



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE HUMANIDADES
DEPARTAMENTO DE ESTUDOS DA LÍNGUA INGLESA, SUAS LITERATURAS E
TRADUÇÃO
CURSO SUPERIOR DE LICENCIATURA EM LÍNGUA INGLESA

LEONARDO NATÃ SILVA DAMASCENO

TRADUÇÃO AUTOMÁTICA E INTELIGÊNCIA ARTIFICIAL: UMA ANÁLISE
HISTORIOGRÁFICA E PERSPECTIVAS FUTURAS

FORTALEZA

2025

LEONARDO NATÃ SILVA DAMASCENO

TRADUÇÃO AUTOMÁTICA E INTELIGÊNCIA ARTIFICIAL: UMA ANÁLISE
HISTORIOGRÁFICA E PERSPECTIVAS FUTURAS

Trabalho de conclusão de curso apresentado ao curso de Letras-Inglês do Departamento de Estudos da Língua Inglesa, suas Literaturas e Tradução da Universidade Federal do Ceará, como requisito parcial à obtenção do título de licenciado em Letras-Inglês.

Orientador: Prof. Dr. Fabio Nunes Assunção

FORTALEZA

2025

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- D162t Damasceno, Leonardo Natã Silva.
Tradução automática e Inteligência Artificial : Uma análise historiográfica e perspectivas futuras /
Leonardo Natã Silva Damasceno. – 2025.
29 f. : il. color.
- Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Centro de Humanidades,
Curso de Letras (Inglês), Fortaleza, 2025.
Orientação: Prof. Dr. Fabio Nunes Assunção.

1. Tradução automática. 2. Inteligência Artificial. 3. Translationese. I. Título.

CDD 420

LEONARDO NATÃ SILVA DAMASCENO

TRADUÇÃO AUTOMÁTICA E INTELIGÊNCIA ARTIFICIAL: UMA ANÁLISE
HISTORIOGRÁFICA E PERSPECTIVAS FUTURAS

Trabalho de conclusão de curso apresentado ao curso de Letras-Inglês do Departamento de Estudos da Língua Inglesa, suas Literaturas e Tradução da Universidade Federal do Ceará, como requisito parcial à obtenção do título de licenciado em Letras-Inglês.

Aprovada em: ___/___/___.

BANCA EXAMINADORA

Prof. Dr. Fábio Nunes Assunção (Orientador)
Universidade Federal do Ceará (UFC)

Profa. Dra. Diana Costa Fortier Silva
Universidade Federal do Ceará (UFC)

Profa. Dra. Lídia Amelia de Barros Cardoso
Universidade Federal do Ceará (UFC)

AGRADECIMENTOS

Agradeço à minha família, meu pai e minha avó por todo incentivo e apoio que me deram em tudo que eu tentei, nada disso seria possível sem eles.

Agradeço a Deus.

E agradeço ao professor Fábio Nunes pela orientação e suporte ao longo de toda produção dessa pesquisa.

RESUMO

Nas últimas décadas, a evolução das tecnologias digitais remodelou significativamente o campo da tradução, especialmente com o surgimento dos sistemas de tradução automática e, mais recentemente, das inteligências artificiais generativas (IAs). Este estudo investiga a intervenção da IA na tradução adotando uma abordagem metodológica mista qualitativa, quantitativa, exploratória e historiográfica para examinar os aspectos técnicos, históricos e sociais dessa transformação. A pesquisa está estruturada em três etapas: uma revisão bibliográfica sobre o desenvolvimento histórico da tradução automática (dos sistemas baseados em regras até os sistemas neurais e generativos), uma análise comparativa de motores de tradução (como Google Tradutor, DeepL, Amazon Translate e modelos baseados em GPT), e um estudo prospectivo sobre tendências e desafios futuros. Os resultados mostram que, embora os Grandes Modelos de Linguagem (LLMs), como o GPT-4, superem os sistemas tradicionais de Tradução Automática Neural (NMT) em fluência contextual e adaptabilidade, eles ainda apresentam traços de *translationese* e enfrentam limitações em idiomas com poucos recursos. O estudo conclui que o futuro da tradução está em modelos híbridos que combinem o poder generativo dos LLMs com ajustes específicos por domínio, junto à contínua relevância dos tradutores humanos para garantir qualidade, ética e nuances culturais.

Palavras-chave: tradução automática; inteligência artificial; *translationese*.

ABSTRACT

Over the past decades, the evolution of digital technologies has significantly reshaped the field of translation, especially through the emergence of machine translation systems and, more recently, generative artificial intelligences (AIs). This study investigates the intervention of AI in translation by adopting a mixed methodological approach qualitative, quantitative, exploratory, and historiographical to examine the technical, historical, and social aspects of this transformation. The research is structured in three stages: a literature review of the historical development of machine translation (from Rule-Based to Neural and Generative systems), a comparative analysis of translation engines (such as Google Translate, DeepL, Amazon Translate, and GPT-based models), and a prospective study on future trends and challenges. Results show that although Large Language Models (LLMs) like GPT-4 outperform traditional Neural Machine Translation (NMT) systems in contextual fluency and adaptability, while still exhibit translationese traits and face limitations in under-resourced languages. The study concludes that the future of translation lies in hybrid models that combine the generative power of LLMs with domain-specific fine-tuning, alongside the continued relevance of human translators in ensuring quality, ethics, and cultural nuance.

Keywords: machine translation; artificial intelligence; translationese.

