



**UNIVERSIDADE ESTADUAL DA PARAÍBA
CAMPUS VII - GOVERNADOR ANTÔNIO MARIZ
CENTRO DE CIÊNCIAS EXATAS E SOCIAIS APLICADAS
CURSO DE BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO**

GABRIEL LIRA DA NÓBREGA

**ANÁLISE DE DESEMPENHO DE MODELOS DE IA
GENERATIVA OPEN SOURCE NA SUMARIZAÇÃO DE
DOCUMENTOS**

**PATOS
2025**

GABRIEL LIRA DA NÓBREGA

ANÁLISE DE DESEMPENHO DE MODELOS DE IA
GENERATIVA OPEN SOURCE NA SUMARIZAÇÃO DE
DOCUMENTOS

Trabalho de Conclusão de Curso apresentado ao Curso de Bacharelado em Ciência da Computação da Universidade Estadual da Paraíba, em cumprimento à exigência para obtenção do grau de Bacharel em Ciência da Computação.

Área de concentração: Inteligência Artificial

Orientador: Profa. Dra. Mikaelle Oliveira Santos Gomes

PATOS
2025

É expressamente proibida a comercialização deste documento, tanto em versão impressa como eletrônica. Sua reprodução total ou parcial é permitida exclusivamente para fins acadêmicos e científicos, desde que, na reprodução, figure a identificação do autor, título, instituição e ano do trabalho.

N754a Nóbrega, Gabriel Lira da.

Análise de desempenho de modelos de ia generativa *open source* na sumarização de documentos [manuscrito] / Gabriel Lira da Nóbrega. - 2025.

31 f. : il. color.

Digitado.

Trabalho de Conclusão de Curso (Graduação em Ciência da computação) - Universidade Estadual da Paraíba, Centro de Ciências Exatas e Sociais Aplicadas, 2025.

"Orientação : Prof. Dra. Mikaelle Oliveira Santos Gomes, Coordenação do Curso de Computação - CCEA".

1. Extração de informações. 2. Resumos automáticos. 3. Compreensão de texto. 4. Documentos não estruturados. I. Título

21. ed. CDD 006.31

GABRIEL LIRA DA NÓBREGA

ANÁLISE DE DESEMPENHO DE MODELOS DE IA GENERATIVA OPEN
SOURCE NA SUMARIZAÇÃO DE DOCUMENTOS

Trabalho de Conclusão de Curso
apresentado à Coordenação do Curso
de Ciência da Computação da
Universidade Estadual da Paraíba,
como requisito parcial à obtenção do
título de Bacharel em Ciência da
Computação

Aprovada em: 03/06/2025.

BANCA EXAMINADORA

Documento assinado eletronicamente por:

- **Mikaelle Oliveira Santos Gomes** (***.466.104-**), em **11/06/2025 13:24:27** com chave **8b9688e646e011f0a1611a1c3150b54b**.
- **Giovanna Trigueiro de Almeida Araújo** (***.352.004-**), em **15/06/2025 11:26:51** com chave **c730581649f411f0b8321a7cc27eb1f9**.
- **Jucelio Soares dos Santos** (***.475.114-**), em **11/06/2025 13:37:14** com chave **545afc1646e211f0af8c06adb0a3afce**.

Documento emitido pelo SUAP. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse https://suap.uepb.edu.br/comum/autenticar_documento/ e informe os dados a seguir.

Tipo de Documento: Folha de Aprovação do Projeto Final

Data da Emissão: 15/06/2025

Código de Autenticação: 58e63d



AGRADECIMENTOS

Primeiramente, agradeço a Deus por tudo. Sem Ele, nada disso seria possível. Foi Ele quem me capacitou para conquistar tudo o que venho alcançando até aqui.

Aos meus pais, que sempre estiveram ao meu lado, oferecendo todo o suporte e força ao longo dessa jornada. Em especial, à minha mãe, Maria da Conceição, pela coragem e luta que sempre demonstrou ao longo da vida para me criar e nunca deixar faltar nada. Essa força e dedicação são, até hoje, uma das maiores fontes da minha motivação.

Agradeço também à minha noiva, Verônica, que esteve comigo em todos os momentos dessa caminhada. Sua presença diária, apoio constante e determinação em nunca me deixar desistir foram fundamentais. O amor e a fé que ela sempre teve em mim mostram, com clareza, como o amor pode superar qualquer obstáculo.

Aos meus amigos, que ofereceram apoio, companheirismo e força ao longo do tempo. Acredito que um dos aspectos mais importantes dessa trajetória foi o espírito de colaboração e a troca de conhecimentos entre nós. Isso foi essencial para a conclusão deste trabalho e é algo que valorizo profundamente. A vocês, meus verdadeiros amigos, meu sincero agradecimento.

À minha orientadora, Mikaelle, agradeço por toda a orientação, dedicação e paciência ao longo deste projeto. Seu vasto conhecimento foi fundamental para que eu encontrasse um bom direcionamento. Sou grato pela confiança, pelos conselhos, pelos puxões de orelha e por todo o suporte oferecido ao longo dessa jornada.

A todos vocês, minha mais sincera gratidão. Sem o apoio de cada um, este trabalho não seria possível.

"A maior recompensa para o trabalho do homem não é o que ele ganha com isso, mas o que ele se torna com isso." John Ruskin

RESUMO

A internet é atualmente caracterizada por uma vasta quantidade de dados não estruturados, o que dificulta a busca e a recuperação eficiente de informações relevantes, tornando o processamento desses dados uma tarefa complexa, diante desse cenário, Este estudo apresenta uma análise de desempenho de modelos de IAs generativas open source para extração e sumarização de documentos, onde foi utilizado IAs generativas para facilitar esse processo por meio da sumarização automática de documentos. O desenvolvimento utilizou tecnologias como *Python*, *Hugging Face* e *Google Colab*, além dos modelos *Bart* e *Pegasus*, implementando toda a lógica de sumarização. Para a análise de desempenho, foi utilizada a métrica *Rouge*, que compara os resumos gerados com resumos de referência. Os objetivos foram plenamente atingidos, demonstrando qual dos dois modelos mencionados anteriormente é o mais apropriado para realizar a sumarização de documentos de forma automática. Apesar de algumas limitações na parte de realizar o levantamento dos resultados, foram propostas estratégias para mitigar esses desafios. Assim, este trabalho evidencia a IA generativa como uma aliada na otimização do tempo e na eficiência da gestão de informações.

Palavras-chave: Extração de Informações, Resumos Automáticos, Compreensão de Texto, Documentos Não Estruturados.

ABSTRACT

The internet is currently characterized by a vast amount of unstructured data, making the search and efficient retrieval of relevant information challenging and turning data processing into a complex task. In this context, this study presents a performance analysis of open-source generative AI models for document extraction and summarization, using generative AI to facilitate this process through automatic document summarization. The development employed technologies such as Python, Hugging Face, and Google Colab, along with the Bart and Pegasus models, implementing the complete summarization logic. Performance was evaluated using the Rouge metric, which compares generated summaries with reference summaries. The objectives were fully achieved, identifying which of the two models is most suitable for automatic document summarization. Although some limitations were encountered in result collection, mitigation strategies were proposed. This work demonstrates how generative AI can optimize time and improve information management efficiency.

