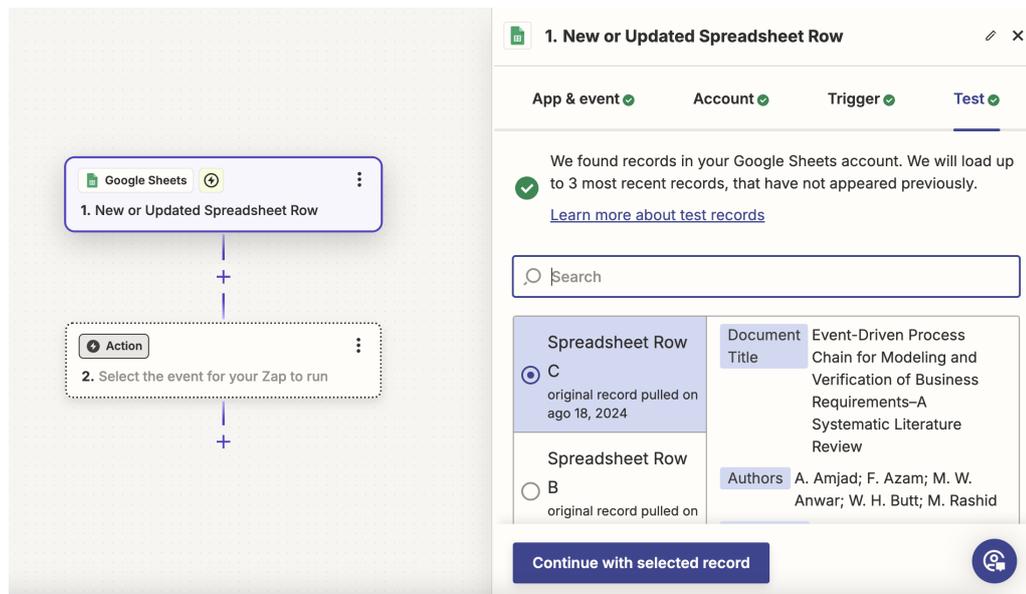


Figura 5.28: Fase de teste da planilha para gerar resumos.

5.1.7 Sumarização dos artigos

Nessa etapa, os artigos registrados no Google Sheets e integrados com o Zapier são enviados ao ChatGPT, que será responsável por gerar um resumo detalhado de cada um. Após o Zapier detectar as novas entradas na aba designada, é acionada uma *action* que encaminha as informações do artigo do Google Sheets para o ChatGPT. O ChatGPT, então, processa essas informações e elabora resumos detalhados, permitindo que os pesquisadores compreendam de forma rápida e aprofundada a relevância e os principais pontos de cada estudo. Esses resumos são fundamentais para facilitar a análise crítica dos artigos, otimizando o processo de revisão da literatura. O resumo gerado é então automaticamente inserido em um documento, onde pode ser revisado pelos pesquisadores. Finalmente, todos os resumos são organizados e armazenados, prontos para serem utilizados nas próximas fases da revisão da literatura. Essa automatização não só acelera o processo de análise, mas também garante que todos os artigos sejam tratados de forma uniforme e sistemática, reduzindo significativamente o risco de inconsistências ou erros humanos. Esse passo é feito seguindo as seguintes etapas:

- Primeiramente, selecionar o aplicativo da OpenAI dentro do Zapier, conforme a Figura 5.29;

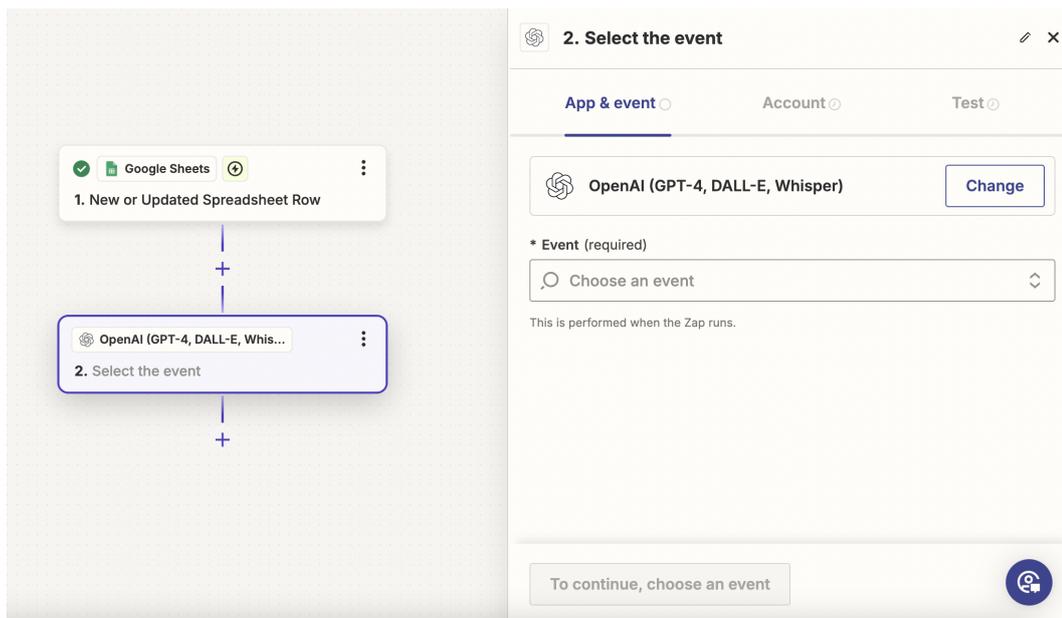


Figura 5.29: Selecionar o aplicativo da Open AI no Zapier para gerar resumos.

- Com o Open AI selecionado, escolher "Send Prompt" como evento, que por sua vez irá enviar as informações do artigo para receber um resumo detalhado, assim como na Figura 5.30;

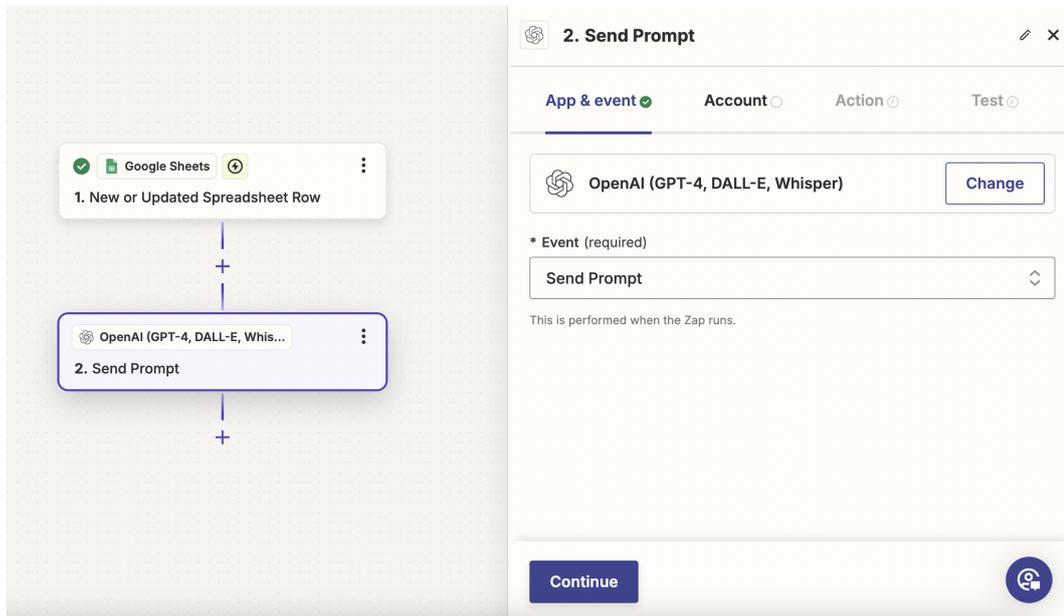


Figura 5.30: Selecionar evento a ser realizado para gerar resumos.

- Com o Open AI selecionado é necessário conectar a conta da Open AI para permitir que o Zapier consiga fazer a conexão, como representado na Figura 5.31;

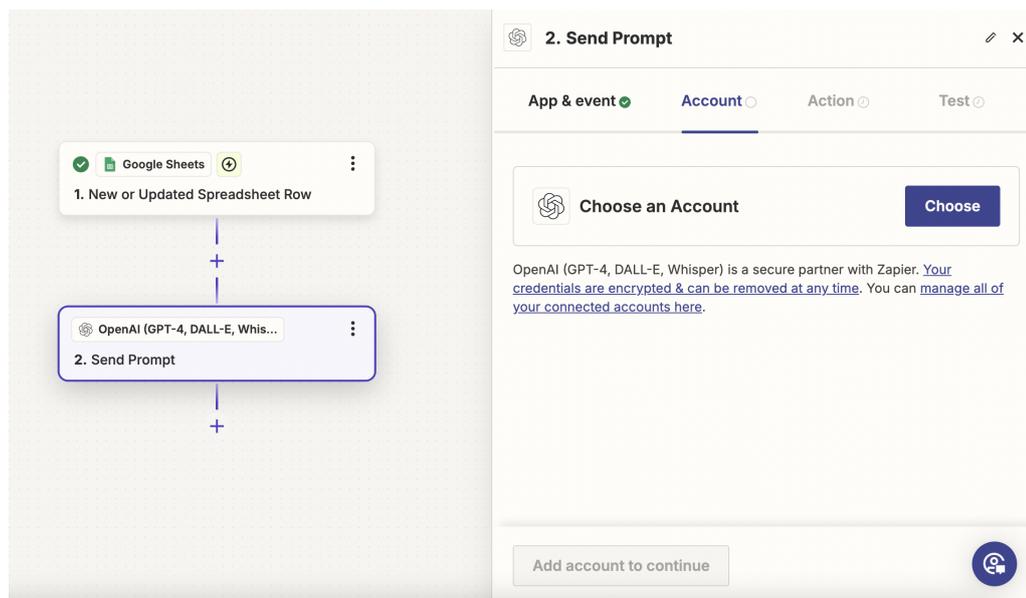


Figura 5.31: Conectar conta da Open AI para gerar resumos.

- Com a conta conectada, o próximo passo será configurar o *prompt*, que será a ação

a ser realizada. Nessa etapa serão enviadas ao Chat GPT 4o as informações sobre o artigo a ser analisado e o *prompt* será configurado para retornar um resumo sobre o artigo, assim como na Figura 5.32;

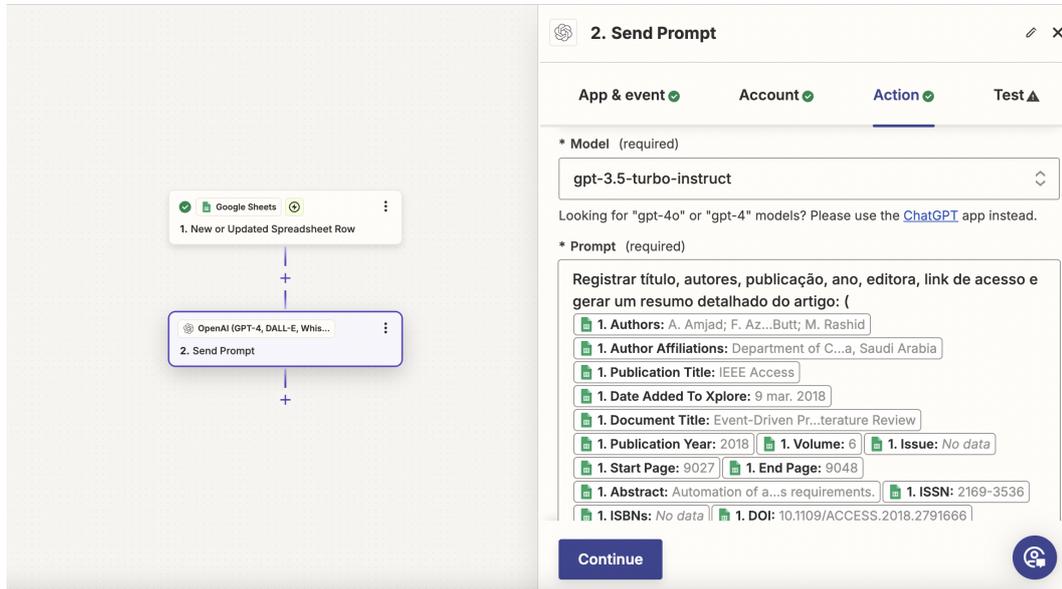


Figura 5.32: Configuração do *prompt* para gerar resumos.

- Por fim, a fase de teste verifica se o *prompt* foi enviado corretamente para que gere as respostas corretas, assim como retrata a Figura 5.33.

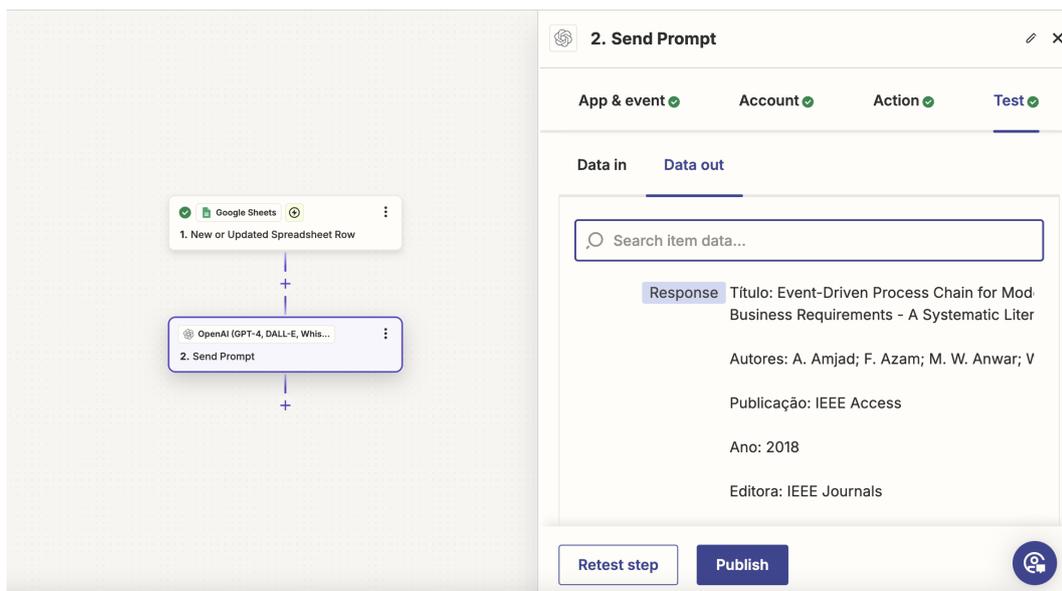


Figura 5.33: Fase de teste do *prompt* para gerar resumos.