SUMÁRIO

1	INTRODUÇÃO	9
2	FUNDAMENTAÇÃO TEÓRICA	10
2.1	Breve história da tradução automática	10
2.2	Tecnologias atuais de tradução automática	11
<i>2.2.1</i>	<i>Google Tradutor</i>	<i>12</i>
<i>2.2.2</i>	<i>DeepL</i>	<i>13</i>
<i>2.2.3</i>	<i>Amazon Translate</i>	<i>14</i>
<i>2.2.4</i>	<i>Bing Microsoft Translator</i>	<i>14</i>
<i>2.2.5</i>	<i>Systran Translate</i>	<i>16</i>
2.3	O advento do uso das I.As generativas	17
3	METODOLOGIA	21
4	ANÁLISE DOS DADOS	24
5	CONCLUSÃO	31
	REFERÊNCIAS	33

1 INTRODUÇÃO

Nas últimas décadas, o avanço das tecnologias digitais tem promovido profundas transformações em diversas áreas do conhecimento, sendo a tradução uma das mais impactadas. A introdução de ferramentas de tradução automática e, mais recentemente, o uso de inteligências artificiais generativas (IAs), tem remodelado não apenas os métodos de tradução, mas também as atribuições e competências dos profissionais da área. Embora a ideia de máquinas substituindo o trabalho humano pareça recente, ela remonta a discussões pós-Segunda Guerra Mundial, quando surgiram os primeiros sistemas automáticos desenvolvidos para fins estratégicos e militares. Desde então, os sistemas evoluíram de regras rígidas para modelos probabilísticos e, posteriormente, redes neurais capazes de simular estruturas cognitivas complexas (Melo, 2013) esse processo histórico culmina atualmente com a chegada dos Grandes Modelos de Linguagem (LLMs), como o ChatGPT, cuja capacidade vai além da tradução literal, permitindo a interpretação contextual e a produção textual autônoma (LIONBRIDGE, 2023).

Este trabalho tem como objetivo geral investigar as possibilidades de intervenção da inteligência artificial na tradução, considerando os aspectos técnicos, históricos e sociais que envolvem essa evolução. Para isso, adota-se uma abordagem mista qualitativa, quantitativa, exploratória e historiográfica que permite a análise de diferentes perspectivas sobre o tema.

Dentre os objetivos específicos estão: investigar o desenvolvimento histórico e técnico da tradução automática, desde os modelos baseados em regras até os sistemas neurais contemporâneos; comparar dados de desempenho e características linguísticas entre os modelos tradicionais e os modelos generativos atuais, como os LLMs; e propor um estudo prospectivo sobre o futuro da tradução automatizada, analisando tendências tecnológicas e possíveis implicações sociais e profissionais.

A relevância deste estudo reside na necessidade urgente de compreender o papel transformador da IA sobre a tradução e suas implicações para profissionais, educadores e pesquisadores. Em um cenário marcado pela aceleração tecnológica, discutir tais questões se torna fundamental para a formação crítica de tradutores e para o estabelecimento de práticas éticas e eficazes no uso dessas ferramentas.

A metodologia será composta por três etapas principais: uma revisão bibliográfica sobre a evolução da tradução automática; uma análise comparativa entre os modelos existentes, com base em dados secundários e relatórios técnicos; e um estudo prospectivo sobre os impactos futuros das IAs generativas na área de tradução.

2 FUNDAMENTAÇÃO TEÓRICA

Muito se discute sobre a possível ameaça que as I.As (inteligências artificiais) representam para o trabalho humano. A ideia de que as máquinas tomariam nossos empregos, apesar de ser bastante falada atualmente, já é um tema antigo. Tratando-se de tradução, por exemplo, os tradutores automáticos surgiram bem antes e já geravam desconfiança. Sua origem data do período pós-Segunda Guerra Mundial, quando, na Guerra Fria, fazia-se necessário máquinas para traduzir as mensagens criptografadas do russo para o inglês (Melo, 2013). Sua evolução constante a partir desse momento fundamentou as bases para a criação dos sistemas de I.A que temos hoje. Com base nos estudos de Hutchins (1995, 2006) e Vaswani *et al* (2017), a presente pesquisa discute, neste capítulo, os seguintes temas: breve história da tradução automática, suas tecnologias e o advento do uso das I.As generativas.

2.1 Breve história da tradução automática

Um dos primeiros experimentos na área foi realizado pela Georgetown IBM em 1954, traduzindo 49 frases do russo para o inglês (Hutchins, 1995). Nas décadas de 1950 e 1960, foi introduzido o método conhecido como *Rule Based Machine Translation*¹ (RBMT), que se baseava no uso de regras gramaticais estritas e dicionários (Poibeau, 2009).

Apesar de representar uma evolução significativa para os padrões da época, o RBMT era inflexível na adaptação à fluidez da linguagem e enfrentava dificuldades em idiomas menos conhecidos e com recursos limitados (Poibeau, 2009).

Em 1996, o relatório *Automatic Language Processing Advisory Committee*² (ALPAC) reduziu as expectativas em relação à tradução automática nos Estados Unidos, afirmando que a tecnologia ainda não estava pronta para aplicações práticas, o que desencorajou investimentos significativos na área (Hutchins, 2006). Enquanto isso, outras regiões como a URSS e o Japão continuaram a avançar em suas pesquisas.

O interesse pela tradução automática ressurgiu nas décadas de 1980 e 1990 com o desenvolvimento da *Statistical Machine Translation*³ (SMT). Esse método permitiu que as máquinas aprendessem a partir de grandes *corpora* bilíngues, isto é, bancos de dados e textos

¹ Tradução Automática Baseada em Regras (todas as traduções foram feitas pelo presente autor)

² Comitê Consultivo de Processamento Automático de Linguagem

³ Tradução Automática Estatística

com os dois idiomas, para serem comparados pela máquina, melhorando a precisão das traduções em comparação com o RBMT (Manning & Schütze, 1999).

Um dos modelos mais proeminentes de SMT foi desenvolvido pela IBM, que utilizou um *framework* matemático baseado em probabilidades para lidar com a fluidez da linguagem, oferecendo uma abordagem mais flexível e ajustável (Manning & Schütze, 1999).

Em 2014, surgiram as redes neurais profundas, que simulam o processamento cerebral humano ao passar informações por diversas camadas de análise de dados e probabilidades. A *Neural Machine Translation*⁴ (NMT), introduzida nesse período, revolucionou a tradução automática ao incorporar o modelo "*Seq2Seq*"⁵, o qual trabalha com um codificador.