Key-words: Information Extraction, Automatic Summaries, Text Comprehension, Unstructured Documents.

LISTA DE ILUSTRAÇÕES

Figura 1 – Fluxograma do processo realizado pela aplicação	18
Figura 2 – Processo de extração de resumos e obtenção de resultados	21

LISTA DE TABELAS

Tabela 1 – Métricas Rouge para o resumo gerado pelo modelo de IA generativa <i>Bart</i>	24
Tabela 2 – Métricas Rouge para o resumo gerado pelo modelo de IA generativa <i>Pegasus</i>	24

SUMÁRIO

1	INTRODUÇÃO	10
1.1	Objetivos	11
1.1.1	<i>Objetivo Geral</i>	11
1.1.2	<i>Objetivos Específicos</i>	11
2	REFERENCIAL TEÓRICO	13
2.1	Inteligência Artificial	13
2.2	História e Evolução da Inteligência Artificial	13
2.3	IA Generativa	14
2.4	Modelos de IA Generativa Open Source	15
2.4.1	<i>Bart</i>	15
2.4.2	<i>Pegasus</i>	16
2.5	Ambientes de Desenvolvimento para Modelos de IA Open Source	16
2.5.1	<i>Hugging Face</i>	17
2.6	Compreensão de Documentos Usando IA Generativa	17
3	METODOLOGIA	18
3.1	Obtenção de Modelos de IAs Generativas	19
3.2	Extração de Conteúdo Textual	20
3.3	Preparação do Texto para a Análise	20
3.4	Diferença dos Documentos Usados Para Sumarização	20
3.5	Processo de Geração dos Resumos	20
3.6	Obtenção do Desempenho dos Modelos	21
4	RESULTADOS E DISCUSSÕES	23
4.1	Análise dos Resultados	23
4.2	Desempenho Dos Modelos	23
4.3	Limitações e Desafios da Pesquisa	25
5	CONCLUSÃO	27
5.1	Trabalhos Futuros	27
5.2	Sugestões para Trabalhos Futuros	28
	REFERÊNCIAS	29

1 INTRODUÇÃO

O contexto atual da internet é caracterizado por uma vasta quantidade de dados chamados de "informação não estruturada", ou seja, documentos que não possuem classificação ou metadados associados. Essa situação dificulta a busca e a recuperação eficiente de informações relevantes, tornando o processamento desses dados uma tarefa complexa. Os dados não estruturados incluem tudo, desde documentos à imagens, fluxo de vídeo e áudio à postagens de mídia social, e hoje, esses tipos de dados representam mais de 80 por cento do universo geral de dados digitais, de acordo com o artigo publicado pela MIT Management School Harbert (2021).

Com o advento da era digital, a qualidade e variedade de dados disponíveis na internet têm crescido exponencialmente, em média 2,5 quintilhões de bytes de dados são criados a cada dia em nosso ritmo atual, segundo Marr (2018). Dentre esses dados, os chamados "dados não estruturados" têm desempenhado um papel significativo.

Esses dados não possuem um formato pré-definido ou organizado, abrangendo diversos tipos de informações, como textos em documentos, imagens, áudios, vídeos, postagens em redes sociais e muito mais. Acrescente utilização de plataformas digitais, dispositivos móveis e mídias sociais tem impulsionado a produção massiva de dados não estruturados, tornando-os uma fonte valiosa de informações em várias áreas.

Nesse contexto, a exploração de inteligências artificiais (IAs) generativas, área de estudo dentro de ML, destaca-se como uma abordagem inovadora e poderosa. Ao contrário dos sistemas convencionais de IA que aderem a padrões e regras predeterminadas, a inteligência artificial generativa possui a capacidade singular de criar, ou seja, produzir informações novas/inéditas dependentes dos dados em que foi treinada García-Peñalvo e Vázquez-Ingelmo (2023).

Dessa forma, ela é capaz de gerar conteúdos inéditos, como áudio, arte e texto, mediante aprendizado a partir de um conjunto de dados sem a necessidade de instruções explícitas.

Este estudo tem como objetivo explorar o potencial dos modelos de IA generativa de código aberto, baseados em *Transformers*, para uma compreensão mais clara de documentos, visando aprimorar a geração de resumos e sumarização de documentos textuais.

A proposta no processamento e análise de dados não estruturados permitiu a geração de resumos com mais qualidade, sem a necessidade de pré-classificação dos mesmos. A aplicação dessas técnicas tem impulsionado o acesso a informações relevantes em diversas áreas, proporcionando uma ferramenta valiosa para a tomada de decisões fundamentadas.

Acredita-se que o uso desses modelos para realizar essa tarefa trará maior eficiência e compreensão do contexto, beneficiando a comunicação e interoperabilidade entre diferentes atividades no ambiente da informação.

O objetivo principal deste trabalho foi estudar e explorar modelos de inteligência artificial generativa *open source*, com ênfase na análise e geração de resumos para documentos não estruturados. Para isso, foi desenvolvida uma aplicação em *Python* utilizando bibliotecas como *transformers*, *pdfminer* e *python-docx* para extrair e preparar textos de arquivos PDF e DOCX. O conteúdo extraído é processado por dois modelos de IA, *Bart* (*Facebook*) e *Pegasus* (*Google*), com o objetivo de comparar a qualidade do resumo gerado na tarefa de sumarização de documentos.

Ao utilizar esses modelos citados, foi possível proporcionar uma maneira eficiente e confiável de gerar resumos sobre o conteúdo de documentos, permitindo que os usuários obtenham uma visão geral do conteúdo com base nos assuntos abordados, sem a necessidade de ler o documento por completo.

Os resultados obtidos mostraram que os modelos geraram resumos satisfatórios, mas com variações em termos de qualidade. O modelo *Bart* demonstrou melhor qualidade no conteúdo gerado, enquanto o modelo *Pegasus* ficou abaixo nos resultados em comparação com o outro modelo. Além disso, observou-se que o formato DOCX demandou menos recursos computacionais em comparação ao PDF, o que impactou na velocidade da sumarização. As métricas de avaliação, como o *Rouge*, foram usadas para quantificar a qualidade dos resumos gerados.

1.1 Objetivos

1.1.1 *Objetivo Geral*

O objetivo geral deste trabalho é explorar formas para realizar a compreensão de documentos, de diferentes formatos, e geração de resumos dos mesmos através do uso de modelos de inteligências artificiais generativas *Open Source* (Software Livre).

A proposta consiste em estudar e comparar dois modelos de IAs generativas, visando encontrar soluções eficientes para tarefa de gerar resumos extraindo o contexto principal dos documentos.