5.1.8 Consolidação das respostas

A consolidação das respostas é a etapa seguinte do processo. Para garantir que todas as respostas geradas pelo ChatGPT estejam centralizados e acessíveis, configura-se uma *action* no Zapier que transfere automaticamente essas respostas para um documento no Google Docs. Esse documento consolidado oferece uma visão abrangente de todos os artigos, facilitando a revisão e análise por parte dos pesquisadores. O Google Docs é escolhido por suas capacidades de colaboração em tempo real e por suas ferramentas de edição e formatação de texto, tornando-o ideal para o trabalho em equipe.

Será utilizado um único documento no Google Docs para centralizar todos os resumos gerados, garantindo organização e fácil acesso. Esse documento deve ser criado previamente, permitindo que cada novo resumo seja automaticamente inserido na ordem correta. A cada nova linha adicionada na planilha do Google Sheets, o processo é reiniciado automaticamente, com o Zapier acionando o fluxo de trabalho para gerar e adicionar o novo resumo ao documento. Essa abordagem centralizada facilita a revisão e assegura que todas as informações estejam organizadas de maneira eficiente. Para isso, é necessário seguir os seguintes passos:

- Primeiramente, selecionar o aplicativo do Google Docs dentro do Zapier, conforme a Figura 5.34;

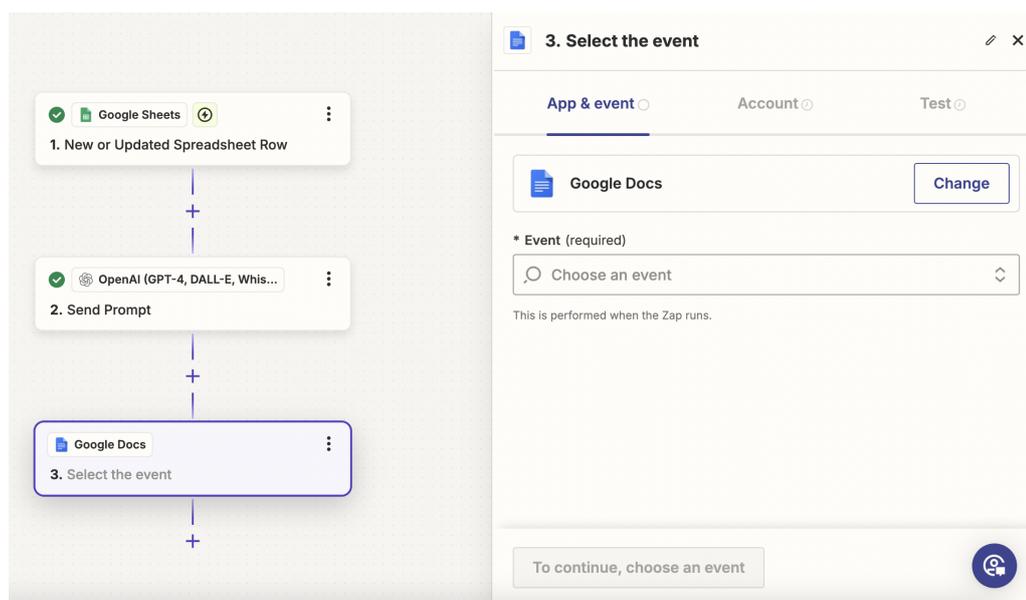


Figura 5.34: Selecionar o aplicativo do Google Docs para gerar resumos.

- Com o Google Docs selecionado, escolher "Append text to document" como evento, que por sua vez irá acrescentar em um documento com as respostas que forem geradas pelo ChatGPT 4o, como representa a Figura 5.35;

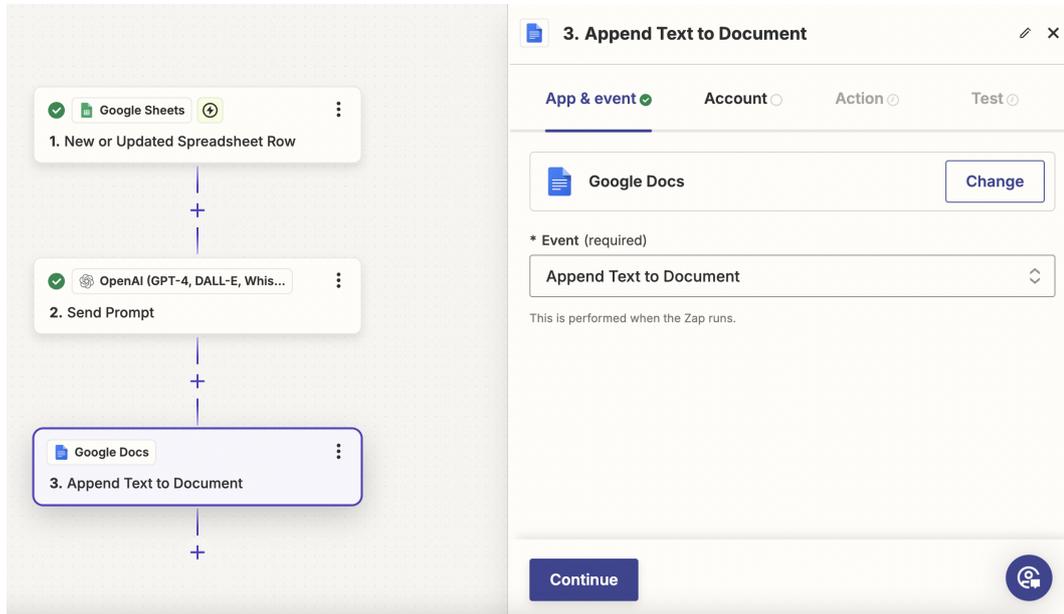


Figura 5.35: Selecionar evento a ser realizado para gerar resumos.

- Com o Google Docs selecionado é necessário conectar a conta autenticada do Google para permitir que o Zapier retorne as respostas, conforme a Figura 5.36;

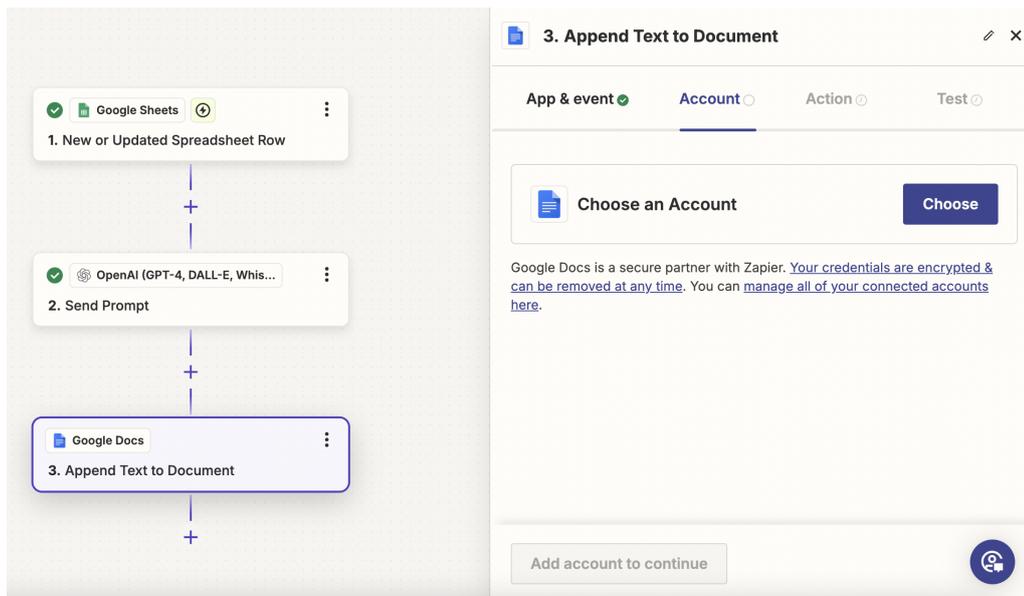


Figura 5.36: Conectar conta autenticada do Google para gerar resumos.

- Com a conta conectada, o próximo passo será configurar a ação a ser realizada.

Assim, nessa etapa, será selecionada a resposta que foi gerada pelo ChatGPT 4o e anexá-la em um documento já existente no Google Docs, informando o nome do documento, assim como na Figura 5.37;

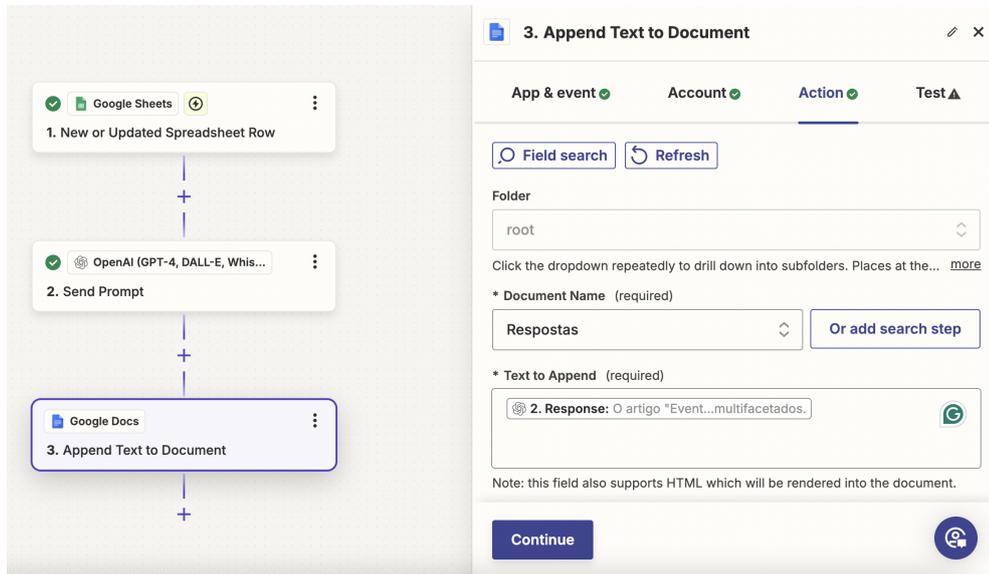


Figura 5.37: Configurar Google Docs para gerar resumos.

- A fase de teste verifica se a resposta foi anexada corretamente no Google Docs, assim como retrata a Figura 5.38;

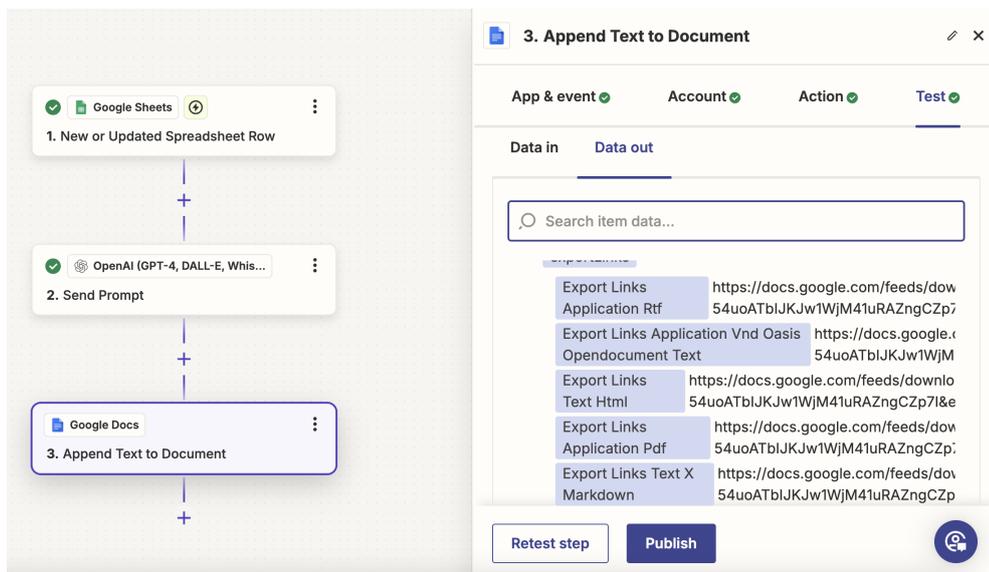


Figura 5.38: Fase de teste respostas para gerar resumos.

- Por fim, ao abrir a conta do Google, conectada anteriormente, será possível verificar no documento, os resumos e as informações sobre o artigo, autores, ano e editora,

que foram gerados pelo ChatGPT 4o, assim como a Figura 5.39, que indica o fim do processo.

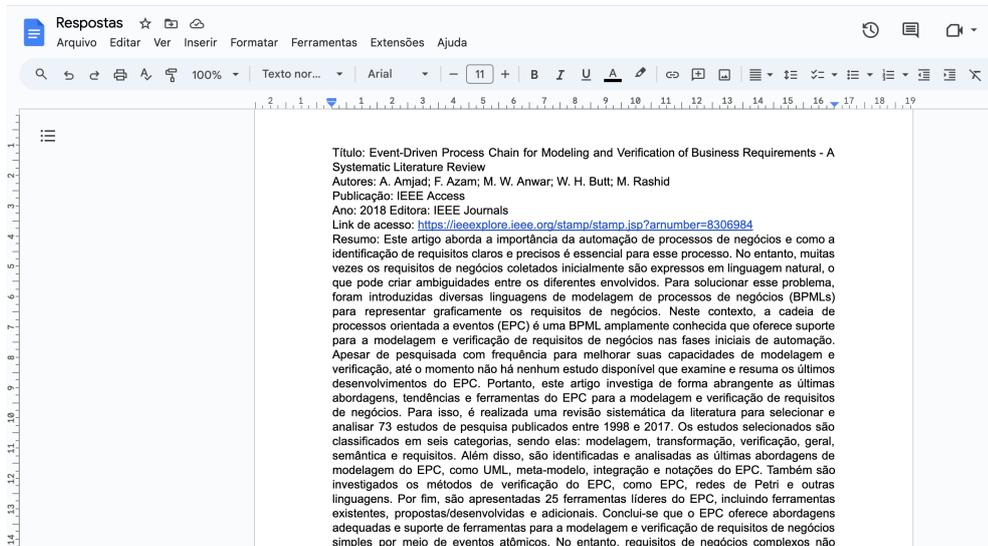


Figura 5.39: Resumo gerado pelo Chat GPT 4o.