Este codificador recebe a mensagem no texto original, faz análises dela e de seu contexto, e quando possui as informações necessárias, as passa para o decodificador. O decodificador, utilizando essas informações, traduz a frase de maneira mais funcional, além dos mecanismos de atenção que tornam a máquina capaz de focar em qualquer parte da frase, diminuindo bastante a perda de sentidos e permitindo uma tradução mais contextual e precisa (VASWANI *et al.*, 2017).

Essas inovações culminaram no modelo Transformer, introduzido em 2017, que elevou ainda mais as capacidades da NMT e foi utilizado em diversas aplicações de IA generativas, como o ChatGPT, Generative Pre-trained Transformer⁶ (GPT) (Vaswani *et al.*, 2017).

2.2 Tecnologias atuais de tradução automática

Nos últimos anos, a tecnologia de tradução automática evoluiu significativamente, tornando-se uma ferramenta essencial para a comunicação global. Diversos serviços de tradução, como Google Tradutor, DeepL Translator, Amazon Translate, Bing Microsoft Translator e Systran Translate, utilizam avançados modelos de aprendizado de máquina para fornecer traduções cada vez mais precisas e naturais. Desde a popularidade e acessibilidade do *Google Tradutor* até a precisão refinada do DeepL, cada ferramenta apresenta características específicas que atendem a diferentes necessidades. Enquanto algumas soluções são gratuitas e amplamente utilizadas pelo público geral, outras, como o Amazon Translate, oferecem recursos personalizáveis voltados para empresas. Essa diversidade de opções reflete a crescente demanda por traduções rápidas e eficientes em um mundo cada vez mais interconectado.

⁴ Tradução Automática Neural

⁵ Sequência para Sequência

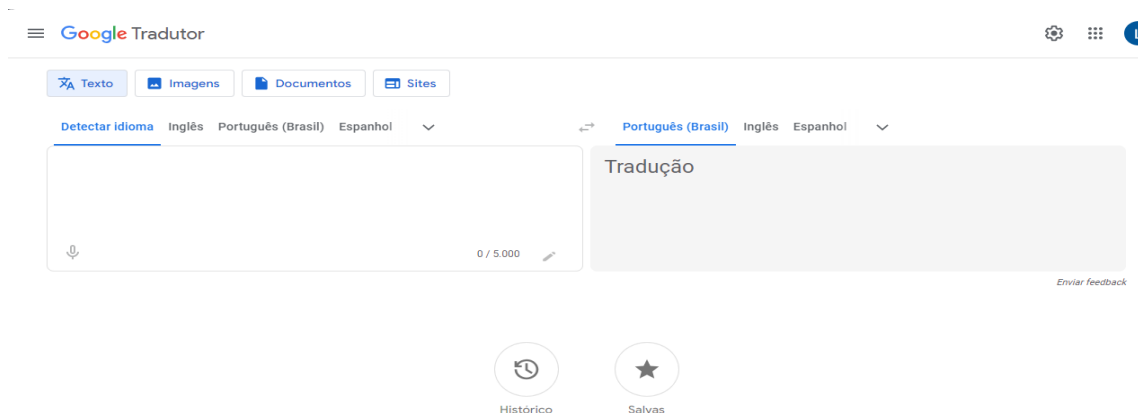
⁶ Transformador Generativo Pré-treinado

Posto isso, com o advento das inteligências artificiais generativas, observa-se uma evolução significativa na capacidade de produzir traduções mais naturais. No entanto, mesmo as tecnologias atuais de tradução automática neural (NMT), como DeepL e Google Translate, ainda geram textos que exibem características distintas daqueles escritos originalmente na língua alvo por falantes nativos. Essas diferenças, denominadas artefatos de tradução (translation artifacts), também conhecidas como *translationese* manifestam-se, por exemplo, no uso excessivo de pontuação e determinantes, e na subutilização de advérbios (ADV) e verbos auxiliares (AUX), tornando as traduções mais literais e rígidas (Sizov et al., 2024). Traduções humanas, por outro lado, apresentam maior diversidade lexical e padrões mais alinhados ao discurso nativo, sendo mais difíceis de distinguir de textos originais.

2.2.1 Google Tradutor

O Google Tradutor, também conhecido como Google Translate, é provavelmente um dos mecanismos de tradução automática mais conhecidos no mundo. Lançado em 2006 pela gigante Google, essa ferramenta gratuita é capaz de traduzir textos, documentos e sites *online*. Inicialmente, o Google Tradutor utilizava a tradução automática estatística (*Statistical Machine Translation* - SMT), mas em 2016 migrou para o método mais avançado de tradução automática neural (*Neural Machine Translation* - NMT) para aumentar a precisão das traduções (RapidTranslate, 2024)

Figura 1 - Google Tradutor



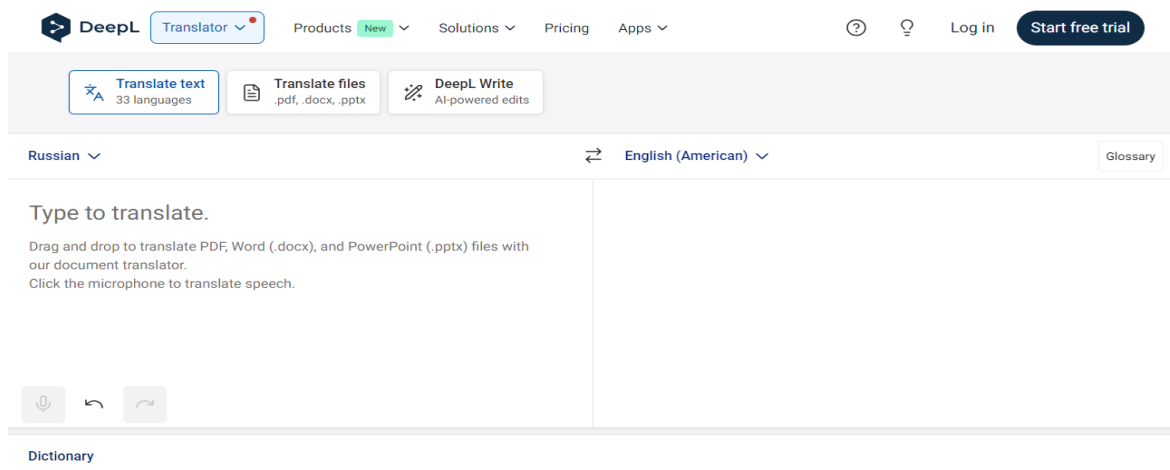
Fonte: <https://translate.google.com.br/?sl=auto&tl=pt&op=translate>