1.1.2 *Objetivos Específicos*

- Identificar os passos necessários para realizar o resumo de documentos utilizando modelos de inteligências artificiais generativas.

- Realizar um estudo sobre os modelos de IA generativa *Open Source* disponíveis, compreendendo suas capacidades e limitações.
- Comparar os resultados obtidos pelos modelos de inteligência artificial generativa treinados, analisando a qualidade do resumo gerado.

2 REFERENCIAL TEÓRICO

Neste capítulo, será apresentado o referencial teórico sobre os conceitos e características da temática abordada nesta pesquisa.

2.1 Inteligência Artificial

O surgimento de tecnologias avançadas de IA tem impactado significativamente organizações, sociedades e indivíduos, tornando-se um campo de estudo cada vez mais relevante. Esse desenvolvimento tem impulsionado transformações em diversos setores, como apontado por (SILVA, 2024).

A inteligência artificial é uma área da ciência da computação voltada para a criação de sistemas que imitam a capacidade humana de pensar e decidir. Esses sistemas aprendem com dados e se ajustam com novas informações, permitindo que realizem tarefas antes executadas por humanos e, em alguns casos, desenvolvam novas soluções ao reconhecer padrões como enfatiza Barbosa e Portes (2023).

Segundo Cozman, Plonski e Neri (2021), a IA pode ser caracterizada por agentes inteligentes que representam conhecimento, lidam com incertezas, raciocinam, tomam decisões, aprendem com experiências e interagem com o ambiente. Embora existam conceitos abstratos, a inteligência artificial é principalmente desenvolvida em computadores digitais de silício, envolvendo sistemas capazes de realizar essas funções de maneira sofisticada.

2.2 História e Evolução da Inteligência Artificial

Atualmente, uma vasta quantidade de aplicações e modelos de IA vem sendo apresentada constantemente em uma grande variedade de canais e plataformas. Conseqüentemente, acompanhar esses avanços tem se tornado uma tarefa cada vez mais desafiadora, especialmente para pessoas que estão buscando se inserir na área. Isso ressalta a necessidade de se criar um repositório centralizado que reúna esses desenvolvimentos, proporcionando um acesso mais fácil e facilitando a exploração de todo esse conteúdo (ZAMBOM, 2023).

A aplicação da inteligência artificial tem desempenhado um papel relevante na transformação da sociedade moderna, revolucionando a maneira como vivemos e impactando diversos setores. Exemplos disso incluem assistentes virtuais, comércio eletrônico, tradução automática de texto e atendimento ao cliente por meio de chatbots (FIGUEIREDO; MEDEIROS, 2023).

A IA tem avançado significativamente no Brasil, impulsionada por investimentos públicos e privados, além de políticas nacionais que fomentam a pesquisa e o desenvolvimento na área. Barbosa e Pinheiro (2023) destacam que iniciativas como o Plano Nacional de inteligência artificial têm contribuído para a consolidação do ecossistema de IA no país, promovendo a colaboração entre universidades, empresas e o governo.

No campo do Processamento de Linguagem Natural (PLN), pesquisadores brasileiros têm desenvolvido modelos linguísticos adaptados ao português, considerando as especificidades culturais e linguísticas do país. Silva (2024) apresentam um panorama da evolução da inteligência artificial, desde os primeiros sistemas até os modelos atuais, evidenciando o progresso na área.

A aplicação da IA em setores estratégicos, como a saúde, também tem mostrado resultados promissores. Moraes e Souza (2023) discutem como ferramentas baseadas em inteligência artificial têm sido utilizadas para melhorar o diagnóstico e o prognóstico em cardiologia, contribuindo para a personalização dos cuidados e a tomada de decisões clínicas mais precisas.

Além disso, a adoção de tecnologias de IA pela sociedade brasileira tem crescido significativamente. Rosa (2025) relatam que 63 por cento dos brasileiros já utilizam inteligência artificial em suas rotinas diárias, com 70 por cento tendo iniciado esse uso há menos de um ano, evidenciando a rápida integração dessas tecnologias no cotidiano da população.

Por fim, é importante destacar a preocupação com os aspectos éticos e regulatórios relacionados ao uso da IA no Brasil. Silva e Almeida (2023) analisam as implicações legais da crescente adoção da inteligência artificial, enfatizando a necessidade de políticas públicas que assegurem a transparência, a equidade e a proteção dos direitos fundamentais dos cidadãos.

2.3 IA Generativa

A IA Gerativa representa uma transição de uma abordagem tradicional de inteligência artificial, focada em tarefas de percepção, classificação e previsão, para uma abordagem que visa a criação de conteúdo, como imagens e textos. Embora os fundamentos técnicos dessa tecnologia não sejam novos, o processo de geração se baseia em um aprendizado profundo das características do domínio de atuação, semelhante ao processo de aprendizado de um especialista humano. Esse tipo de inteligência computacional passa por um treinamento intensivo e ajuste fino, até alcançar um domínio adequado para sua aplicação (CORREDERA, 2023).

No entanto, os sistemas de geração de conteúdo parecem trazer particularidades importantes. Um dos principais desafios é a presença de possíveis vieses em várias etapas do processo. Na prática, existem muitos aspectos obscuros e questionáveis, desde os algoritmos

e decisões envolvidas até, principalmente, os conjuntos de dados usados no treinamento. Como resultado, os Modelos de Linguagem de Grande Escala (*Large Language Models, LLMs*) frequentemente acabam reproduzindo vieses e estereótipos presentes nos dados de origem (SAMPAIO et al., 2024).

A IA generativa permite integrar a multimodalidade em seu processo de aprendizagem, aproveitando dados de diferentes formatos, como texto, imagem e conversação, e possibilitando interações similares às de um tutor virtual, que pode esclarecer dúvidas e sugerir atividades. As tecnologias atuais já conseguem extrair conhecimento de grandes volumes de informação disponíveis na Internet, adaptando-o a contextos específicos e a níveis de aprendizagem definidos, sob orientação de um especialista (CORREDERA, 2023).

Desse modo, é indiscutível que a inteligência artificial generativa teve um grande impacto na sociedade atual. Marques e Laipelt (2023), destacam que os modelos de geração automática é uma das invenções mais significativas desde a criação da internet. Diante desse panorama, torna-se necessário e necessário desenvolver uma teoria sobre a degeneração da informação e da desinformação, a fim de analisar suas implicações em um ambiente caracterizado pela pós-realidade.

Em suma, as considerações sobre a IA generativa revelam tanto seu potencial transformador quanto os desafios que apresenta. A capacidade de gerar conteúdo e integrar multimodalidade promete personalizar a aprendizagem e enriquecer as interações, mas é fundamental reconhecer as questões de transparência e os vieses que podem emergir dos dados de treinamento. Além disso, a necessidade de uma teoria que analise a degeneração da informação e a desinformação se torna evidente em um contexto de pós-realidade. Portanto, abordar esses aspectos de forma crítica é importante para garantir que a implementação da inteligência artificial na sociedade seja ética e responsável, maximizando seus benefícios enquanto minimiza seus riscos.