5.1.9 Avaliação da qualidade dos artigos

A avaliação da qualidade dos artigos é significativo para uma pesquisa científica robusta e confiável. Esse processo envolve a análise criteriosa dos artigos selecionados, garantindo que as fontes utilizadas sejam de alta qualidade e relevantes para o tema estudado. A qualidade dos artigos pode ser avaliada por critérios como originalidade, clareza na apresentação dos dados, adequação metodológica, profundidade da revisão de literatura e contribuição ao campo do conhecimento.

Após a aplicação dos critérios de inclusão e exclusão, dos artigos inicialmente importados de bases de dados digitais, foi selecionado um grupo final utilizado na pesquisa. Esse processo rigoroso de filtragem garante que apenas os estudos mais relevantes sejam considerados, fortalecendo a pesquisa.

Durante a avaliação, é importante verificar se os artigos foram publicados em revistas ou conferências de renome, indexadas em bases de dados reconhecidas, como o IEEEEXplore, que foi utilizado nesta pesquisa.

Nessa etapa, um novo processo é inicializado no Zapier, usando novamente a planilha baixada do Google Sheets com os artigos encontrados no IEEEEXplore. Dessa forma,

o Google Sheets será usado como *trigger*, ponto inicial do processo. Esse procedimento visa sistematizar a análise, permitindo uma organização eficaz das informações coletadas e facilitando a aplicação de critérios de qualidade. Para isso, segue os seguintes passos:

- Primeiramente, selecionar o aplicativo do Google Sheets dentro do Zapier como o aplicativo de origem, conforme a Figura 5.40;

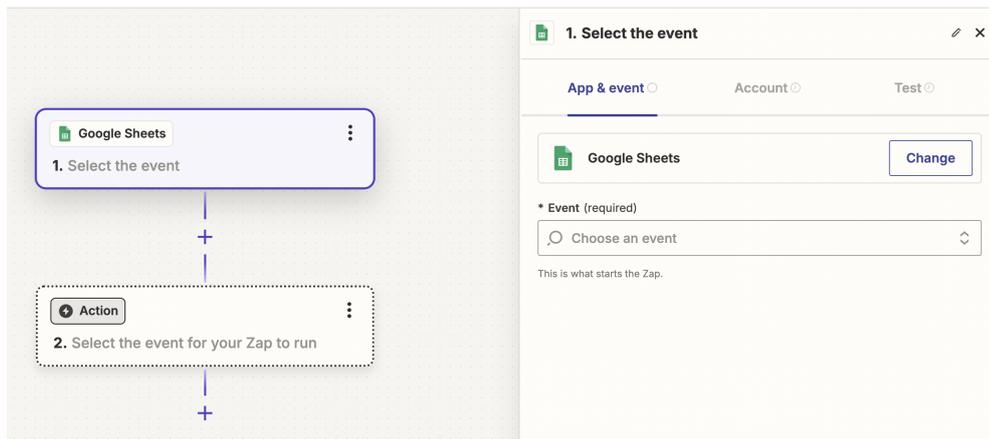


Figura 5.40: Selecionar Google Sheets no Zapier para avaliação de artigos.

- Com o Google Sheets selecionado, escolher "New or Updated Spreadsheet Row" como evento, refere-se a um gatilho que inicia um fluxo de trabalho automatizado sempre que uma nova linha é adicionada ou uma linha existente é atualizada na planilha, conforme a Figura 5.41;

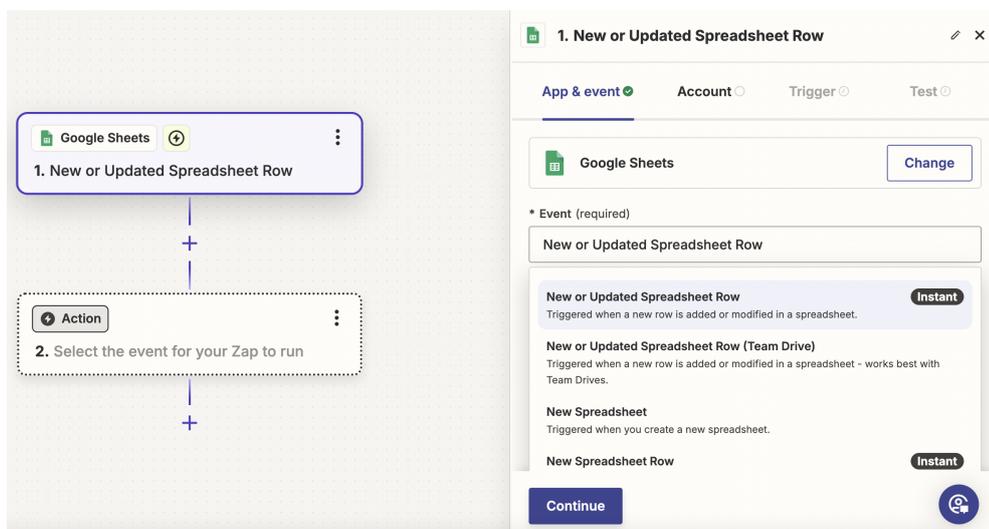


Figura 5.41: Selecionar evento a ser realizado para avaliação de artigos.

- Com o Google Sheets selecionado é necessário conectar a conta autenticada do Google para permitir o acesso do Zapier aos dados da planilha, conforme a Figura 5.42;

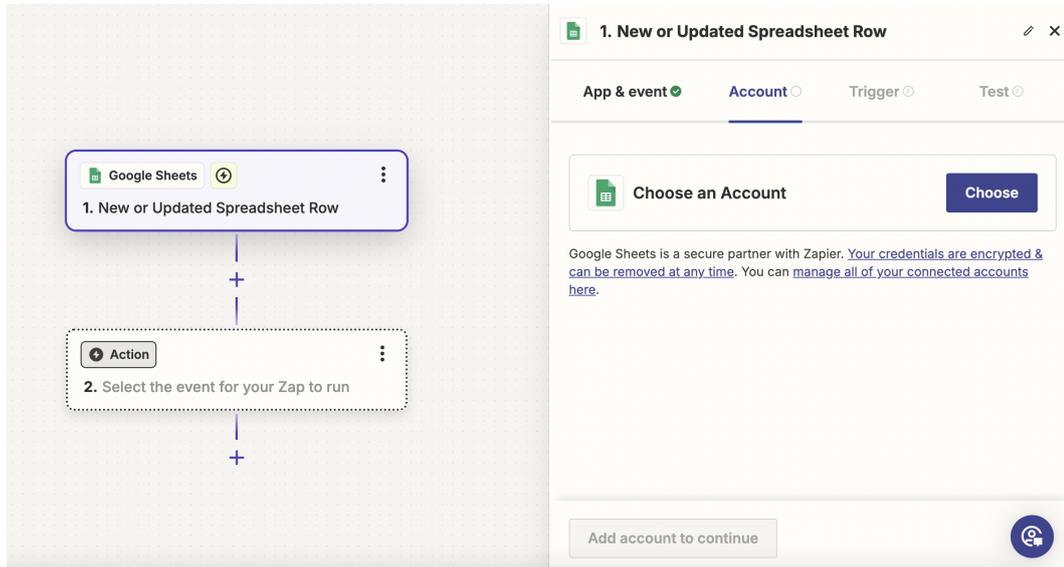


Figura 5.42: Conectar conta autenticada do Google para avaliação de artigos.

- O passo a seguir é configurar a planilha, preenchendo as lacunas *spreadsheet* que é a planilha a ser utilizada, *worksheet* a página da planilha que contém a questão de pesquisa e *trigger column* que é a coluna a ser analisada, conforme a Figura 5.43;

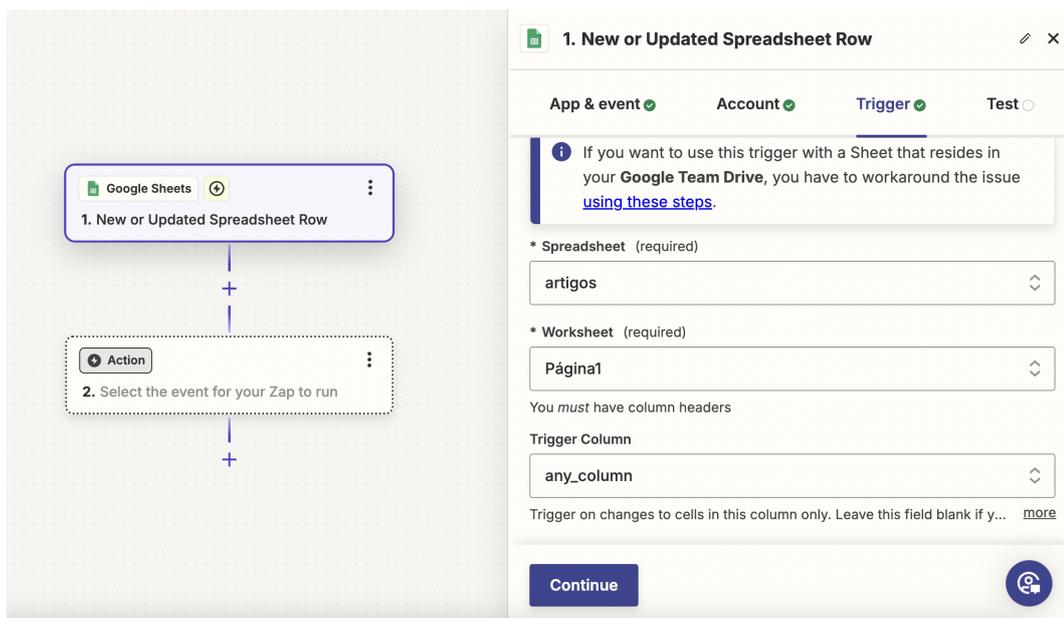


Figura 5.43: Configuração da planilha no Zapier para avaliação de artigos.

- Por fim, a fase de teste verifica se a planilha, página e coluna estão certas para poder dar continuidade no processo, de acordo com a Figura 5.44.

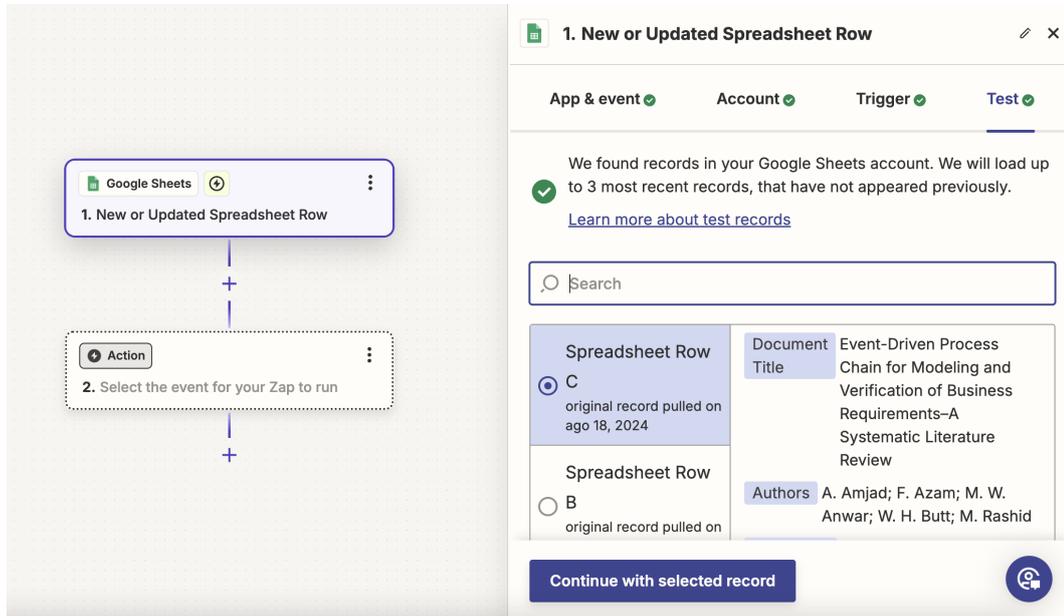


Figura 5.44: Fase de teste da planilha para avaliação de artigos.

5.1.10 Escala de Likert

Nessa etapa, os artigos registrados no Google Sheets e integrados com o Zapier são enviados ao ChatGPT, que aplicará a Escala de Likert (CUNHA, 2007) para avaliar cada artigo. A Escala de Likert mede atitudes, opiniões ou percepções, permitindo que os respondentes expressem seu grau de concordância ou discordância em relação a uma série de afirmações, atribuindo valores numéricos para facilitar a análise quantitativa.

Após o Zapier detectar as novas entradas no Google Sheets, uma ação é acionada, enviando as informações do artigo para o ChatGPT, que aplica a Escala de Likert para avaliar aspectos como clareza, metodologia, relevância da revisão de literatura e contribuição científica. Essa avaliação é utilizada para determinar a qualidade dos artigos e garantir que apenas os estudos mais relevantes sejam considerados.

A automação desse processo não apenas acelera a análise dos artigos, mas também assegura que todos sejam tratados de maneira uniforme e sistemática. Esse passo é feito seguindo as seguintes etapas:

- Primeiramente, selecionar o aplicativo da OpenAI dentro do Zapier, conforme a

Figura 5.45;

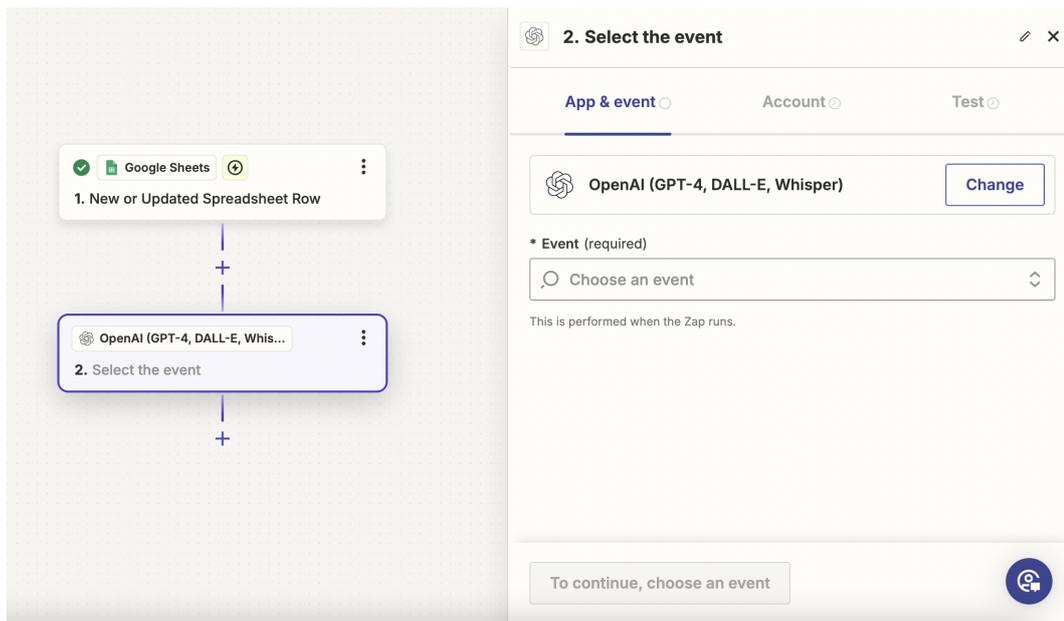


Figura 5.45: Selecionar o aplicativo da Open AI no Zapier para avaliação de artigos.