Com uma interface simples e de fácil navegação, o *Google Tradutor* oferece suporte a mais de 130 idiomas, além de funcionalidades adicionais, como a tradução de imagens e texto manuscrito. Essa combinação de acessibilidade, variedade de idiomas e múltiplas funcionalidades garante uma alta porcentagem de uso entre os usuários em todo o mundo.

2.2.2 DeepL

O DeepL Translator, desenvolvido pela empresa alemã DeepL GmbH (antiga Linguee GmbH), é conhecido por sua precisão e refinamento nas traduções. Lançado em 2017, o DeepL utiliza a tecnologia de Tradução Automática Neural (*Neural Machine Translation - NMT*), que permite maior fluidez e consistência no contexto das frases traduzidas. Uma das principais vantagens do DeepL em comparação com outras ferramentas é sua capacidade de "aprender" a partir de fontes linguísticas confiáveis, o que garante traduções mais naturais. (RapidTranslate, 2024)

Figura 2 - DeepL Translate



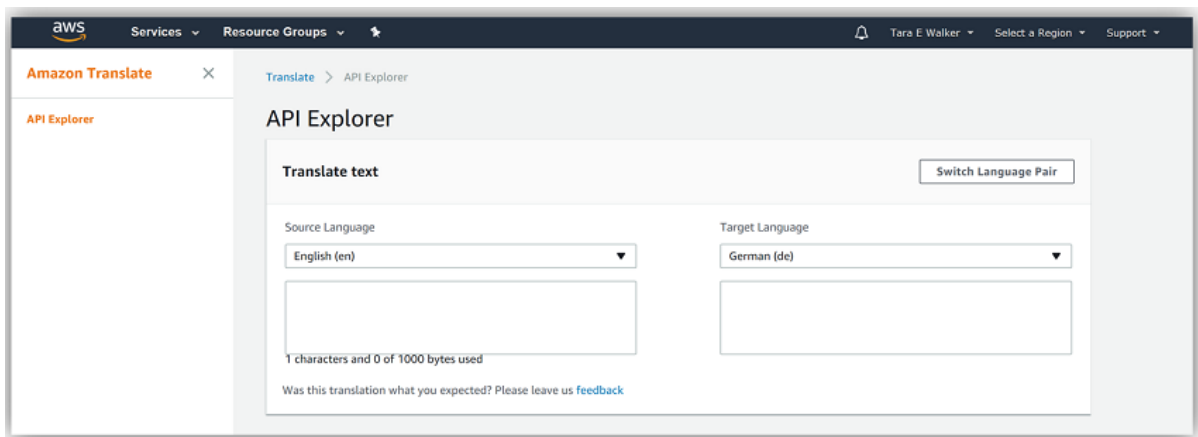
Fonte: <https://www.deepl.com/pt-BR/translator>

Com suporte para 32 idiomas e 800 combinações linguísticas, o DeepL é amplamente usado tanto em traduções de textos quanto em documentos de diversos formatos. Sua interface amigável, disponível para Windows e iOS, permite fácil navegação e uso eficiente. O DeepL também é frequentemente destacado como o tradutor mais preciso em avaliações de usuários e especialistas.

2.2.3 Amazon Translate

O Amazon Translate é um serviço de tradução automática pago que utiliza modelos de aprendizado profundo (*Deep Learning*) para fornecer traduções rápidas e de alta qualidade. Lançado como parte da Amazon Web Services (AWS), esse serviço é projetado para entregar traduções automáticas personalizáveis e acessíveis, sendo amplamente usado por empresas e desenvolvedores (RapidTranslate, 2024).

Figura 3 - Amazon Translate



Fonte: <https://aws.amazon.com/pt/translate>.

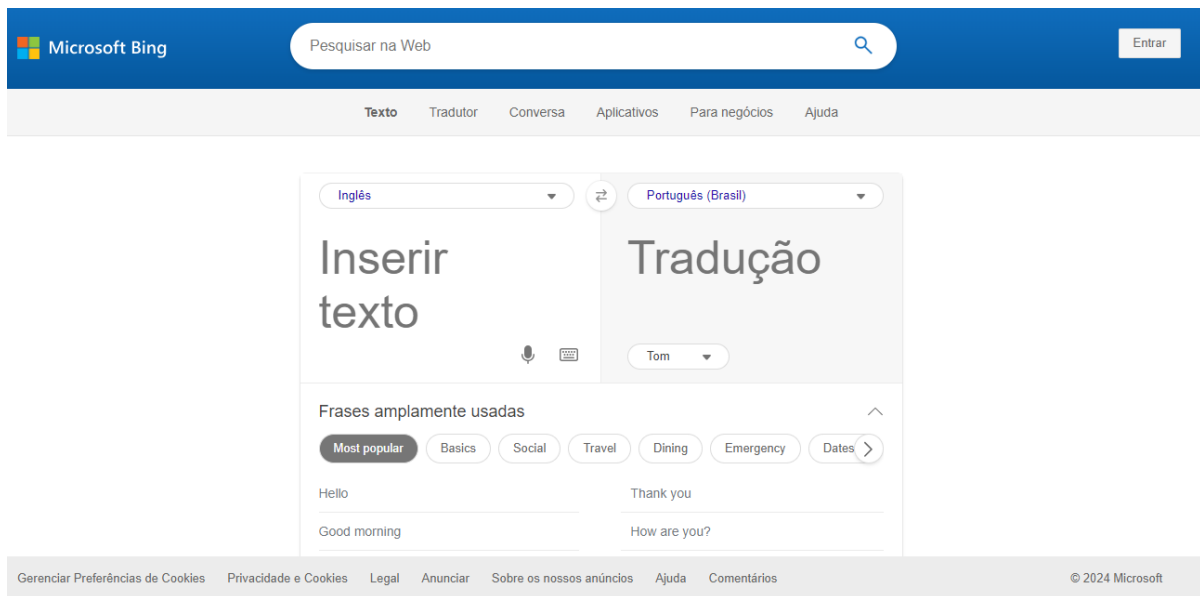
O Amazon Translate oferece suporte a múltiplos formatos de conteúdo, como docx, pptx e xlsx, e se destaca por sua capacidade de traduzir grandes volumes de texto com alta precisão, atualizando constantemente seus conjuntos de dados. Ele também permite que os usuários personalizem as traduções com dados específicos, proporcionando mais controle sobre o tom e a terminologia usada.