2.4 Modelos de IA Generativa Open Source

A IA generativa cria novos conteúdos, diferentemente dos sistemas tradicionais que apenas processam dados existentes. Utilizando modelos complexos como transformadores, esses sistemas geram respostas variadas a partir de grandes volumes de dados, aplicando abordagens de aprendizado supervisionado, semissupervisionado ou não supervisionado, dependendo do método aplicado (GOZALO-BRIZUELA; GARRIDO-MERCHAN, 2023).

2.4.1 *Bart*

O *Bart* é uma inteligência artificial generativa que tem como foco principal a geração e compreensão de texto, ele é um modelo desenvolvido pelo *Facebook*, ele é particularmente eficaz quando ajustado para geração de texto (por exemplo, resumo, tradução), mas

também funciona bem para tarefas de compreensão (por exemplo, classificação de texto, resposta a perguntas) (LEWIS et al., 2020).

Um dos pontos fortes do *Bart* é a velocidade, graças a sua arquitetura de codificador-codificador transformador, ele comporta grandes quantidades de dados de texto com facilidade. Como por exemplo, resumindo artigos extensos ou fazendo a geração do texto a partir do documento, ele pode fazer isso em um pequeno tempo (FACEBOOK, 2024).

De modo geral, o *Bart* é um modelo flexível que combina alta eficiência com a capacidade de processar grandes volumes de texto rapidamente, sendo útil tanto para compreensão quanto para geração de conteúdo.

2.4.2 *Pegasus*

Também vamos abordar outro modelo de IA generativa, que é o *Pegasus*. Um modelo de linguagem multimodal especializado em compreensão e interação de um determinado conteúdo por meio de linguagem natural (LIU; ZHAO, 2020).

O *Pegasus* se comporta semelhante à sumarização, no entanto, ele trabalha da seguinte maneira, por exemplo, contextos são removidos/mascarados de um determinado documento e são gerados junto com uma sequência de saída a partir das frases restantes, muito semelhante a um resumo extrativo (HUGGINGFACE, 2025).

Em resumo, o *Pegasus* realiza a sumarização ao ocultar partes do texto original e treinar a inteligência artificial para prever os trechos removidos, permitindo que o modelo compreenda o contexto e gere resumos mais coerentes e informativos.

2.5 Ambientes de Desenvolvimento para Modelos de IA Open Source

O uso de ambientes de desenvolvimento open source para IA tem se expandido, promovendo soluções colaborativas e sustentáveis. Iniciativas como o *Enterprise Neurosystem Group* conectam múltiplos modelos de inteligência artificial para melhorar a eficiência e oferecer uma visão abrangente das operações, facilitando a integração de dados e a tomada de decisões estratégicas como aborda Verma et al. (2022).

Adicionalmente, Chun et al. (2024) destacam os benefícios da transparência e flexibilidade oferecidos por ambientes de IA de código aberto, que possibilitam o desenvolvimento conjunto e a detecção de vulnerabilidades de segurança em modelos de inteligência artificial. Esses ambientes oferecem uma plataforma para que pesquisadores colaborem no aprimoramento das práticas de cibersegurança, promovendo uma base sólida para o desenvolvimento de IA com integridade e adaptada a diferentes setores e necessidades.

Esses exemplos ilustram a importância dos ambientes open source no avanço da inteligência artificial, destacando como essas plataformas colaborativas permitem a criação de sistemas interconectados e oferecem flexibilidade para adaptação e inovação contínua, mantendo um nível de transparência crucial para sua aplicação em diferentes contextos.

2.5.1 *Hugging Face*

O *Hugging Face* se destacou como uma plataforma central para IA e NLP (*Natural Language Processing*), oferecendo uma ampla biblioteca de modelos prontos que facilita a integração de soluções avançadas nessas áreas. De acordo com Pol, Vadar e Moharekar (2023), a estrutura da plataforma permite que desenvolvedores implementem rapidamente funcionalidades de NLP, ampliando o alcance dessas tecnologias em diversas aplicações.

Para melhorar a eficiência na busca e reutilização de modelos, engenheiros empregam um sistema de nomeação estruturado, que categoriza os modelos com base em arquitetura, tarefa e dados de treinamento. Conforme Jiang et al. (2024), esse sistema de classificação, distinto das práticas tradicionais de engenharia de software, torna o processo de busca mais direcionado e eficiente. O uso de ferramentas automáticas para detectar anomalias na nomenclatura é sugerido para aumentar a confiabilidade na reutilização dos modelos.

Com o aumento do uso de inteligência artificial de código aberto, surge a preocupação com vulnerabilidades associadas à ampla acessibilidade dos modelos no *Hugging Face*. Segundo Samtani et al. (2023), práticas de segurança robustas são fundamentais para mitigar riscos em um ambiente colaborativo como o da plataforma, assegurando um uso confiável e seguro dos modelos.

2.6 Compreensão de Documentos Usando IA Generativa

A compreensão de documentos usando IA generativa é um campo emergente que aplica modelos de inteligência artificial, como o próprio *ChatGPT*, para interpretar, resumir e extrair informações relevantes de textos. Com técnicas de Processamento de Linguagem Natural (PLN), a inteligência artificial pode gerar resumos automáticos, identificar dados relevantes e facilitar a análise de grandes volumes de documentos.

A compreensão de documentos vai além da simples extração de dados, envolvendo a geração de novas informações com base no texto original, como a criação de imagens, músicas e conteúdo textual. Conforme Cruz (2024), modelos como o *ChatGPT* trouxeram inovações significativas, especialmente na geração de texto, sendo treinados em grandes conjuntos de dados para produzir conteúdos escritos que replicam diversos estilos e formatos.

3 METODOLOGIA

A metodologia deste TCC também contempla aspectos da pesquisa quantitativa, com o objetivo de medir e analisar dados de forma objetiva, utilizando métodos estatísticos para avaliar o desempenho e a eficácia dos sistemas desenvolvidos. Segundo WAZLAWICK (2021), a abordagem quantitativa na ciência da computação é adequada quando se busca validar hipóteses e obter resultados generalizáveis, por meio da coleta sistemática de dados e sua posterior análise numérica. Neste estudo, ela será aplicada para quantificar a qualidade da IA generativa na tarefa de sumarização de documentos, por meio da métrica ROUGE, permitindo uma avaliação precisa e comparável entre dois modelos.

Para viabilizar essa análise, foi desenvolvida uma aplicação utilizando a linguagem *Python*, que oferece bibliotecas robustas e consolidadas voltadas à tarefa de sumarização de documentos. Nesta seção, apresenta-se a metodologia proposta para o desenvolvimento do projeto, descrevendo os recursos utilizados, as etapas de implementação e os critérios de avaliação adotados ao longo do processo.