- Com o Open AI selecionado, escolher *"Send Prompt"* como evento, que por sua vez irá enviar as informações do artigo para avaliar corretamente na escala de Likert, assim como na Figura 5.46;

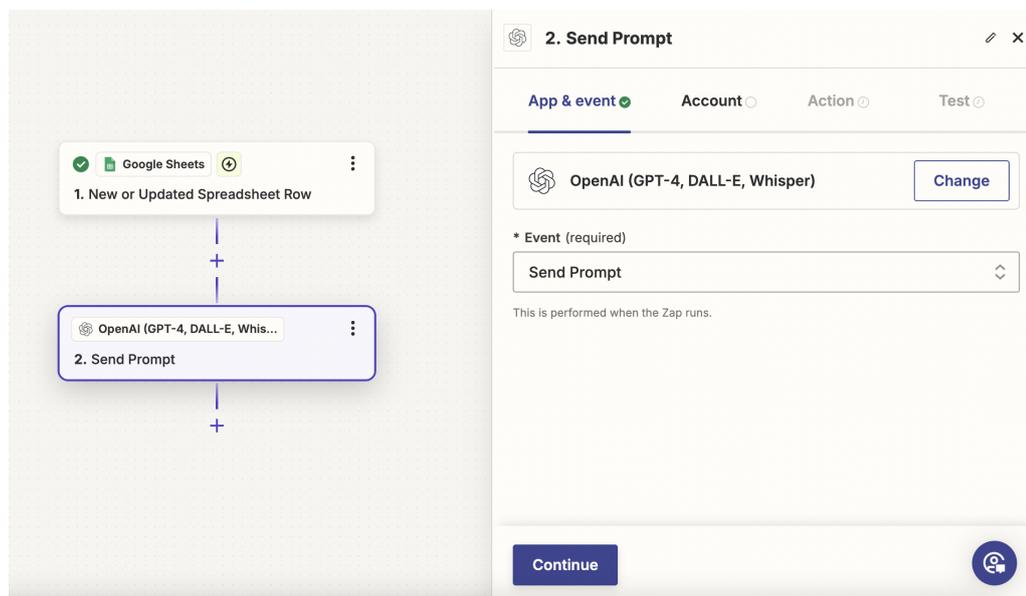


Figura 5.46: Selecionar evento a ser realizado para avaliação de artigos.

- Com o Open AI selecionado é necessário conectar a conta da Open AI para permitir que o Zapier consiga fazer a conexão, como representado na Figura 5.47;

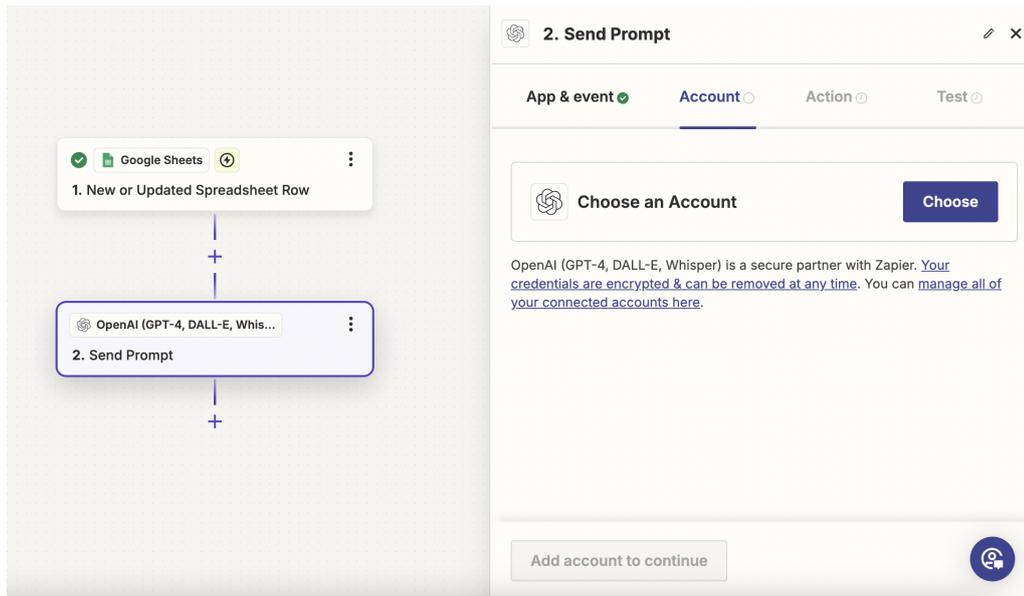


Figura 5.47: Conectar conta da Open AI para avaliação de artigos.

- Com a conta conectada, o próximo passo será configurar o *prompt*, que será a ação a ser realizada. Nessa etapa será enviada ao Chat GPT 4o as informações sobre o artigo a ser analisado e o *prompt* será configurado para retornar um resumo sobre o artigo, assim como na Figura 5.48;

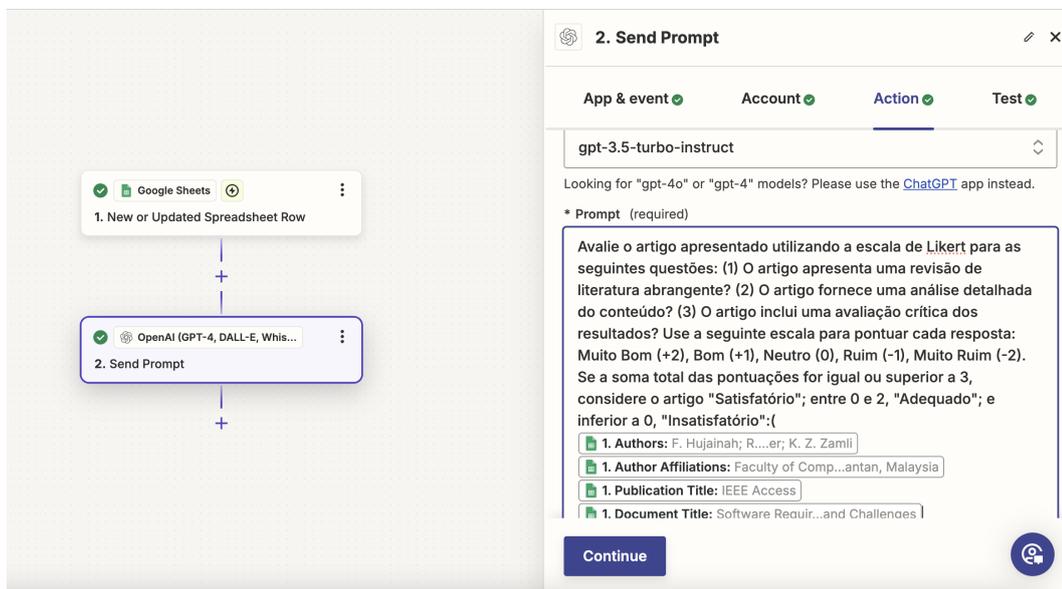


Figura 5.48: Configuração do *prompt* para avaliação de artigos.

- Por fim, a fase de teste verifica se o *prompt* foi enviado corretamente para que gere as respostas corretas, assim como retrata a Figura 5.49.

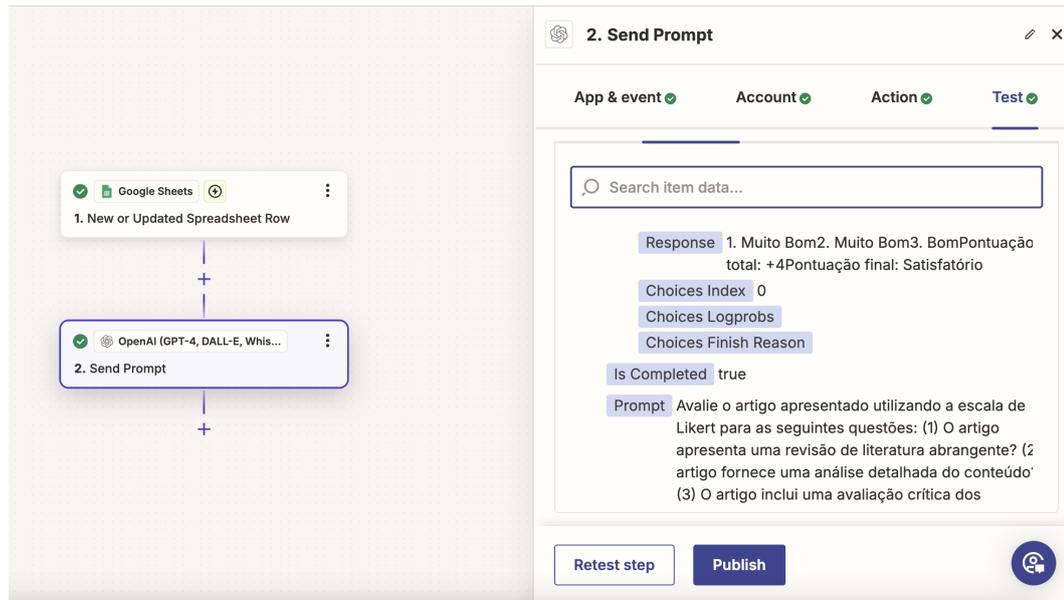


Figura 5.49: Fase de teste do *prompt* para avaliação de artigos.

5.1.11 Consolidação da avaliação

A consolidação das respostas de avaliação é a etapa seguinte do processo. Para garantir que todas as respostas geradas pelo ChatGPT estejam centralizadas e acessíveis, configura-se uma action no Zapier que transfere automaticamente essas respostas para um documento no Google Docs. Esse documento consolidado oferece uma visão abrangente de todos os artigos, facilitando a revisão e análise por parte dos pesquisadores. Será utilizado um único documento no Google Docs para centralizar todas as avaliações geradas, garantindo organização e fácil acesso. Esse documento deve ser criado previamente, permitindo que cada nova avaliação seja automaticamente inserida na ordem correta.

Dessa forma, a cada nova linha adicionada na planilha do Google Sheets, o Zapier detecta automaticamente a atualização e aciona o fluxo de trabalho para avaliar os artigos e consolidar suas respostas no Google Docs. Ao automatizar as avaliações dos artigos, o Zapier assegura que o processo seja eficiente e consistente, centralizando todas as informações de maneira organizada e facilitando a revisão por parte dos pesquisadores. Para implementar essa abordagem, é necessário seguir os seguintes passos:

- Primeiramente, selecionar o aplicativo do Google Docs dentro do Zapier, conforme a Figura 5.50;

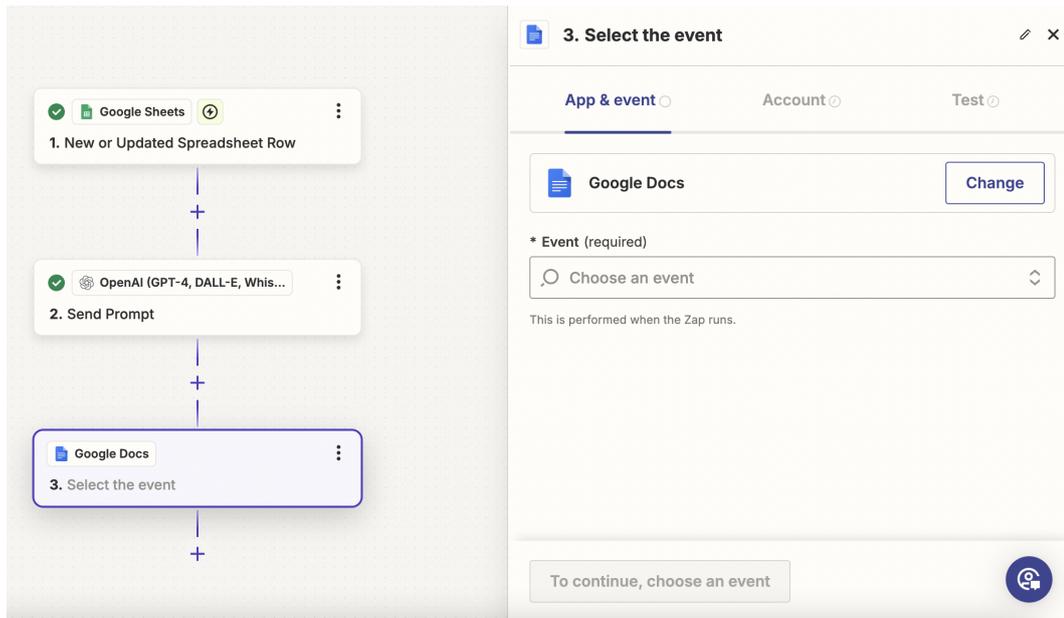


Figura 5.50: Selecionar o aplicativo do Google Docs para avaliação de artigos.