Essa ferramenta é amplamente utilizada na localização de conteúdo para *websites*, *blogs* e aplicativos, além de fornecer traduções automáticas em interações como *chats*, *e-mails*, *helpdesk* e emissão de *tickets* para melhorar a comunicação entre diferentes idiomas.

2.2.4 Bing Microsoft Translator

O Bing Microsoft Translator, parte dos Serviços Cognitivos da Microsoft, é uma ferramenta de tradução automática integrada a vários produtos da Microsoft, como o Bing, Microsoft Office, e Microsoft Edge. Lançado em 2007, ele utiliza a tecnologia NMT (*Neural Machine Translation*) para produzir traduções de alta qualidade e precisa (RapidTranslate, 2024).

Figura 4 - Bing Microsoft Translator



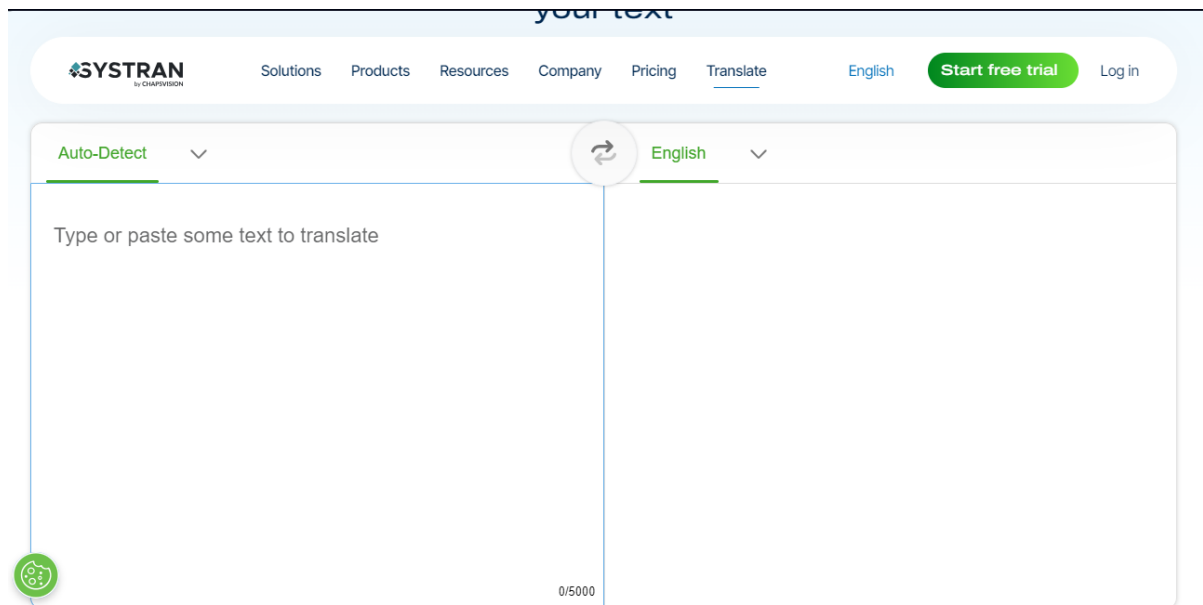
Fonte: <https://www.bing.com/translator?cc=br>.

Com suporte para mais de 135 idiomas, o Bing Translator oferece traduções de textos, imagens e até voz, o que o torna uma opção versátil para diferentes necessidades de tradução. Sua integração em diversos aplicativos garante uma experiência eficiente e amigável, seja no ambiente corporativo ou no dia a dia dos usuários.

2.2.5 Systran Translate

O Systran Translate é um dos mais antigos sistemas de tradução automática, lançado em 1968, com mais de 50 anos de experiência no setor. Inicialmente focado em serviços comerciais, o Systran hoje usa NMT (*Neural Machine Translation*) para oferecer traduções em tempo real de textos, documentos, imagens e *e-mails* (RapidTranslate, 2024).

Figura 5 - Systran Translate



Fonte: <https://www.systransoft.com/translate/>

Com suporte para mais de 55 idiomas, o Systran é amplamente utilizado por grandes corporações, incluindo gigantes como Yahoo, Google e NASA. Sua capacidade de lidar com grandes volumes de conteúdo, como arquivos e pastas completos, facilita a comunicação interna em grandes empresas e entre equipes de diferentes regiões do mundo.

2.3 O advento do uso das IAs generativas

As IAs generativas são novos modelos de inteligência artificial que, analisando, imitando e se baseando em dados, padrões, obras, textos, músicas, códigos, etc., são capazes de criar algo novo de maneira totalmente autônoma, em vez de apenas analisar ou classificar dados já existentes (Goodfellow et al., 2014). A inteligência artificial generativa tem se tornado um campo de grande interesse devido ao seu potencial de revolucionar diversas áreas, desde a arte até a ciência de dados.