Outro ponto importante é a integração do *Python* com a plataforma *Hugging Face*, cuja documentação apresenta diversos exemplos de uso nessa linguagem. Isso influenciou a decisão de utilizá-lo no desenvolvimento do projeto.

A plataforma *Hugging Face* disponibiliza várias inteligências artificiais generativas para sumarização de documentos. Neste projeto, foram utilizadas as IAs *Bart*, desenvolvida pelo *Facebook*, e *Pegasus*, do *Google*. O objetivo é analisar a velocidade, o desempenho e comparar o comportamento dessas IAs ao processar documentos nos formatos DOCX e PDF, onde todo o processo é ilustrado conforme a Figura 1.

Figura 1 – Fluxograma do processo realizado pela aplicação



Fonte: Autor(2025)

Na implementação do projeto, foi desenvolvida uma lógica para a extração de texto a partir de documentos nos formatos DOCX e PDF usando as bibliotecas *pdfminer* para a

extração em PDF e *python-docx* para extração do texto em DOCX. Após essa extração, o texto é dividido em segmentos menores, onde na aplicação está sendo feita uma separação do texto original em segmentos, onde cada segmento é armazenado na lista com um limite máximo de 1024 caracteres para cada segmento.

Isso permite que cada segmento seja processado separadamente. Onde esses segmentos são organizados em uma lista, que será enviada para o modelo disponibilizado pela biblioteca *Transformers* do *Hugging Face* para realizar o processamento.

Essa divisão foi necessária devido à limitação da quantidade de *tokens* que a inteligência artificial generativa da plataforma *Hugging Face* suporta por vez. Assim, tornou-se necessário realizar a *tokenização* por segmentos, possibilitando o processamento adequado do conteúdo.

Na etapa seguinte, o modelo realiza a *tokenização*, convertendo o texto em *tokens* para que possa processá-lo corretamente. Essa etapa é importante, pois os modelos de IA trabalham com representações numéricas do texto original. Em seguida, cada segmento é sumarizado individualmente, e os resultados são concatenados para formar o resumo final do documento,

Na parte da concatenação, cada modelo devolve um objeto do tipo *summary text* que contém cada segmento sumarizado, com isso, é criada uma lista antes de recuperar o segmento sumarizado, onde a cada resposta do modelo com o segmento sumarizado, o mesmo é armazenado na lista, que por fim, vai resultar no texto completo sumarizado.

3.1 Obtenção de Modelos de IAs Generativas

Para a obtenção de modelos de Inteligências Artificiais generativas, como mencionado anteriormente, foi utilizado o plataforma *Hugging Face*, que é uma plataforma que disponibiliza uma ampla variedade de modelos de IAs generativas *open source* prontos para uso. Foi selecionado o conjunto de modelos mais adequado às necessidades do estudo.

A escolha pela utilização da plataforma *Hugging Face* surgiu a partir da visualização de um vídeo no canal *Hashtag Programação*, no YouTube. Nesse vídeo, demonstrou-se de forma clara como utilizar a plataforma e destacou-se a facilidade de acesso e uso de diversos modelos voltados para tarefas como resumo de textos, geração de conteúdo, entre outras funcionalidades. A praticidade apresentada e a ampla variedade de modelos disponíveis contribuíram para a decisão de adotar a *Hugging Face* como base para o desenvolvimento deste trabalho.

3.2 Extração de Conteúdo Textual

Foi empregada uma biblioteca de processamento de documentos, como *pdfminer* para documentos no formato PDF ou *python-docx* para DOCX, para extrair o texto do documento. Essa etapa permitirá alimentar o modelo de inteligência artificial generativa com o conteúdo textual necessário para análise, compreensão e geração do resumo.

3.3 Preparação do Texto para a Análise

Após a extração do texto, foi realizada uma preparação para garantir que o conteúdo esteja pronto para ser processado pelos modelos de IA. Isso envolve ajustes na formatação como, por exemplo, exclusão de referências, notas de rodapé, quebra de textos e remoção de informações desnecessárias.

Como os modelos resumizam todo o documento, é necessário que esse documento em questão contenha apenas as informações que fazem parte do contexto geral daquele documento, para otimizar tempo e processamento do modelo na sumarização do arquivo.

Além disso, como os modelos de inteligência artificial possuem uma capacidade limitada de processar grandes quantidades de texto de uma vez, é necessário dividir o conteúdo em partes menores e mais gerenciáveis.

Essa divisão foi feita de maneira estratégica para que cada trecho de texto mantenha seu sentido original e possibilite uma análise eficiente pelo modelo de IA.

3.4 Diferença dos Documentos Usados Para Sumarização

Durante a execução dos testes, foi notada uma diferença significativa no processamento entre os formatos. Os documentos em PDF exigiram um maior uso de recursos computacionais para a sumarização, chegando a sobrecarregar a CPU em determinados momentos. Essa demanda elevada foi evidenciada até mesmo pelo próprio software, que indicava um aumento no consumo de processamento ao executar a tarefa.

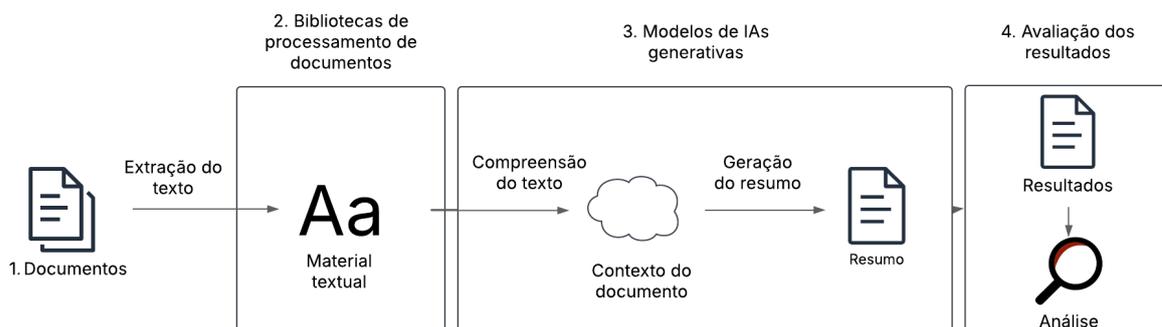
Por outro lado, os documentos em formato DOCX apresentaram um desempenho mais eficiente, realizando a sumarização com menor uso de recursos computacionais em comparação aos arquivos PDF. Essa diferença no consumo de processamento foi um dos principais aspectos observados na análise dos resultados.

3.5 Processo de Geração dos Resumos

Os modelos de inteligência artificial selecionados foram responsáveis por analisar os trechos de texto e gerar resumos automáticos. O processo seguirá algumas etapas importantes:

- Cada parte do texto será enviada para o modelo de IA, que interpretará o conteúdo e gerará um resumo;
- Os resumos gerados para cada trecho serão posteriormente reunidos para formar um único resumo final;
- O resultado será revisado para garantir que a coesão e a clareza sejam mantidas.