- Com o Google Docs selecionado, escolher *"Append text to document"* como evento, que por sua vez irá acrescentar em um documento com as respostas que forem geradas pelo ChatGPT 4o, como representa a Figura 5.51;

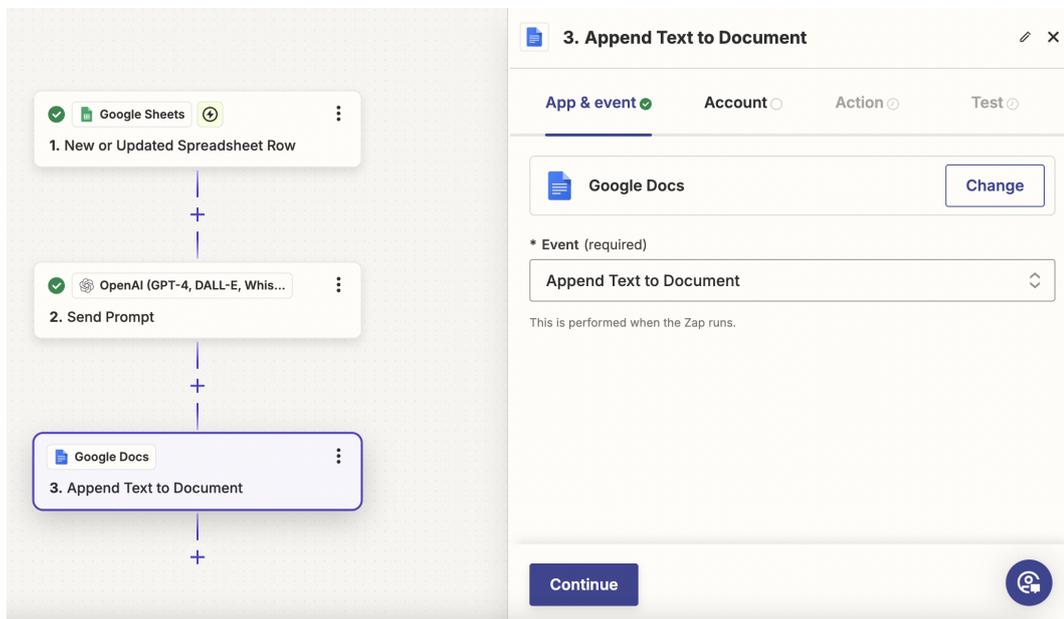


Figura 5.51: Selecionar evento a ser realizado para avaliação de artigos.

- Com o Google Docs selecionado é necessário conectar a conta autenticada do Google para permitir que o Zapier retorne as respostas, conforme a Figura 5.52;

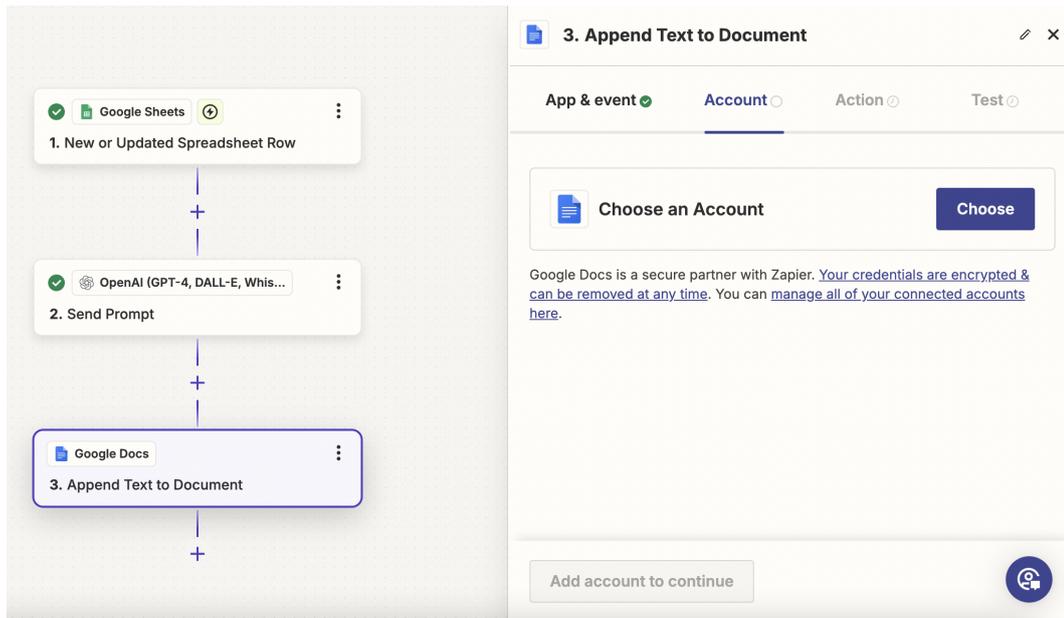


Figura 5.52: Conectar conta autenticada do Google para avaliação de artigos.

- Com a conta conectada, o próximo passo será configurar a ação a ser realizada. Assim, nessa etapa, será selecionada a resposta que foi gerada pelo ChatGPT 4o e anexá-la em um documento já existente no Google Docs, informando o nome do documento, assim como na Figura 5.53;

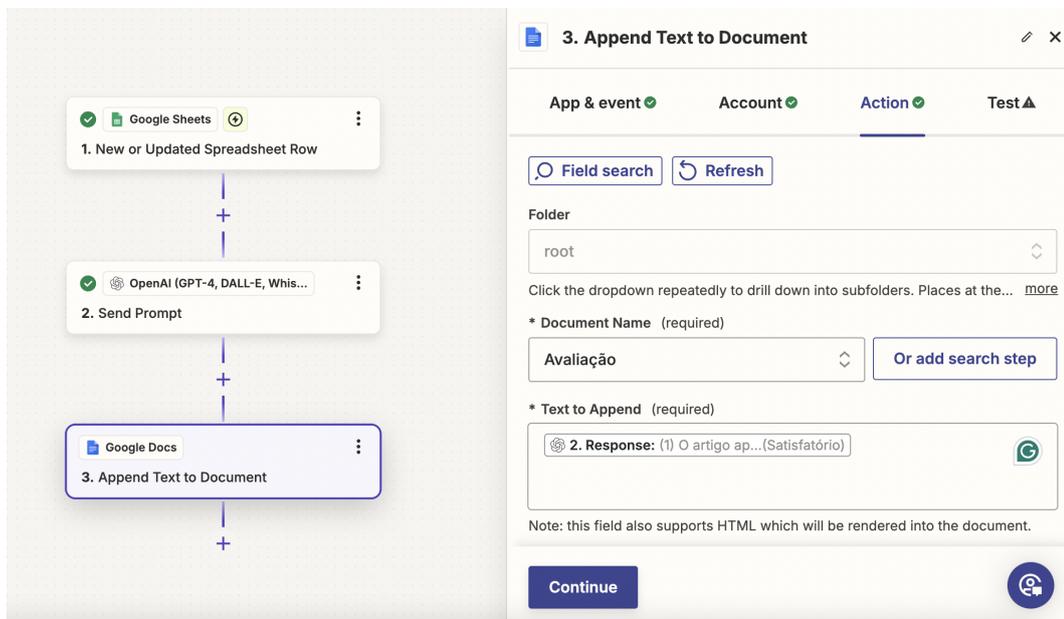


Figura 5.53: Configurar Google Docs para avaliação de artigos.

- A fase de teste verifica se a resposta foi anexada corretamente no Google Docs, assim como retrata a Figura 5.54;

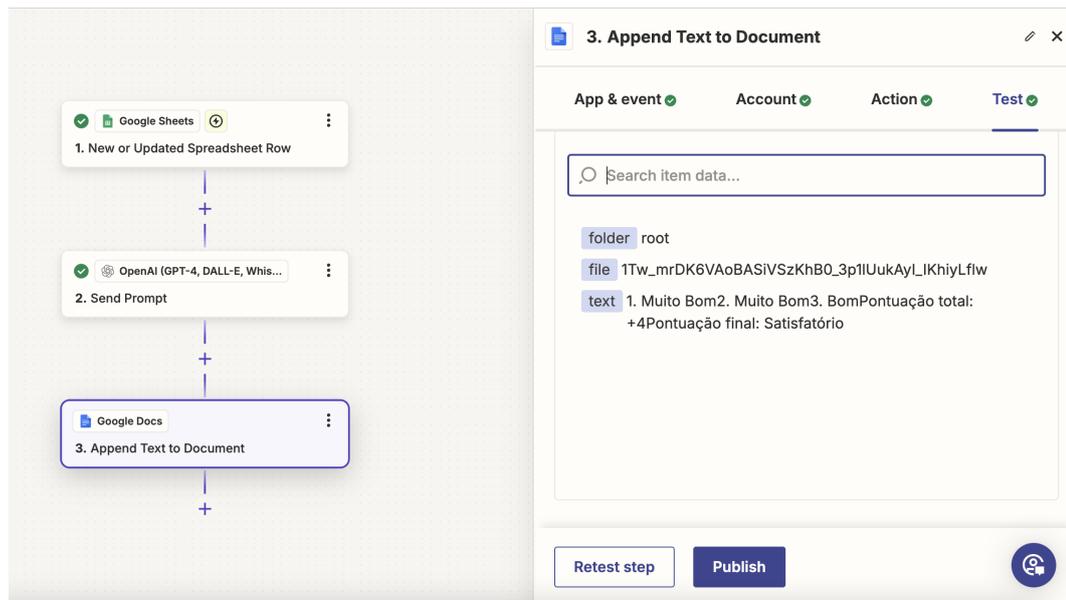


Figura 5.54: Fase de teste respostas para avaliação de artigos.

- Por fim, ao abrir a conta do Google, conectada anteriormente, será possível verificar no documento e as as avaliações que foram geradas pelo ChatGPT 4o, assim como a Figura 5.55, que indica o fim do processo.

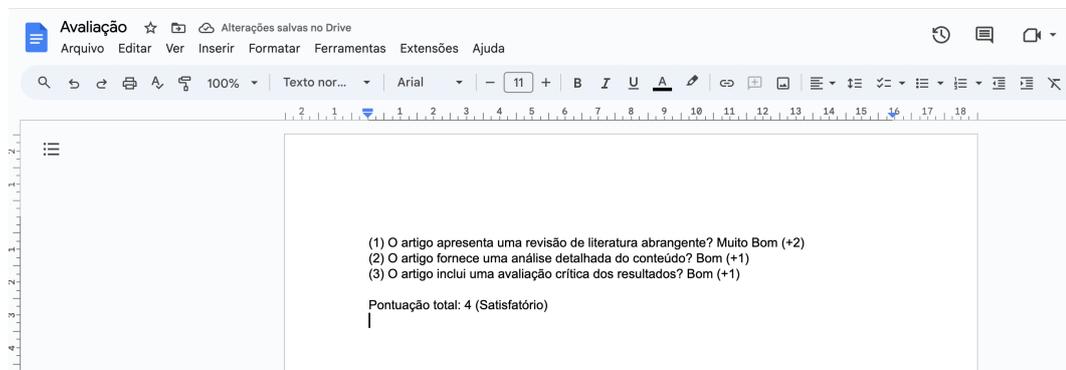


Figura 5.55: Avaliação gerada pelo Chat GPT 4o.

5.1.12 Geração de gráfico e mapa de palavras

As ferramentas gráficas desempenham um papel significativo na pesquisa científica, oferecendo aos pesquisadores meios poderosos de visualizar, interpretar e comunicar dados complexos. Em um cenário acadêmico onde a quantidade de informações e a complexidade dos dados continuam a crescer exponencialmente, a capacidade de transformar números e textos em representações visuais claras e informativas se torna cada vez mais valiosa.

Gráficos e mapas de palavras, por exemplo, não apenas simplificam a análise de grandes volumes de dados, mas também revelam padrões, tendências e relações que podem passar despercebidos em análises puramente textuais. Esses recursos visuais permitem aos pesquisadores identificar rapidamente os picos de produção acadêmica, as lacunas no conhecimento, as influências mais proeminentes e as áreas emergentes de estudo. Além disso, ao facilitar a comunicação de descobertas complexas de maneira acessível e persuasiva, as ferramentas gráficas desempenham um papel importante na disseminação do conhecimento científico, garantindo que *insights* importantes sejam compreendidos e aplicados de forma eficaz por uma audiência mais ampla. Assim, a integração de ferramentas gráficas na pesquisa não só aprimora a eficiência do processo investigativo, mas também eleva a qualidade e o impacto das conclusões obtidas.

O Zapier, embora seja uma ferramenta poderosa para automatizar fluxos de trabalho e integrar diferentes aplicativos, não possui conexão direta com a biblioteca Matplotlib (PETTER; DELONE; MCLEAN, 2008), que foi utilizada para gerar tanto o gráfico de publicações por ano quanto o mapa de palavras com os autores mais proeminentes. A Matplotlib é uma ferramenta específica para a criação de visualizações gráficas, exigindo um ambiente de programação para sua execução, algo que o Zapier não suporta em suas funcionalidades. Devido a essa limitação, a geração dessas visualizações não pôde ser automatizada via Zapier e, portanto, foi realizada manualmente utilizando o ChatGPT. O ChatGPT permitiu, com seus plugins, que esses gráficos fossem criados de maneira precisa e detalhada, atendendo às necessidades específicas da análise, apesar da ausência de uma integração automatizada pelo Zapier.

Na elaboração do gráfico que mostra o número de publicações por ano, conforme ilustra a Figura 5.56, foi adotada uma abordagem híbrida que combinou métodos automatizados e manuais, priorizando a precisão e a relevância dos dados apresentados. O ChatGPT desempenhou um papel central ao utilizar a biblioteca Matplotlib, uma ferramenta amplamente reconhecida pela sua capacidade de gerar gráficos e visualizações de alta qualidade. Através do ChatGPT, foi possível criar gráficos precisos e informativos, essenciais para compreender a evolução temporal das publicações em um determinado campo de estudo.

ChatGPT 4o ▾



gere um gráfico com o número de publicações por ano

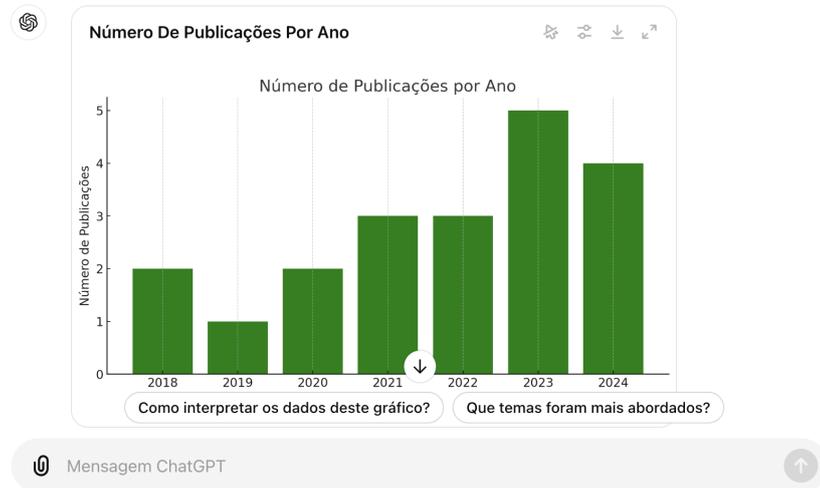


Figura 5.56: Gráfico gerado pelo ChatGPT 4o.