Usando como base o conceito de redes neurais profundas, a inteligência artificial foi tomando forma e, em 2014, o modelo de *Generative Adversarial Networks*⁷, conhecido como "GANs", foi introduzido. O modelo funciona com base na competição entre duas redes neurais: a rede geradora, que cria amostras sintéticas de imagens, músicas e várias formas de arte; e a rede discriminadora, que tenta distinguir entre a obra original e a obra criada pela rede geradora, resultando em uma melhoria contínua do sistema e na produção de obras, com ambas as redes neurais evoluindo juntas (Goodfellow et al., 2014).

Em 2013, foram propostos os *Autoencoders Variacionais* (VAEs), que têm um sistema parecido com os GANs, porém o codificador e o decodificador deles não competem entre si. Enquanto os GANs analisam padrões e estilos de forma mais geral, os VAEs transformam a obra em uma representação latente, que é um espaço de dimensões reduzidas, tendo um foco maior no detalhamento e em dados mais sutis do que os GANs, focando assim em trabalhos mais minuciosos, como detecção de anomalias, fraudes em dados e compressão de dados (Kingma & Welling, 2013).

Em 2017, um novo marco foi alcançado com a introdução dos Transformers, com suas capacidades de atenção multi-cabeça, permitindo que o modelo se concentre em diferentes partes da entrada simultaneamente, entendendo múltiplas relações de padrões e dados ao mesmo tempo. Sua capacidade de processar em paralelo todas as informações de entrada, além de sua alta escalabilidade, possibilita sua utilização para várias funções, como o próprio ChatGPT (Vaswani et al., 2017).

Os modelos de inteligência artificial generativa, como o ChatGPT⁸, lançados pela OpenAI em 2022, estão transformando a forma como interagimos com a tecnologia ao

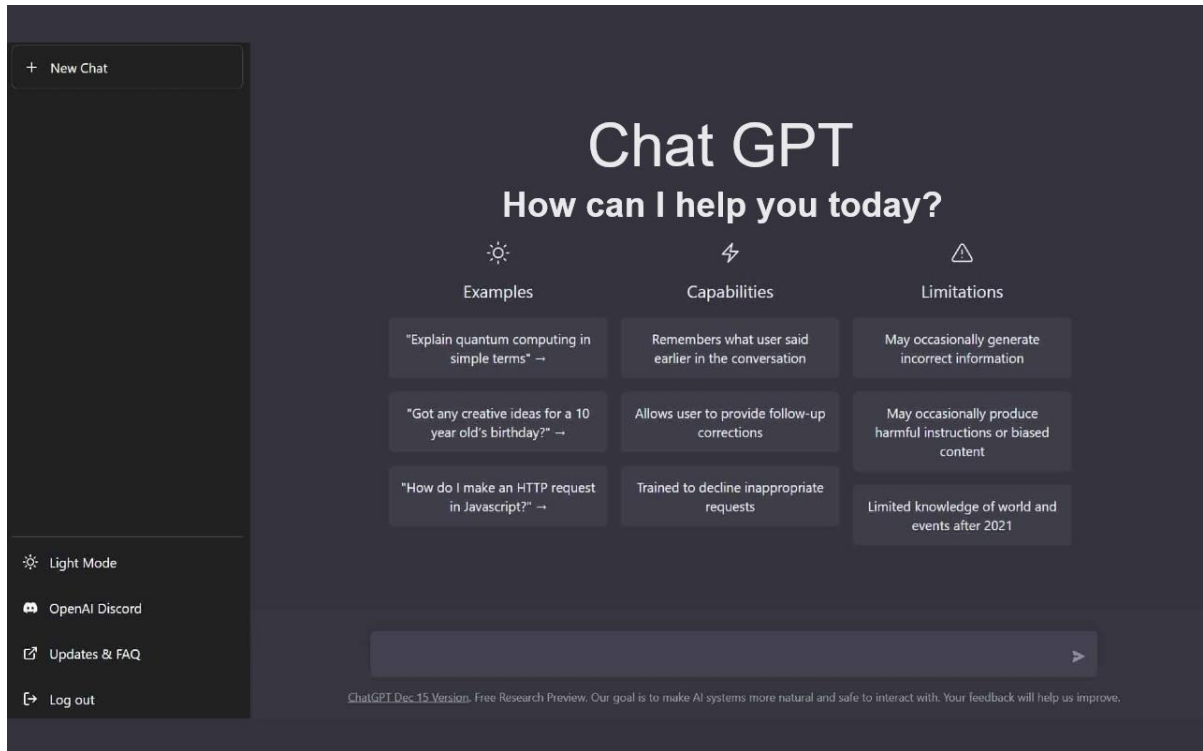
⁷ Redes Generativas Adversárias (todas as traduções foram feitas pelo presente autor)

⁸ Transformer Generativo Pré-treinado (GPT) é um modelo de linguagem de inteligência artificial da OpenAI, treinado com grandes volumes de texto para compreender e gerar linguagem natural por meio de redes neurais do tipo *transformer*

automatizar tarefas como redação, tradução, programação e análise de dados. Baseados em avanços como os Transformers e o aprendizado de máquina, esses sistemas oferecem análises contextuais profundas, mas enfrentam limitações significativas, como vieses nos dados de treinamento e falta de transparência devido a segredos comerciais. Essas questões geram preocupações, especialmente na educação, onde podem comprometer a autoria e a integridade acadêmica, além de reacender debates sobre a substituição de trabalhadores humanos em diversas áreas.

Embora modelos mais avançados, como o GPT-4, tenham sido desenvolvidos, sua performance parece se aproximar de um ponto de saturação, indicando desafios para avanços futuros. A rápida adoção dessas ferramentas também destaca a necessidade urgente de regulamentação ética, como sugerido pela UNESCO, que propõe diretrizes para seu uso responsável e educacional, com o objetivo de mitigar desigualdades e maximizar os benefícios.