Figura 2 – Processo de extração de resumos e obtenção de resultados



Fonte: Autor(2025)

Com esse método, busca-se obter resumos que preservem as informações mais importantes dos documentos, facilitando a compreensão do conteúdo sem comprometer sua essência.

3.6 Obtenção do Desempenho dos Modelos

Durante a realização dos testes de sumarização de documentos, foram utilizados arquivos como artigos e histórias de conto para a comparação entre diferentes inteligências artificiais generativas. Ao todo, foram utilizados cinco documentos, nos formatos DOCX e PDF.

Esses documentos foram selecionados tendo em vista a limitação da métrica utilizada que, por conta da incompatibilidade das bibliotecas da métrica com a linguagem utilizada, que foi o Python, acabou que precisei optar por uma ferramenta auxiliar, que foi o Google Colab, que acabou ficando inviável incluir todo o texto do documento na plataforma para gerar as métricas, onde a plataforma tem um limite de aproximadamente 20.000 a 65.000 caracteres, que para documentos muito extensos, dificultou o levantamento das métricas.

Com base nisso, os 5 documentos utilizados para realizar esse comparativo foram documentos com histórias do tipo conto geradas pelo ChatGPT, para conseguir incluir todo o texto do documento no Google Colab, e assim, realizar o levantamento das métricas a partir dele.

O método utilizado para realizar a análise de desempenho dos modelos foi baseado na métrica *Rouge*, disponibilizada pela própria plataforma *Hugging Face*. A escolha por essa ferramenta foi inspirada em um repositório no *GitHub* da Fernanda Kipper, que utilizou essas mesmas métricas para conduzir uma análise semelhante a deste trabalho.

A métrica *Rouge* avalia a qualidade de resumos automáticos por meio da sobreposição de palavras e frases entre o resumo gerado e um resumo de referência.

Esse método realiza uma comparação baseada em n-gramas, ou seja, em sequências de palavras que aparecem tanto no resumo gerado pela IA quanto em um resumo de referência (considerados ideais). O método avalia quantas dessas palavras ou sequências estão presentes em ambos os textos.

Em seguida, calcula-se a razão entre a quantidade de n-gramas coincidentes e o total de n-gramas do resumo de referência e/ou do gerado. Quanto mais próximo de 1 for esse valor, melhor é considerado o resumo gerado, pois indica que ele contém a maior parte das palavras ou expressões esperadas. Em outras palavras, quanto maior a sobreposição entre o resumo gerado e o de referência, maior a qualidade atribuída ao resumo automático.

4 RESULTADOS E DISCUSSÕES

Neste capítulo, são apresentados os resultados obtidos a partir das avaliações de qualidade do resumo gerado pelas inteligências artificiais generativas usadas para o desenvolvimento do projeto, proporcionando uma visão abrangente do uso de modelos de IA para compreensão e extração de resumos de documentos.

4.1 Análise dos Resultados

Essa análise foi conduzida com base nos resultados da avaliação, comparando a qualidade dos modelos na sumarização dos documentos. Para isso, foi considerada a métrica que avalia a qualidade do resumo gerado, a fim de identificar quais dos dois modelos apresentaram melhor resultado na tarefa proposta.

Para realizar essa análise, foi utilizada a métrica *Rouge*, com base no trabalho de Fernanda Kipper, que também utiliza essa métrica para analisar a qualidade dos modelos de inteligências artificiais generativas na extração de texto de documentos.

Além disso, foi realizada uma análise por tipo de documento, permitindo compreender como cada modelo se comporta em diferentes contextos e identificar possíveis variações no processamento entre os formatos analisados.

4.2 Desempenho Dos Modelos

Para analisar e avaliar a qualidade dos dois modelos de IA generativa, que foi falado anteriormente, foi usada a métrica *Rouge* para realizar o levantamento dos modelos. A seguir segue a explicação do que cada métrica avalia, juntamente com a tabela dos resultados obtidos por cada modelo.

- **Rouge-1:** Mede a quantidade de palavras individuais que aparecem tanto no resumo gerado quanto no resumo de referência;
- **Rouge-2:** Mede a sobreposição de sequências de 2 palavras consecutivas entre o resumo gerado e o de referência;
- **Rouge-3:** Mede a sobreposição de sequências de 3 palavras consecutivas;
- **Rouge-Lsum:** Mede a sequência mais longa de palavras no mesmo pedido que aparece em ambos os resumos.

Na tabela 1 são apresentados os resultados obtidos pela métrica *Rouge* para o resumo gerado pelo modelo de inteligência artificial generativa *Bart*:

Tabela 1 – Métricas Rouge para o resumo gerado pelo modelo de IA generativa *Bart*

Métrica	Valor
<i>Rouge-1</i>	0.5032
<i>Rouge-2</i>	0.4487
<i>Rouge-3</i>	0.4904
<i>Rouge-Lsum</i>	0.5032

Fonte: Autor(2025)

Na tabela 2 são apresentados os resultados obtidos pela métrica ROUGE para o resumo gerado pelo modelo de inteligência artificial generativa *Pegasus*:

Tabela 2 – Métricas Rouge para o resumo gerado pelo modelo de IA generativa *Pegasus*

Métrica	Valor
<i>Rouge-1</i>	0.2691
<i>Rouge-2</i>	0.2271
<i>Rouge-3</i>	0.2618
<i>Rouge-Lsum</i>	0.2618

Fonte: Autor(2025)

Com base nesses dados, podemos notar a diferença na qualidade dos resumos gerados por cada um dos modelos de inteligência artificial generativa, tendo em vista que esse método de avaliação analisa a sobreposição de palavras e frases entre o resumo gerado e o resumo de referência.

Ao compararmos os resultados da métrica *Rouge* com os modelos de IAs generativas *Bart* e *Pegasus*. Como podemos ver, a métrica *Rouge-1* obteve um resultado para inteligência artificial generativa *Bart* de de 0.5032, enquanto para a IA generativa *Pegasus* foi de 0.2691. Lembrando que essa métrica avalia a quantidade de palavras individuais que aparecem tanto no resumo gerado quanto no resumo de referência. Com isso, notamos a diferença de qualidade do *Bart* em relação ao *Pegasus* nesse primeiro caso.

Para melhorar o entendimento desse primeiro resultado obtido pela métrica *Rouge*, vamos exemplificar um caso em que o resultado da *Rouge-1* seja 1. Suponhamos que temos um texto cujo resumo de referência seja "Adorei ler Jogos Vorazes" e o resumo gerado pela inteligência artificial generativa seja "Eu realmente adorei ler Jogos Vorazes". Se formos comparar, as 4 palavras do resumo de referência estão contidas no resumo gerado pela IA. Isso quer dizer que o resultado da métrica *Rouge-1* para esse caso é 1.