O gráfico de publicações por ano é uma peça chave na análise bibliométrica, pois revela tendências temporais e picos de interesse acadêmico em temas específicos. Permite identificar períodos de maior ou menor atividade de pesquisa, indicando possíveis mudanças no foco da comunidade acadêmica, o surgimento de novas áreas de estudo ou a consolidação de conhecimentos existentes. Contudo, devido à falta de integração direta do Zapier com a Matplotlib, foi necessário realizar a revisão e organização dos dados manualmente após sua coleta. Essa intervenção manual foi necessária para garantir que os dados fossem tratados e apresentados de forma coerente e precisa, assegurando que o gráfico final refletisse fielmente as tendências identificadas.

Além do gráfico de publicações, foi gerado um mapa de palavras, conforme representado na Figura 5.57, destacando os autores mais proeminentes na área de estudo. Esse mapa é importante para identificar os principais contribuintes para o campo, permitindo uma análise mais aprofundada das influências acadêmicas e das colaborações. Assim como no caso do gráfico de publicações por ano, o mapa de palavras foi criado com a ajuda do ChatGPT, utilizando técnicas de processamento de linguagem natural para identificar e destacar os autores mais frequentes e influentes.

ChatGPT 4o ▾



Figura 5.57: Mapa de palavras gerado pelo ChatGPT 4o.

A combinação de métodos automatizados para a coleta e processamento de dados, seguida de um tratamento manual para a visualização, não apenas facilitou a interpretação dos dados, mas também aprimorou a análise crítica da evolução da produção acadêmica ao longo do tempo. O uso do mapa de palavras, em conjunto com o gráfico de publicações, forneceu uma visão abrangente das tendências e das principais figuras influentes na área de estudo, proporcionando *insights* mais robustos e confiáveis para a pesquisa.

5.2 Considerações do capítulo

As conclusões do estudo de caso analisado neste trabalho ressaltam a importância da automação na revisão de literatura acadêmica, validando a eficácia da integração de ferramentas como Zapier, Google Sheets, ChatGPT e Google Docs. O estudo demonstrou que o processo automatizado não apenas aumentou significativamente a eficiência operacional, mas também melhorou a organização e a precisão na análise de trabalhos acadêmicos. Essa metodologia permitiu que os pesquisadores processassem grandes volumes de dados de forma mais ágil, facilitando a identificação de tendências e a extração de informações

relevantes de maneira mais eficaz do que métodos manuais tradicionais.

Entretanto, o estudo também identificou desafios importantes que precisam ser considerados. A necessidade de monitoramento constante das integrações entre as diversas ferramentas revela que a automação, embora poderosa, ainda exige intervenção humana para assegurar que tudo funcione conforme o planejado. A variabilidade na qualidade das palavras-chave e resumos gerados pelo ChatGPT destacou a importância de realizar verificações manuais para garantir que os resultados sejam precisos e relevantes. Essas intervenções são cruciais para manter a qualidade do processo, evitando que erros ou imprecisões impactem negativamente os resultados finais da revisão de literatura.

6 Conclusões

O presente estudo demonstrou o potencial transformador da automação no processo de levantamento de literatura acadêmica. A integração de ferramentas como Zapier, Google Sheets, ChatGPT e Google Docs mostrou-se eficaz na redução de erros manuais e no aumento da eficiência operacional. A metodologia proposta permitiu uma organização e análise mais precisas e ágeis dos artigos acadêmicos, evidenciando os benefícios tangíveis da automação nesse contexto.

No entanto, a pesquisa também destacou desafios significativos. A necessidade de monitoramento contínuo das integrações, a variabilidade na qualidade das palavras-chave e dos resumos gerados pelo ChatGPT, bem como a dependência de serviços externos, são questões que precisam ser abordadas para garantir a sustentabilidade e a confiabilidade do sistema a longo prazo.

6.1 Limitações e desafios

O desenvolvimento e a implementação de um processo automatizado para levantamento de literatura enfrentam desafios e limitações que precisam ser cuidadosamente considerados. Um dos principais desafios é a integração e sincronização das diversas ferramentas utilizadas, como Google Sheets, ChatGPT, Google Docs e Zapier. Cada plataforma tem suas próprias funcionalidades e limitações, o que pode gerar problemas de compatibilidade e comunicação. Por exemplo, a automação via Zapier pode falhar se houver alterações nas APIs das ferramentas integradas ou se os dados não estiverem formatados corretamente. Assim, é necessário monitoramento constante e ajustes frequentes para assegurar o funcionamento harmonioso do sistema.

Outro aspecto importante é a limitação relacionada ao uso das versões pagas do Zapier e ChatGPT. O acesso ao ChatGPT pago, que oferece funcionalidades avançadas como geração de resumos e palavras-chave mais precisas, é utilizado para a eficiência do sistema, mas representa um custo contínuo que pode ser proibitivo para alguns projetos.

A dependência do Zapier na versão paga também impõe restrições, uma vez que funcionalidades avançadas de automação e integração não estão disponíveis na versão gratuita. Essa dependência de serviços pagos pode limitar a acessibilidade e a escalabilidade do processo automatizado, especialmente em projetos de pesquisa com orçamentos restritos.

Além disso, a dependência de ferramentas externas e serviços de terceiros levanta preocupações sobre a sustentabilidade e a confiabilidade do sistema a longo prazo. Mudanças nas políticas de uso, atualizações de software ou interrupções no serviço de qualquer uma das ferramentas podem impactar significativamente o funcionamento do processo automatizado. A confiança em soluções de terceiros também pode expor o sistema a riscos de segurança e privacidade, especialmente se os dados não forem adequadamente protegidos. Portanto, é necessário ter um plano de contingência e estratégias para mitigar esses riscos, garantindo a continuidade do processo mesmo diante de imprevistos.

Apesar das melhorias potenciais, alguns desafios continuarão a exigir atenção especial. A constante evolução das ferramentas e plataformas, com atualizações frequentes e mudanças nas APIs e políticas de uso, pode afetar o funcionamento do sistema. Para mitigar esses riscos, é necessário manter-se atualizado e ajustar o sistema conforme necessário, evitando interrupções ou perdas de funcionalidade. Além disso, os aspectos éticos e de privacidade permanecem como questões centrais, especialmente com o aumento da automatização e do uso de inteligência artificial. Garantir a conformidade com regulamentações como a Lei Geral de Proteção de Dados (LGPD, 2018) e o Regulamento Geral sobre a Proteção de Dados (GDPR, 2016) é utilizado para assegurar que o uso de dados seja conduzido de maneira responsável e segura.

Outro desafio relevante está relacionado à qualidade dos dados processados. A inteligência artificial utilizada, apesar de avançada, ainda apresenta limitações na compreensão de nuances e contextos específicos dos artigos acadêmicos. Portanto, será necessário continuar a avaliar criticamente os resultados gerados, com a possibilidade de intervenção manual quando necessário, para manter a qualidade das informações processadas. Esse cuidado é necessário para que o processo automatizado de levantamento de literatura seja não apenas eficiente, mas também rigoroso e confiável, atendendo aos altos padrões exigidos pela pesquisa acadêmica.

Em resumo, enquanto a automação do levantamento de literatura oferece inúmeras vantagens, também enfrenta desafios e limitações consideráveis. A integração técnica, a precisão das saídas da inteligência artificial e a dependência de serviços externos são questões que exigem atenção contínua e soluções inovadoras. Ao reconhecer e abordar esses desafios de maneira proativa, os pesquisadores podem melhorar a eficiência e a eficácia do processo automatizado, ao mesmo tempo em que garantem a integridade e a confiabilidade dos dados coletados para suas pesquisas acadêmicas.

6.2 Próximos Passos

Para aprimorar a metodologia apresentada e enfrentar os desafios identificados, é necessário adotar uma abordagem estratégica que inclua o desenvolvimento de *prompts* mais sofisticados e a personalização do ChatGPT para áreas de pesquisa específicas. Esse esforço pode resultar em uma melhora significativa na precisão e relevância das palavras-chave e resumos gerados, atendendo de maneira mais eficaz às necessidades dos pesquisadores. Além disso, a criação de um sistema de monitoramento contínuo das integrações e automações se torna imprescindível. Através de relatórios regulares sobre o desempenho do sistema, será possível identificar e corrigir rapidamente qualquer falha ou ineficiência, assegurando a manutenção da qualidade e eficácia do processo automatizado.

Paralelamente, é significativo desenvolver um plano de ação robusto, preparado para lidar com possíveis interrupções nos serviços de terceiros essenciais ao funcionamento do sistema. Essa preparação inclui a possibilidade de migrar dados e processos para outras plataformas, caso seja necessário, reduzindo assim a dependência de serviços externos. Explorar e testar outras ferramentas ou plataformas que possam complementar ou substituir as atuais é também uma estratégia relevante para aumentar a autonomia do sistema e garantir a sua continuidade, mesmo diante de mudanças nas políticas e funcionalidades das ferramentas atualmente utilizadas.

Outro aspecto importante é a capacitação contínua dos pesquisadores envolvidos no processo. Fornecer treinamento sobre o uso das ferramentas e as melhores práticas na automação de processos acadêmicos garantirá que a equipe esteja sempre preparada para lidar com as tecnologias envolvidas, tirando o máximo proveito de suas funcionalidades.

6.3 Aspectos éticos

A consideração dos aspectos éticos é importante em qualquer pesquisa acadêmica, e o desenvolvimento de um processo automatizado de levantamento de literatura não é exceção. Este projeto, que integra ferramentas como Google Sheets, ChatGPT, Google Docs e Zapier, foi cuidadosamente planejado para garantir que todos os princípios éticos sejam rigorosamente seguidos, protegendo os direitos e a privacidade dos participantes e das informações utilizadas. Uma das primeiras questões éticas a ser abordada é a confidencialidade dos dados. Ao trabalhar com ferramentas que coletam e processam informações, é imperativo assegurar que todos os dados sejam armazenados de forma segura e que apenas pessoas autorizadas que necessitem acesso.

Além disso, é significativo obter consentimento informado dos participantes envolvidos no processo. No contexto deste estudo, os participantes podem incluir pesquisadores que utilizam o sistema automatizado, bem como indivíduos cujos dados podem ser processados durante a pesquisa. O consentimento informado implica que todos os participantes sejam plenamente informados sobre os objetivos do estudo, as metodologias utilizadas, os tipos de dados que serão coletados e como esses dados serão utilizados. Também devem ser informados sobre quaisquer riscos potenciais e benefícios associados à sua participação, e devem ter a oportunidade de retirar seu consentimento a qualquer momento, sem prejuízo.

Outro aspecto ético importante é a transparência e a responsabilidade no uso de inteligência artificial, como o ChatGPT, para gerar palavras-chave e resumos. É vital que os pesquisadores compreendam as limitações e os vieses potenciais dos algoritmos utilizados e sejam transparentes sobre isso em suas comunicações. Devem ser adotadas práticas para mitigar possíveis vieses e assegurar que os resultados gerados sejam justos e precisos. Além disso, o uso de dados deve sempre respeitar as regulamentações vigentes sobre proteção de dados, como o Regulamento Geral sobre a Proteção de Dados (GDPR) na Europa ou a Lei Geral de Proteção de Dados (LGPD) no Brasil, garantindo que todas as práticas estejam em conformidade com as leis de privacidade e proteção de dados. Ao seguir rigorosamente esses aspectos éticos, o processo automatizado de levantamento de literatura pode ser conduzido de maneira responsável e respeitosa, promovendo a integridade e a credibilidade da pesquisa acadêmica.

Neste trabalho, o ChatGPT foi utilizado como ferramenta auxiliar para melhorar a clareza e coesão do texto. A aplicação foi feita de maneira responsável, com todas as sugestões geradas pela IA sendo rigorosamente revisadas pelos autores. Esse uso visou apenas aprimorar a comunicação, mantendo intactas as ideias e interpretações originais, garantindo assim a integridade acadêmica do trabalho.

6.4 Considerações Finais

Este trabalho demonstrou o impacto da automação na pesquisa acadêmica, evidenciado pela integração eficaz de ferramentas como Zapier, Google Sheets, ChatGPT e Google Docs. Ao automatizar processos repetitivos e complexos, foi possível alcançar uma maior eficiência e precisão na coleta e análise de dados, reduzindo erros manuais e acelerando o fluxo de trabalho. A metodologia proposta não apenas otimizou o levantamento de literatura, mas também proporcionou uma solução inovadora para o gerenciamento de informações acadêmicas, oferecendo uma abordagem moderna e adaptada às necessidades da pesquisa atual.

No entanto, o estudo também revelou desafios importantes que devem ser cuidadosamente considerados para garantir a sustentabilidade e a eficácia do sistema a longo prazo. A necessidade de monitoramento contínuo das integrações e a dependência de serviços externos são questões que exigem atenção constante. Além disso, a variabilidade na qualidade dos resultados gerados pelo ChatGPT ressalta a importância de um olhar crítico e, quando necessário, da intervenção manual para garantir que a precisão e a relevância das informações processadas sejam mantidas.

Por fim, este trabalho sublinha a necessidade de um compromisso contínuo com a ética e a privacidade no uso de tecnologias automatizadas e inteligência artificial na pesquisa acadêmica. Assegurar a conformidade com regulamentações de proteção de dados e manter a transparência no uso dessas ferramentas são passos essenciais para preservar a integridade e a confiança nos processos automatizados. Com um planejamento cuidadoso e uma abordagem proativa para superar os desafios, a automação tem o potencial de transformar significativamente o campo da pesquisa acadêmica, elevando o padrão de qualidade e eficiência nas atividades de investigação científica.

Bibliografia

ACMDIGITALLIBRARY. 1997. Disponível em: <https://dl.acm.org/>.

AGARWAL, R.; PRASAD, J. Are individual differences germane to the acceptance of new information technologies? *Decision sciences*, Wiley Online Library, v. 30, n. 2, p. 361–391, 1999.

AIRTABLE. 2023. Disponível em: <https://www.oitchau.com.br/blog/airtable-o-que-e/>.

APPLENUMBERS. 2005. Disponível em: <https://www.apple.com/br/numbers/>.

ARAÚJO, J. C.; ARAÚJO, M. C.; ; ARAÚJO, M. A. P. Em busca de um processo automatizado para levantamento de literatura apoiado por uma inteligência artificial generativa. 2023.

ARAÚJO, J. C.; ARAÚJO, M. C.; ; ARAÚJO, M. A. P. Explorando a automatização na análise estatística com suporte da inteligência artificial generativa na gestão de dados de investigação. 2023.