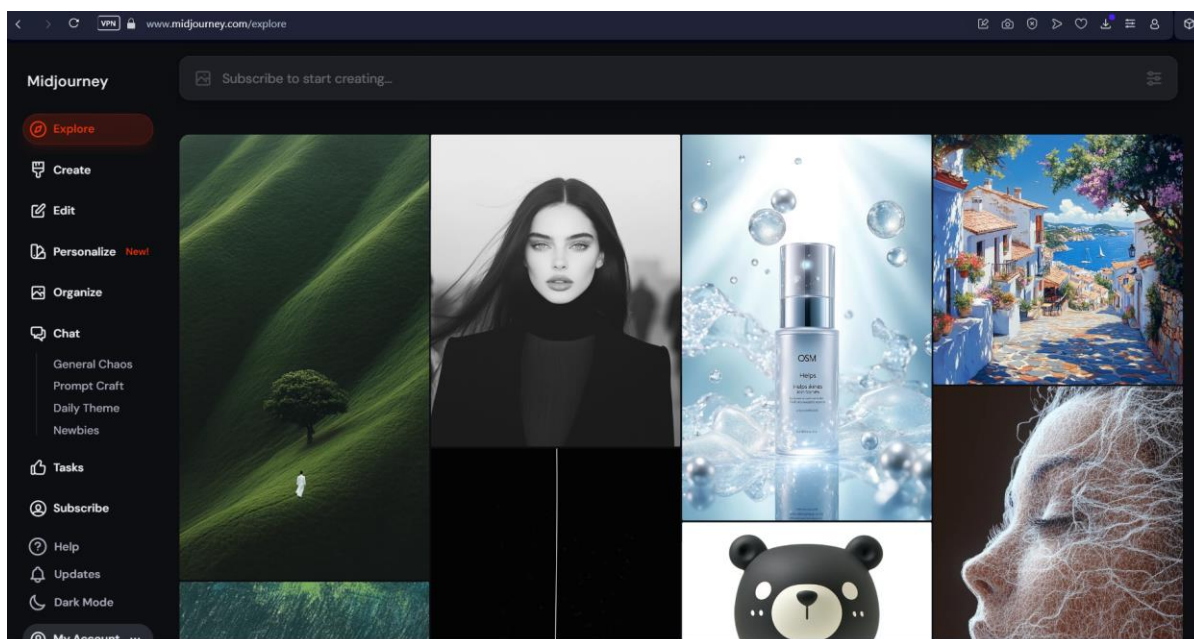
Figura 6 - ChatGPT



Fonte: <https://chatgpt.com>

Esses modelos representam uma verdadeira quebra de paradigma, comparável à introdução do Google ou da Wikipedia, com impacto significativo na pesquisa acadêmica e no ensino, especialmente em regiões como o Sul Global. Ferramentas como o Midjourney, com sua capacidade de gerar imagens de qualidade em tempo real, e também SciSpace, Perplexity, Consensus e Scholarcy têm transformado a pesquisa científica ao automatizar processos de busca, leitura e análise de literatura, introduzindo buscas semânticas dinâmicas, trechos relevantes de artigos e interações mais eficientes com materiais acadêmicos

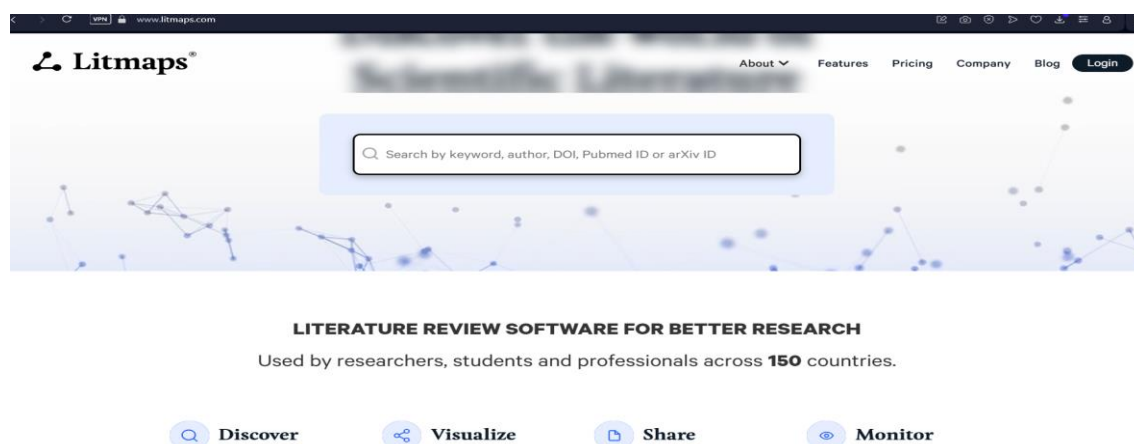
Figura 7 - Midjourney



Fonte: <https://www.midjourney.com/explore?tab=top>

Plataformas como Inciteful, Litmaps e Research Rabbit potencializam essas mudanças ao conectar materiais acadêmicos por meio de redes de citação, identificando lacunas e tendências na literatura. Além disso, soluções como ChatPDF, Humata e My Reader possibilitam a análise simultânea de múltiplos textos, fornecendo resumos, destaques e comparações, enquanto rompem barreiras linguísticas e democratizam o acesso ao conhecimento.

Figura 8 -Litmaps



Fonte: <https://www.litmaps.com>

Com essas inovações, a produção científica se torna mais ágil e eficiente, sinalizando a substituição gradual de métodos tradicionais por soluções integradas de IA que otimizam processos como revisão e leitura acadêmica.

3 METODOLOGIA

Este estudo adota uma abordagem qualitativa, quantitativa, exploratória e historiográfica, com o objetivo de investigar as possibilidades de intervenção da inteligência artificial na tradução. De acordo com Gil (2017), pesquisas podem ser classificadas segundo sua finalidade e métodos; neste caso, trata-se de uma pesquisa mista, que combina aspectos qualitativos e quantitativos, adequada para compreender tanto o desenvolvimento técnico quanto os impactos históricos e sociais da tradução automática.