A segunda métrica, *Rouge-2*, avalia a sobreposição de sequências de 2 palavras consecutivas entre o resumo gerado e o de referência. Podemos ver que o modelo *Bart* apresentou um resultado de 0.4487, enquanto o *Pegasus* devolveu o resultado de 0.2271.

Assim, notamos que o modelo *Bart* se sobressaiu mais uma vez em relação ao *Pegasus*. Um ponto que devemos analisar é a queda no valor dos dois modelos em relação à primeira métrica. Isso ocorreu devido à elevação do rigor da métrica *Rouge-2* em comparação com a *Rouge-1*, pois agora é avaliada a sobreposição de sequências de 2 palavras, enquanto a *Rouge-1* avalia apenas palavras individuais.

Já na métrica *Rouge-3*, que analisa a sobreposição de sequências de 3 palavras consecutivas, podemos notar que o modelo *Bart* obteve um resultado de 0.4904, e o modelo *Pegasus* entregou o resultado de 0.2618. Mais uma vez, o modelo *Bart* saiu na frente em relação ao *Pegasus*. Contudo, nesta métrica, notamos algo diferente: o modelo *Bart* apresentou um aumento no desempenho em relação à métrica *Rouge-2*. Isso indica que a qualidade do modelo nesta métrica foi melhor para a geração de um resumo, por conta da proximidade com o valor 1. Notamos o mesmo no modelo PEGASUS, que, por sua vez, teve um crescimento em relação à segunda métrica, aproximando-se até da primeira métrica em termos de valores.

Por fim, a última métrica, *Rouge-Lsum*, avalia a sequência mais longa de palavras, na mesma ordem, que aparece em ambos os resumos. Ao analisar, notamos que o modelo *Bart* continuou em uma crescente, apresentando um resultado de 0.5032, enquanto o modelo *Pegasus* trouxe um resultado de 0.2618. Este, por sua vez, manteve-se com o mesmo valor da terceira métrica. Com isso, observamos a discrepância entre os dois modelos, em que o *Bart* foi superior em todas as métricas em relação ao *Pegasus*.

Com base nessa análise, chegamos à conclusão de que, para a tarefa de sumarização de documentos, o modelo que tem mais potencial para entregar um resumo de qualidade, com métricas que comprovam tal feito, é o modelo *Bart*, que apresentou os melhores resultados para essa determinada tarefa.

4.3 Limitações e Desafios da Pesquisa

Um dos principais desafios no levantamento dos dados foi a incompatibilidade das bibliotecas *evaluate* e *datasets*, da Hugging Face, com a versão do *Python* usada no projeto. Essas bibliotecas são importantes, por conta, que são necessárias para utilização da métrica *Rouge* no projeto, mas devido a incompatibilidade com o *Python* impediu sua integração direta e, com isso, foi necessário utilizar uma ferramenta auxiliar para obter esse resultados.

Diante dessa limitação, optei pelo *Google Colab* para a coleta e análise dos dados. Essa abordagem permitiu executar o processo de forma isolada, sem impactar o projeto. No *Google Colab*, pude instalar as bibliotecas necessárias sem restrições, garantindo um ambiente mais controlado e adequado às exigências da análise, evitando erros de compatibilidade ou limitações de sistema. Com isso, consegui mitigar uma das limitações

do meu trabalho, utilizando essa ferramenta como alternativa para obter os resultados da métrica *Rouge*.

5 CONCLUSÃO

Os objetivos propostos neste trabalho foram plenamente atingidos. O objetivo geral — investigar formas de compreender documentos em diferentes formatos e gerar resumos por meio do uso de modelos de inteligência artificial generativa de código aberto (*Open Source*) — demonstrou que essas tecnologias possuem grande potencial para apoiar a análise e a contextualização de conteúdos, além de automatizar tarefas repetitivas e complexas.

Durante o desenvolvimento do trabalho, foram conduzidas análises com modelos de IA generativa, nas quais se avaliou o desempenho, o comportamento frente a distintos tipos de documentos e a capacidade de contextualização de cada modelo. Tais análises possibilitaram uma compreensão crítica sobre as vantagens e limitações das soluções adotadas.

Apesar dos benefícios observados, foram identificadas algumas dificuldades relacionadas à aplicação dessas inteligências artificiais no processo de sumarização, como limitações na compreensão de determinados contextos ou formatos documentais. Contudo, foram propostas alternativas e estratégias para mitigar esses desafios, ampliando o escopo de aplicação das ferramentas utilizadas.

Este trabalho também evidenciou a importância da IA generativa como uma aliada na otimização do tempo e na melhoria da eficiência na gestão de informações, sobretudo em um cenário onde o volume de dados cresce continuamente. Assim, além de explorar uma tecnologia emergente e em constante evolução, o trabalho contribui para o debate sobre suas possibilidades de uso prático, especialmente no contexto da compreensão e sumarização automática de documentos.

5.1 Trabalhos Futuros

Com base no que foi realizado no projeto até então, fica como sugestão de trabalho futuro, é desenvolver treinamento para os modelos de inteligência artificial generativa selecionados com datasets de testes relevantes para tarefa de sumarização e classificação de documentos.

Onde seria utilizados *datasets open source* disponíveis no *Hugging Face*, no *Kaggle*, no *OpenML* e *DataHub*. Esses *datasets* contêm documentos relevantes para a tarefa de extração de contexto e geração de resumos.

5.2 Sugestões para Trabalhos Futuros

- **Compreender a Arquitetura:** Realizar um estudo mais aprofundado sobre a arquitetura de cada modelo e otimizar cada um deles;
- **Analisar Limitações:** Fazer uma análise mais detalhada das limitações de cada modelo para poder extrair o máximo de cada um deles;
- **Treinar Modelos:** Treinar os modelos com a biblioteca *datasets* do próprio *Hugging Face*;
- **Avaliação dos *Datasets*:** Avaliar os modelos treinados para medir sua eficácia na sumarização e classificação de documentos.