ARAÚJO, J. C.; ARAÚJO, M. C.; ; ARAÚJO, M. A. P. Explorando automatização na revisão de literatura com suporte de inteligência artificial generativa na gestão de dados de investigação. 2023.

ARUDA, E. P. Inteligência artificial generativa, jogos digitais e ensino de história: Desafios docentes. *VIDEOGAMES E JOGOS ELETRÔNICOS*, p. 117, 2024.

ARUDA, E. P. *INTELIGÊNCIA ARTIFICIAL GENERATIVA NO CONTEXTO DA TRANSFORMAÇÃO DO TRABALHO DOCENTE*. [S.l.]: SciELO Brasil, 2024.

ASKYOURPDF. 2023. Disponível em: <https://askyourpdf.com/pt>.

AZAM, S. *Analog Defect Injection and Fault Simulation Techniques: A Systematic Literature Review*. 2024. Disponível em: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=10194295>.

BARBOSA, R. C. Classificação de veículos baseada em deep learning para aplicação em semáforos inteligentes. 2020.

BARTLETT, L.; KABIR, M. A.; HAN, J. A review on business process management system design: The role of virtualization and work design. *IEEE Access*, IEEE, 2023.

BEVAN, N. Measuring usability as quality of use. *Software Quality Journal*, Springer, v. 4, p. 115–130, 1995.

BRIZOLA, J.; FANTIN, N. Revisão da literatura e revisão sistemática da literatura. *Revista de Educação do Vale do Arinos-RELVA*, v. 3, n. 2, 2016.

BROWN, T.; MANN, B.; RYDER, N.; SUBBIAH, M.; KAPLAN, J. D.; DHARIWAL, P.; NEELAKANTAN, A.; SHYAM, P.; SASTRY, G.; ASKELL, A. et al. Language models are few-shot learners. *Advances in neural information processing systems*, v. 33, p. 1877–1901, 2020.

CARVALHO, I. Automatização de processos: benefícios da implementação no setor financeiro de uma empresa multinacional. 2021.

CHATGPT. 2022. Disponível em: [〈https://chat.openai.com/〉](https://chat.openai.com/).

CHATPDF. 2023. Disponível em: [〈https://www.chatpdf.com/?via=le-quoc-cuong&gad_source=1&gclid=CjwKCAjw26KxBhBDEiwAu6KXt1tOYEIGg3g0H7TXi17yIftJ-L3INm5qyYIVaV9wXZTxoC9zkQAvD_BwE〉](https://www.chatpdf.com/?via=le-quoc-cuong&gad_source=1&gclid=CjwKCAjw26KxBhBDEiwAu6KXt1tOYEIGg3g0H7TXi17yIftJ-L3INm5qyYIVaV9wXZTxoC9zkQAvD_BwE).

CLAUDE. 2023. Disponível em: [〈https://consumer.huawei.com/pt/community/details/J%C3%A1-conhece-o-Claude-2-o-novo-rival-do-Chat-GPT/topicId_54612/〉](https://consumer.huawei.com/pt/community/details/J%C3%A1-conhece-o-Claude-2-o-novo-rival-do-Chat-GPT/topicId_54612/).

CONNECTPAPERS. 2021. Disponível em: [〈https://www.connectpapers.com/〉](https://www.connectpapers.com/).

CONSENSUS. 2022. Disponível em: [〈https://www.consensus.app/〉](https://www.consensus.app/).

CUNHA, L. M. A. da. *Modelos Rasch e Escalas de Likert e Thurstone na medição de atitudes*. Dissertação (Mestrado) — Universidade de Lisboa (Portugal), 2007.

CUTRIM, N. C.; MACHADO, D. M.; COSTA, M. J. M. Inteligência artificial e seus debates éticos: impactos negativos do uso indevido da ia na criação de arte. *Revista de Estudos Multidisciplinares UNDB*, v. 3, n. 2, 2023.

DALL'ALBA, R.; BERNARDE, H. D.; ZIMMERMANN, I. R.; FILHO, L. A. D.; FERRE, F.; RONSONI, R. D. M.; AZEVEDO, J. d. N. B.; GAROFALO, G.; DELBONI, S. G. Automatização nos processos de programação da assistência farmacêutica: A tecnologia, eficiência e cuidado. Galoá, 2018.

DAVIS, F. D. Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS quarterly*, JSTOR, p. 319–340, 1989.

DERMEVAL, D. *Mapeamento Sistemático e Revisão Sistemática da Literatura em Informática na Educação*. 2020. Disponível em: [〈chrome-extension://efaidnbmnnnibpcajpcgclefindmkaj/https://metodologia.ceie-br.org/wp-content/uploads/2019/11/livro2_cap3.pdf〉](chrome-extension://efaidnbmnnnibpcajpcgclefindmkaj/https://metodologia.ceie-br.org/wp-content/uploads/2019/11/livro2_cap3.pdf).

DEVLIN, J.; CHANG, M.-W.; LEE, K.; TOUTANOVA, K. Bert: Pre-training of deep bidirectional transformers for language understanding. *arXiv preprint arXiv:1810.04805*, 2018.

DEY, N.; BHATT, C.; ASHOUR, A. S. Big data for remote sensing: Visualization, analysis and interpretation. *Cham: Springer*, Springer, v. 104, 2018.

DINTER, R. van. *Automation of systematic literature reviews: A systematic literature review*. 2021. Disponível em: [〈chrome-extension://efaidnbmnnnibpcajpcgclefindmkaj/https://edepot.wur.nl/545840〉](chrome-extension://efaidnbmnnnibpcajpcgclefindmkaj/https://edepot.wur.nl/545840).

DUQUE-PEREIRA, I. da S.; MOURA, S. A. de et al. Compreendendo a inteligência artificial generativa na perspectiva da língua. *SciELO Preprints*, 2023.

EICOMPENDEX. 1969. Disponível em: [〈https://www.elsevier.com/solutions/engineering-village/content/ei-compindex〉](https://www.elsevier.com/solutions/engineering-village/content/ei-compindex).

ELICIT. 2021. Disponível em: [〈https://elicit.org/〉](https://elicit.org/).

ENDNOTE. 1988. Disponível em: https://endnote.com/buy/?campaignname=EndNote_LeadGen_AG_Global_2024&campaignid=701Do00000015W5IAI&x-campaign=EndNote_LeadGen_AG_Global_2024&x-source=Google_Ads_Brand&x-medium=Paid&gad_source=1&gclid=CjwKCAjwkJm0BhBxEiwAwT1AXItGRjW8GojAPwFm-QnywPvsjSH_oK6srgkP_GKZ0rXEI-ol21aryRoC_-IQAvD_BwE&utm_campaign=EndNote_LeadGen_AG_Global_2024&utm_source=Google_Ads_Brand&utm_medium=Paid).

FAROOQ, M. S. *Behavior Driven Development: A Systematic Literature Review*. 2023. Disponível em: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=10210040>).

FAÇANHA, S. D. O. *PROSPECÇÃO DO USO DE MACHINE LEARNING NAS CORRETORAS BRASILEIRAS*. 2019. Disponível em: chrome-extension://efaidnbmnnnibpcajpcgclefindmkaj/https://repositorio.ufc.br/bitstream/riufc/60322/1/2019_tcc_sofa%c3%a7anha.pdf).

FERNEDA, E. *Redes neurais e sua aplicação em sistemas de recuperação de informação*. 2006. Disponível em: <chrome-extension://efaidnbmnnnibpcajpcgclefindmkaj/https://www.scielo.br/j/ci/a/SQ9myjZWLxnyXfstXMgCdcH/?format=pdf&lang=pt>).

FEW, S. *Information dashboard design: The effective visual communication of data*. [S.l.]: O'Reilly Media, Inc., 2006.

GDPR. 2016. Disponível em: <https://eur-lex.europa.eu/eli/reg/2016/679/oj>).

GEMINI. 2023. Disponível em: <https://gemini.google.com/?hl=pt-BR>).

GILL, A. Q.; SMITH, S.; BEYDOUN, G.; SUGUMARAN, V. Agile enterprise architecture: a case of a cloud technology-enabled government enterprise transformation. 2014.

GOOGLEDOCS. 2006. Disponível em: <https://docs.google.com/document/u/0/>).

GOOGLESCHOLAR. 2004. Disponível em: <https://scholar.google.com/>).

GOOGLESHEETS. 2006. Disponível em: https://www.googleadservices.com/pagead/aclk?sa=L&ai=DChcSEWjmt-dmt-NqFAxXvEK0GHX0tA7AYABABGgJwdg&ase=2&gclid=CjwKCAjw26KxBhBDEiwAu6KXt73qT3FDRVQ1qVoeKUMiZ5fNfejWF_o7hTioofPYTaDbtwAhbNHbzBoChjAQA_vD_BwE&ohost=www.google.com&cid=CAESVeD2v3VginzDzN-IF1ndJCF3tsyOwCDTnreEw6rXIFtppg4_PnL8NUdmZ7ywM78S3I6Whc7C6NB5UmYA_-BkmRAd38m8il1VK39ZvdDkn2HhC-tLA5g&sig=AOD64.07ZNSDR2mqNR-E.l85Na5O8L8Sjg&q&nis=4&adurl&ved=2ahUKEwjFoMWt-NqFAxXnqpUCHYXaDs0Q0Qx6BAgFEAE).

GUTWIN, C.; GREENBERG, S. Design for individuals, design for groups: tradeoffs between power and workspace awareness. In: *Proceedings of the 1998 ACM conference on Computer supported cooperative work*. [S.l.: s.n.], 1998. p. 207-216.

HIND ZINEB SERHIER, M. J. M. B. O. B. *Artificial intelligence: perception, attitudes and use among students at the Casablanca Faculty of Medicine*. 2024. Disponível em: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=10366176>).

HOSAKI, G. Y. G. Y.; RIBEIRO, D. F. Deep learning: ensinando a aprender. 275, 2021.

- IBMWATSON. 2023. Disponível em: https://www.ibm.com/br-pt/watson?utm_content=SRCWW&p1=Search&p4=43700078882371979&p5=e&p9=58700008628432339&gclid=Cj0KCQjw0_WyBhDMARIsAL1Vz8sahFgnI8sOFmbNwn3ITTwuYnm-sVuWE8Cs7JQWmAVJ0yqp1FyArUIaAwcB&gclsrc=aw.ds.
- IEEEEXPLORE. 2000. Disponível em: <https://ieeexplore.ieee.org/>.
- IMRAN, M. *Advancing Process Audits With Process Mining: A Systematic Review of Trends, Challenges, and Opportunities*. 2023. Disponível em: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=10172178>.
- INTEGROMAT. 2018. Disponível em: https://www.mendeley.com/?interaction_required=true.
- JARDIM-FILHO, N. D. M. *Melhoria e automatização de processos*. 2022.
- JESUS, D. d. *Uso de ferramentas livres e de código aberto para a automatização de processos e produtos, redução de custos e prazos em projetos de risco geológico*. Tese (Doutorado), 2023.
- JOHNSON, D. W.; JOHNSON, F. P. *Joining together: Group theory and group skills*. [S.l.]: Prentice-Hall, Inc, 1991.
- JOHNSON, M.; MACDONALD, S. *Joining the Conversation: Writing in College and Beyond*. [S.l.]: Pearson, 2019.
- JOSHI, A.; KALE, S.; CHANDEL, S.; PAL, D. K. Likert scale: Explored and explained. *British Journal of Applied Science & Technology*, v. 7, n. 4, p. 396–403, 2015.
- JOSKOWICZ, D. S. J. *Engineers' Perspectives on the Use of Generative Artificial Intelligence Tools in the Workplace*. 2024. Disponível em: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=10319661>.
- KAUFMAN, D. Inteligência artificial e os desafios éticos: a restrita aplicabilidade dos princípios gerais para nortear o ecossistema de ia. *PAULUS: Revista de Comunicação da FAPCOM*, v. 5, n. 9, 2021.
- KITCHENHAM, B. *Procedures for Performing Systematic Reviews*. 2004. Disponível em: <chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=29890a936639862f45cb9a987dd599dce9759bf5>.
- LARGUESA, R. *Engenharia de Prompt para Devs: Um guia para aprender a usar a IA antes que a IA aprenda a usar você*. Casa do Código, 2024. ISBN 9788555193712. Disponível em: <https://books.google.com.br/books?id=Qj79EAAAQBAJ>.
- LAUDON, K. C.; LAUDON, J. P. *Management information systems: Managing the digital firm*. [S.l.]: Pearson Educación, 2004.
- LAZZARESCHI, N.; GUERRA, C. M. F.; NAKAOKA, M. Y. T. O impacto das tecnologias gpt no futuro do trabalho. *Caderno Eletrônico de Ciências Sociais*, v. 11, n. 2, p. 38–51, 2023.
- LGPD. 2018. Disponível em: http://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/lei/L13709.htm.

LLAMA. 2023. Disponível em: <https://llama.meta.com/>).

LUCIDCHART. 2008. Disponível em: <https://www.lucidchart.com/>).

LUNETTA, A. de; GUERRA, R. Metodologia da pesquisa científica e acadêmica. *Revista OWL (OWL Journal)-Revista Interdisciplinar de Ensino e Educação*, v. 1, n. 2, p. 149–159, 2023.

LUNSFORD, A.; EDE, L. Singular texts/plural authors: Perspectives on collaborative writing. *Carbondale: Southern Illinois UP*, 1990.

LUNSFORD, A. A.; EDE, L. Singular texts/plural authors: Perspectives on collaborative writing. *Southern Illinois University Press*, 2020.

LUSTOSA, M. de M. *Inteligência Artificial e Comunicação Científica: uma revisão sistemática*. 2024. Disponível em: <file:///Users/marinaaraujo/Downloads/Dialnet-InteligenciaArtificialEComunicacaoCientificaUmaRev-9342789.pdf>).

MAESTRO, M. A. Explorando modelos de machine learning na predição de compras online. 2023.

MARINESCU, D. C. *Cloud computing: theory and practice*. [S.l.]: Morgan Kaufmann, 2022.

MARQUES, S. D. *Pós-realidade e Teoria da Desinformação: inquietações sobre o uso massivo de IA Generativa*. 2023. Disponível em: <chrome-extension://efaidnbmnnnibpcajpcgclefindmkaj/https://lume.ufrgs.br/bitstream/handle/10183/265448/001177114.pdf?sequence=1>).

MARSHALL, I. *Rapid reviews may produce different results to systematic reviews: a meta-epidemiological study*. 2019. Disponível em: <chrome-extension://efaidnbmnnnibpcajpcgclefindmkaj/https://www.jameslindlibrary.org/wp-data/uploads/2019/04/Marshall-et-all-2019.pdf>).

MARTINEZ, A. L. Gerenciamento de resultados no brasil: um survey da literatura. *BBR-Brazilian Business Review*, FUCAPE Business School, v. 10, n. 4, p. 1–31, 2013.

MARTINS, E. *MACHINE LEARNING: UMA ANÁLISE BIBLIOMÉTRICA*. 2023. Disponível em: <https://periodicos.uninove.br/innovation/article/view/24056/10417>).

MCCARTHY, J. *Some Philosophical Problems from the Standpoint of Artificial Intelligence Author links open overlay panel*. 1981. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/B9780934613033500337>).

MENDELEY. 2008. Disponível em: https://www.make.com/en/register?pc=astseo&gad_source=1&gclid=CjwKCAjw1K-zBhBIEiwAWeCOFz3cLR1kPIFq9h-0KBOYFHOyg8rnWufbNNe3G8bSGrfSyOBoC8koQAvD_BwE).

MICROSOFT EXCEL. 2006. Disponível em: https://www.microsoft.com/pt-br/microsoft-365/excel?ef_id=k_CjwKCAjw1K-zBhBIEiwAWeCOF0SyZRxdttWQm7-1fq2wj4ZDQ9qG9UR15vBEtM_ccJ-Pel0-V7tqCxoCmNAQAvD_BwE_k_&OCID=AIDcmmq9ldqz5w_SEM_k_CjwKCAjw1K-zBhBIEiwAWeCOF0SyZRxdttWQm7-1fq2wj4ZDQ9qG9UR15vBEtM_ccJ-Pel0-V7tqCxoCmNAQAvD_BwE_k_&gad_source=1&gclid=CjwKCAjw1K-zBhBIEiwAWeCOF0SyZRxdttWQm7-1fq2wj4ZDQ9qG9UR15vBEtM_ccJ-Pel0-V7tqCxoCmNAQAvD_BwE).

- MICROSOFTPOWERAUTOMATE. 2019. Disponível em: https://www.microsoft.com/pt-br/power-platform/products/power-automate?ef_id=k_CjwKCAjw1K-zBhBIEiwAWeCOF00_Cp9X_zq8TCjk9YI-pIkU5ParxwkNQXDr0c1ivGM2NPqBOumhKxoCToQQAvD_BwE_k_&OCID=AIDcmmp8nuwpcd_SEM_k_CjwKCAjw1K-zBhBIEiwAWeCOF00_Cp9X_zq8TCjk9YI-pIkU5ParxwkNQXDr0c1ivGM2NPqBOumhKxoCToQQAvD_BwE_k_&gad_source=1&glid=CjwKCAjw1K-zBhBIEiwAWeCOF00_Cp9X_zq8TCjk9YI-pIkU5ParxwkNQXDr0c1ivGM2NPqBOumhKxoCToQQAvD_BwE).
- MICROSOFTWORD. 1983. Disponível em: https://www.microsoft.com/pt-br/microsoft-365/word?ef_id=k_CjwKCAjw1K-zBhBIEiwAWeCOFwn8u0j2PbX3MzQEgWwaiYHTzlyhaqZsvYpY32h0EQA8GE44nBwE_k_&OCID=AIDcmmq9ldqz5w_SEM_k_CjwKCAjw1K-zBhBIEiwAWeCOFwn8u0j2PbX3MzQEgWwaiYHTzlyhaqZsvYpY32h0EQA8GE44nBwE_k_&gad_source=1&glid=CjwKCAjw1K-zBhBIEiwAWeCOFwn8u0j2PbX3MzQEgWwaiYHTzlyhaqZsvYpY32h0EQA8GE44nBwE).
- MINDMEISTER. 2007. Disponível em: <https://www.mindmeister.com/>).
- MIRANDA, M. L. D.; FILHO, M. J. R. D. S. Inteligência artificial como ferramenta inovadora na educação. In: EDITORA CIENTÍFICA DIGITAL. *A PEDAGOGIA DO SUCESSO: REVISÕES, REFLEXÕES E RELATOS DE EXPERIÊNCIAS EXITOSAS NA EDUCAÇÃO*. [S.l.], 2024. v. 1, p. 107–119.
- MIRO. 2011. Disponível em: <https://miro.com/>).
- NACIMENTO, J. R. d. *Exploração de técnicas de engenharia de prompt para aprimorar os resultados do uso de LLM no TCMRio*. Dissertação (B.S. thesis) — Universidade Federal do Rio Grande do Norte, 2024.
- NARCISO, R. *TRANSFORMAÇÃO E DESAFIOS: A INTEGRAÇÃO DA INTELIGÊNCIA ARTIFICIAL NO ENSINO SUPERIOR*. 2024. Disponível em: <https://periodicorease.pro.br/rease/article/view/13498>).
- NETO, H. N.; MATTOS, D. M.; FERNANDES, N. C. Privacidade do usuário em aprendizado colaborativo: Federated learning, da teoria à prática. *Sociedade Brasileira de Computação*, 2020.
- NIELSEN, J. *Usability engineering*. [S.l.]: Morgan Kaufmann, 1994.
- NUNAMAKER, J. F.; DENNIS, A. R.; VALACICH, J. S.; VOGEL, D.; GEORGE, J. F. Electronic meeting systems. *Communications of the ACM*, ACM New York, NY, USA, v. 34, n. 7, p. 40–61, 1991.
- OAMG. 2020. Disponível em: <https://www.oa.mg/>).
- OKTAVIAN REZA FUAD RACHMADI, W. R. *Evaluation of Artificial Intelligence (AI) Readiness Level in the Manufacturing Industry in Indonesia*. 2023. Disponível em: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=10428204>).
- OLIVEIRA, L. H. T. d. *Desafios da automatização de processos de migração de softwares*. Tese (Doutorado) — Mestrado em Sistemas de Informação e Gestão do Conhecimento, 2018.

OLSON, G. M.; OLSON, J. S.; CARTER, M. R.; STORROSTEN, M. Small group design meetings: An analysis of collaboration. *Human-Computer Interaction*, Taylor & Francis, v. 7, n. 4, p. 347–374, 1992.

ONENOTE. 2003. Disponível em: <https://www.onenote.com/notebooks?auth=2&nf=1>).

PERPLEXITY. 2022. Disponível em: <https://www.perplexity.ai/>).

PETTER, S.; DELONE, W.; MCLEAN, E. Measuring information systems success: models, dimensions, measures, and interrelationships. *European journal of information systems*, Taylor & Francis, v. 17, n. 3, p. 236–263, 2008.

PREECE, J.; ROGERS, Y.; SHARP, H.; BENYON, D.; HOLLAND, S.; CAREY, T. *Human-computer interaction*. [S.l.]: Addison-Wesley Longman Ltd., 1994.

PUBMED. 1996. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/>).

RAFFEL, C.; SHAZEER, N.; ROBERTS, A.; LEE, K.; NARANG, S.; MATENA, M.; ZHOU, Y.; LI, W.; LIU, P. J. Exploring the limits of transfer learning with a unified text-to-text transformer. *Journal of machine learning research*, v. 21, n. 140, p. 1–67, 2020.

RAYYAN. 2016. Disponível em: <https://www.rayyan.ai/>).

REDISCOVERY. 2021. Disponível em: <https://www.researcherapp.com/discover>).

RESEARCHRABBIT. 2021. Disponível em: <https://www.researchrabbit.ai/>).

ROSSONI, L.; CHAT, G. A inteligência artificial e eu: escrevendo o editorial juntamente com o chatgpt. *Revista Eletrônica de Ciência Administrativa*, v. 21, n. 3, p. 399–405, 2022.

SANTOS, A. *Desafios e Oportunidades da Inteligência Artificial na Educação e na Formação*. 2023. Disponível em: <file:///Users/marinaaraujo/Downloads/34154-Texto%20do%20Trabalho-150510-1-10-20240102.pdf>).

SANTOS, C. M. da C. *A estratégia PICO para a construção da pergunta de pesquisa e busca de evidências*. 2007. Disponível em: <https://www.scielo.br/j/rlae/a/CfKNnz8mvSqVjZ37Z77pFsy/?lang=pt>).

SANTOS, H. G. dos. *Comparação da performance de algoritmos de machine learning para a análise preditiva em saúde pública e medicina*. 2018. Disponível em: chrome-extension://efaidnbmnmmnibpcajpcgclefindmkaj/https://www.teses.usp.br/teses/disponiveis/6/6141/tde-09102018-132826/publico/HellenGeremiasdosSantos_DR_ORIGINAL.pdf).

SANTOS, R. P. dos. Enhancing chemistry learning with chatgpt, bing chat, bard, and claude as agents-to-think-with: A comparative case study. *arXiv e-prints*, p. arXiv–2311, 2023.

SCHAEFFER-FILHO, A. E.; NOBRE, J. C.; WICKBOLDT, J. A.; GRANVILLE, L. Z.; GASPARY, L. P.; CORDEIRO, W. L. da C. Segurança cibernética 2030: Experiências, desafios e oportunidades. *Sociedade Brasileira de Computação*, 2023.

SCIENCEDIRECT. 1997. Disponível em: <https://www.sciencedirect.com/>).

- SCISPACE. 2014. Disponível em: <<https://www.scispace.com/>>.
- SCOPUS. 2004. Disponível em: <<https://www.scopus.com/>>.
- SEMANTICSCHOLAR. 2015. Disponível em: <<https://www.semanticscholar.org/>>.
- SHNEIDERMAN, B. Universal usability. *Communications of the ACM*, ACM New York, NY, USA, v. 43, n. 5, p. 84–91, 2000.
- SHNEIDERMAN, B. *Universal Usability*. [S.l.]: Routledge, 2021.
- SIRINO, E. B. Medidas básicas de segurança da informação aplicadas em um cfc (centro de formação de condutores). 004, 2018.
- SMITH, M. A.; FARNHAM, S. D.; DRUCKER, S. M. The social life of small graphical chat spaces. In: *Proceedings of the SIGCHI conference on Human factors in computing systems*. [S.l.: s.n.], 2000. p. 462–469.
- SOLMS, R. V.; NIEKERK, J. V. From information security to cyber security. *computers & security*, Elsevier, v. 38, p. 97–102, 2013.
- SOUZA, M. T. S. de; CERVENY, C. M. de O. Resiliência psicológica: revisão da literatura e análise da produção científica. *Revista Interamericana de Psicología/Interamerican Journal of Psychology*, Sociedad Interamericana de Psicología, v. 40, n. 1, p. 119–126, 2006.
- TENOPIR, C. Use and users of electronic library resources: An overview and analysis of. 2003.
- TENOPIR, C.; KING, D. W. Use of scientific literature in digital age. *Annual Review of Information Science and Technology*, v. 56, n. 1, p. 247–276, 2022.
- THONG, J. Y. An integrated model of information systems adoption in small businesses. *Journal of management information systems*, Taylor & Francis, v. 15, n. 4, p. 187–214, 1999.
- TRINDADE, A. S. C. E. da. *Inteligência Artificial (IA) generativa e Competência em Informação: habilidades informacionais necessárias ao uso de ferramentas de IA generativa em demandas informacionais de natureza acadêmica-científica*. 2024. Disponível em: <<https://periodicos.ufmg.br/index.php/pci/article/view/47485/43923>>.
- VAMOS, O. E. E. P. O. Inteligência artificial, deep learning, machine learning, redes neurais na medicina e biomarcadores vocais: Conceitos. *Rev Soc Cardiol Estado de São Paulo*, v. 32, n. 1, p. 11–7, 2022.
- VENKATESH, V.; MORRIS, M. G.; DAVIS, G. B.; DAVIS, F. D. User acceptance of information technology: Toward a unified view. *MIS quarterly*, JSTOR, p. 425–478, 2003.
- VENTURA, M. M. O estudo de caso como modalidade de pesquisa. *Revista SoCERJ*, v. 20, n. 5, p. 383–386, 2007.
- WAGNER, G.; LUKYANENKO, R.; PARÉ, G. Artificial intelligence and the conduct of literature reviews. *Journal of Information Technology*, SAGE Publications Sage UK: London, England, v. 37, n. 2, p. 209–226, 2022.
- WEBOFSCIENCE. 1997. Disponível em: <<https://www.webofscience.com/>>.

WHITE, H. D.; MCCAIN, K. W. Visualizing a discipline: An author co-citation analysis of information science, 1972–1995. *Journal of the American society for information science*, Wiley Online Library, v. 49, n. 4, p. 327–355, 1998.

WHITE, H. D.; MCCAIN, K. W. Visualizing literature: Mapping and analyzing research trends. *Journal of the Association for Information Science and Technology*, v. 71, n. 3, p. 284–299, 2020.

WOLF, T.; DEBUT, L.; SANH, V.; CHAUMOND, J.; DELANGUE, C.; MOI, A.; CISTAC, P.; RAULT, T.; LOUF, R.; FUNTOWICZ, M. et al. Transformers: State-of-the-art natural language processing. In: *Proceedings of the 2020 conference on empirical methods in natural language processing: system demonstrations*. [S.l.: s.n.], 2020. p. 38–45.

WU XUSHENG LIU, Q. W. X. W. X. *Application of Artificial Intelligence in Customer Service Field*. 2021. Disponível em: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9711991>.

XMIND. 2006. Disponível em: <https://www.xmind.net/>.

YANG, W. *Deep Learning*. 2022. Disponível em: <chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/https://wenxiao5.github.io/Note/Inference%20and%20Learning/Inference%20and%20Learning.pdf>.

ZAPIER. 2011. Disponível em: https://zapier.com/1/home?utm_source=google&utm_medium=cpc&utm_campaign=gaw-row-nua-evr-search_brand_alldev_prospecting_trademark_d2-ads&utm_adgroup=brand_trademark_zapier&utm_term=zapier&utm_content=9101186&gad_source=1&gclid=CjwKCAjw26KxBhBDEiwAu6KXtzGIfn-83r0liNPq8DxnlgK-xZSGwVXn_XbaUxalbhsNRJns8y6wHhoC1CcQAvD_BwE.

ZHAO, H. *Explainability for Large Language Models: A Survey*. 2024. Disponível em: <https://dl.acm.org/doi/full/10.1145/3639372#Bib0042>.

ZOHOWRITER. 2022. Disponível em: <https://www.zoho.com/pt-br/writer/>.

ZOTERO. 2006. Disponível em: <https://www.zotero.org/>.