REFERÊNCIAS

- BARBOSA, L. F.; PINHEIRO, C. d. R. Inteligência artificial no brasil. **Revista de Informação Legislativa**, Senado Federal, v. 60, n. 240, p. 11–41, 2023. Disponível em: <https://www12.senado.leg.br/ril/edicoes/60/240/ril_v60_n240_p11.pdf>. Citado na página 14.
- BARBOSA, L. M.; PORTES, L. A. F. A inteligência artificial. **Revista Tecnologia Educacional**, Rio de Janeiro, n. 236, p. 16–27, 2023. [online]. Citado na página 13.
- CHUN, A. et al. Risks and opportunities of open-source generative ai. **SSRN Electronic Journal**, 2024. Accessed on October 29, 2024. Disponível em: <<https://core.ac.uk/download/pdf/613712440.pdf>>. Citado na página 16.
- CORREDERA, J. C. Inteligencia artificial generativa. In: **Anales de la Real Academia de Doctores**. [S.l.: s.n.], 2023. p. 475–489. Citado nas páginas 14 e 15.
- COZMAN, F. G.; PLONSKI, G. A.; NERI, H. **Inteligência Artificial**. São Paulo: Blucher, 2021. Citado na página 13.
- CRUZ, F. A. **GenAI e acessibilidade: uma abordagem inclusiva para documentos textuais**. 59 p. Trabalho de Conclusão de Curso (Bacharelado em Ciência da Computação) — Universidade Estadual de Londrina, Centro de Ciências Exatas, Londrina, 2024. Acesso em: 16 out. 2024. Disponível em: <https://sites.uel.br/dc/wp-content/uploads/2024/06/TCC_FELIPE_CRUZ.pdf>. Citado na página 17.
- FACEBOOK. Bart large cnn. **Dataloop**, 2024. Disponível em: Dataloop AI. Acesso em: 19 fev. 2025. Disponível em: <https://dataloop.ai/model/facebook_bart-large-cnn/index.html>. Citado na página 16.
- FIGUEIREDO, J. E. D. S.; MEDEIROS, M. do D. Evolução da ia: Inteligência artificial na contemporaneidade. humanos interpretados como “máquinas semânticas”. In: **Título do Livro (adicionar título, se disponível)**. [S.l.: s.n.], 2023. p. 82. Citado na página 13.
- GARCÍA-PEÑALVO, F.; VÁZQUEZ-INGELMO, A. What do we mean by genai? a systematic mapping of the evolution, trends, and techniques involved in generative ai. **IJIMAI**, 2023. Disponível em: IJIMAI. Acesso em: 13 fev. 2025. Disponível em: <<https://www.ijimai.org/journal/bibcite/reference/3348>>. Citado na página 10.
- GOZALO-BRIZUELA, R.; GARRIDO-MERCHAN, E. C. Chatgpt is not all you need. a state of the art review of large generative ai models. **arXiv preprint arXiv:2301.04655**, 2023. Citado na página 15.
- HARBERT, T. Tapping the power of unstructured data. **Mit Management School**, 2021. Disponível em: MIT Sloan. Acesso em: 18 fev. 2025. Disponível em: <<https://mitsloan.mit.edu/ideas-made-to-matter/tapping-power-unstructured-data>>. Citado na página 10.

HUGGINGFACE. Pegasus. **HuggingFace**, 2025. Disponível em: HuggingFace. Acesso em: 19 fev. 2025. Disponível em: <https://huggingface.co/docs/transformers/model_doc/pegasus>. Citado na página 16.

JIANG, W. et al. **Naming Practices of Pre-Trained Models in Hugging Face**. 2024. Accessed on 29 Oct. 2024. Disponível em: <<https://wenxin-jiang.github.io/files/publications/PTMNaming.pdf>>. Citado na página 17.

LEWIS, M. et al. Bart: Denoising sequence-to-sequence pre-training for natural language generation, translation, and comprehension. **Research facebook**, 2020. Disponível em: Research facebook. Acesso em: 19 fev. 2025. Disponível em: <<https://research.facebook.com/publications/bart-denoising-sequence-to-sequence-pre-training-for-natural-language-generation-translation-and-comprehension/>>. Citado na página 16.

LIU, P. J.; ZHAO, Y. Pegasus: A state-of-the-art model for abstractive text summarization. **Research Google**, 2020. Disponível em: Research Google. Acesso em: 19 fev. 2025. Disponível em: <<https://research.google/blog/pegasus-a-state-of-the-art-model-for-abstractive-text-summarization/>>. Citado na página 16.

MARQUES, S. D.; LAIPELT, R. d. C. F. Pós-realidade e teoria da desinformação: inquietações sobre o uso massivo de ia generativa. In: **Anais do Fórum de Estudos em Informação, Sociedade e Ciência**. Porto Alegre: UFRGS, PPGCIN, 2023. v. 5. Citado na página 15.

MARR, B. How much data do we create every day? the mind-blowing stats everyone should read. **Forbes**, 2018. Disponível em: Forbes. Acesso em: 13 fev. 2025. Disponível em: <<https://www.forbes.com/sites/bernardmarr/2018/05/21/how-much-data-do-we-create-every-day-the-mind-blowing-stats-everyone-should-read/>>. Citado na página 10.

MORAES, A. B. d.; SOUZA, C. H. d. Inteligência artificial e saúde: Aplicações na cardiologia. **Revista Brasileira de Cardiologia**, Sociedade Brasileira de Cardiologia, v. 36, n. 2, p. 123–130, 2023. Citado na página 14.

POL, U. R.; VADAR, P. S.; MOHAREKAR, T. T. **Hugging Face: Revolutionizing AI and NLP**. 2023. ResearchGate, accessed on 29 Oct. 2024. Disponível em: <<https://www.researchgate.net/publication/383497950>>. Citado na página 17.

ROSA, **Inteligência artificial no Brasil: avanços, aplicações e perspectivas**. 2025. Acesso em: 09 maio 2025. Disponível em: <<https://softdesign.com.br/blog/inteligencia-artificial-no-brasil/>>. Citado na página 14.

SAMPAIO, R. C. et al. Chatgpt e outras ias transformarão a pesquisa científica: reflexões sobre seus usos. **Revista de Sociologia e Política**, v. 32, p. e008, 2024. Citado na página 15.

SAMTANI, S. et al. **Assessing the Vulnerabilities of the Open-Source Artificial Intelligence (AI) Landscape: A Large-Scale Analysis of the Hugging Face Platform**. 2023. ResearchGate, accessed on 29 Oct. 2024. Disponível em: <<https://www.researchgate.net/publication/372761501>>. Citado na página 17.

SILVA, J. P.; ALMEIDA, F. Impactos jurídicos da inteligência artificial no brasil. **Revista de Direito e Tecnologia**, Universidade de São Paulo, v. 15, n. 1, p. 45–60, 2023. Citado na página 14.

SILVA, M. A. B. d. **Do Eliza ao ChatGPT: História e Evolução da Inteligência Artificial**. PUC Goiás, 2024. Disponível em: <<https://repositorio.pucgoias.edu.br/jspui/handle/123456789/7928>>. Citado na página 14.

SILVA, T. L. e. a. D. Inteligência artificial generativa no ensino de programação: um mapeamento sistemático da literatura. **Revista Novas Tecnologias na Educação**, v. 22, n. 1, p. 262–272, 2024. Citado na página 13.

VERMA, D. et al. **Open Source Collaborative AI Development in the Enterprise Neurosystem Group**. 2022. Accessed on October 29, 2024. Disponível em: <<https://sciforum.net/manuscripts/12636/manuscript.pdf>>. Citado na página 16.

WAZLAWICK, R. S. **Metodologia de Pesquisa para Ciência da Computação**. 3. ed. Rio de Janeiro - RJ: GEN, 2021. Citado na página 18.

ZAMBOM, E. d. G. **Uma ferramenta interativa para exploração do universo de inteligência artificial gerativa**. 2023. Trabalho de Conclusão de Curso. Citado na página 13.