A metodologia envolve três etapas principais: revisão da literatura, análise comparativa e estudo prospectivo. A primeira etapa consiste em uma revisão sistemática da literatura, caracterizada como pesquisa bibliográfica, conforme definição de Gil (2017), que a entende como um estudo elaborado com base em material já publicado, abrangendo livros, artigos científicos, teses e fontes digitais.

O propósito da revisão é investigar o desenvolvimento histórico e técnico das tecnologias de tradução automática, construindo uma cronologia desde as primeiras máquinas, com base em critérios relacionados ao processo de criação desses sistemas. A revisão abordará as expectativas iniciais geradas, os primeiros testes e experiências positivas, até a subsequente quebra de expectativas, decorrente das limitações que foram progressivamente percebidas.

Assim, esta pesquisa, de natureza mista e bibliográfica, busca, segundo Gil (2017), não apenas preencher lacunas no conhecimento característica da pesquisa básica, mas também apontar possibilidades práticas de intervenção da inteligência artificial na tradução, o que aproxima seu caráter de uma pesquisa aplicada.

Esse padrão de pesquisa seguirá para cada um dos modelos de tradução automática, passando por RBMT, SMT, NMT, até inovações trazidas pelas AIs generativas, como GANs e VAEs. Essa revisão será conduzida em bases de dados como Google Scholar e IEEE Xplore, utilizando palavras-chave relacionadas à tradução automática e inovações em IA. Estudos seminais, como os de Hutchins (1995), Vaswani et al. (2017) e Goodfellow et al. (2014), serão utilizados como base teórica.

A segunda etapa do estudo envolve uma análise comparativa realizada de forma qualitativa e quantitativa entre as abordagens tradicionais e contemporâneas de tradução automática. O foco será tanto na quantidade de palavras e na extensão dos textos que podem ser traduzidos por cada método, quanto na qualidade do processo de adequação tradutória, e domesticação focando não apenas na tradução fiel do texto, mas sim na capacidade da tradução de transmitir sua mensagem sem perder o significado original.

Com esse método em mente, serão avaliadas as limitações e capacidades do RBMT. O SMT, que se destacou por utilizar corpora bilíngues para melhorar a precisão das traduções, será analisado por seus avanços em relação ao RBMT, bem como suas limitações e capacidades em termos de compreensão contextual.

Finalmente, o estudo do NMT focará nos benefícios das redes neurais profundas, especialmente no modelo Transformer, que foca no avanço do entendimento semântico e da precisão das traduções. A análise comparativa será fundamentada em estudos empíricos e relatórios de desempenho dos sistemas, utilizando como referência trabalhos como os de Manning & Schütze (1999) e Vaswani et al. (2017) para evidenciar as evoluções tecnológicas e os desafios persistentes.

A terceira e última etapa da pesquisa será um estudo prospectivo sobre as intervenções futuras da IA na área de tradução. O estudo será realizado com base nas tendências tecnológicas emergentes, como os modelos GPT, e nas contribuições de tecnologias como as GANs e os VAEs, que oferecem novas perspectivas para a tradução automática. Esse estudo historiográfico e prospectivo será baseado em relatórios de tendências tecnológicas e artigos especializados, buscando prever como a AI continuará a transformar o campo da tradução.

Também serão analisadas as possíveis implicações sociais e éticas decorrentes dessas inovações, especialmente no que diz respeito à substituição de tradutores humanos por sistemas automatizados. As fontes de pesquisa incluirão conferências anuais, como a Oficina de Tradução Automática (doravante WMT – *Workshop on Machine Translation*), promovida pela Association for Computational Linguistics (2024), utilizando também relatórios corporativos de empresas globais de idiomas e processos tradutórios, como o relatório de tradução automática (*Machine Translation Report*) da Lionbridge (LIONBRIDGE, 2023), além do uso de bases de dados como Google Scholar e IEEE Xplore, com palavras-chave como IA, *Rule-Based Machine Translation* (RBMT), tradução automática baseada em regras, *Statistical Machine Translation* (SMT), tradução automática estatística, *Neural Machine Translation* (NMT), tradução automática neural, *Generative Adversarial Networks* (GANs), redes adversárias generativas, e *Variational Autoencoders* (VAEs), *autoencoders* variacionais.

Esta metodologia visa fornecer uma análise detalhada da trajetória histórica e técnica das tecnologias de tradução automática. Posto isso, dada a natureza dinâmica da

Presente pesquisa, é necessário reconhecer as suas limitações, especialmente relacionadas ao estudo prospectivo, que, mesmo embasado em diversas fontes de pesquisa e teorias, trata-se, como o nome sugere, de uma prospecção de futuras evoluções tecnológicas na área e futuras relações entre tradutores e máquinas de tradução automática, tornando-se

impossível alegar com absoluta certeza que esse aspecto do trabalho irá prever completamente as constantes futuras. Afinal, trata-se de uma perspectiva sobre o futuro da inteligência artificial na área de tradução.

4 ANÁLISE DOS DADOS

Esta seção apresenta os dados analisados com base nos três eixos estabelecidos na metodologia: a evolução histórica da tradução automática, a comparação entre ferramentas contemporâneas e as perspectivas futuras relacionadas ao uso de inteligência artificial generativa na tradução. As informações foram extraídas da revisão de literatura e complementadas por dados secundários provenientes de artigos científicos, relatórios corporativos e marcos de desempenho de diferentes sistemas. O objetivo é examinar o atual cenário da tradução automática à luz de três estudos recentes, os quais abordam, sob diferentes enfoques, a relação entre sistemas de Tradução Automática Neural (NMT), Grandes Modelos de Linguagem (LLMs) e a tradução humana.

A transição observada nesse campo, marcada pelo protagonismo crescente dos LLMs, evidencia-se por meio de pesquisas que expõem tanto os limites dos sistemas tradicionais quanto as oportunidades emergentes com as novas abordagens baseadas em modelos generativos. Como discutido por Hutchins (1995), cada avanço paradigmático na tradução automática esteve ligado à superação de restrições técnicas e linguísticas específicas da fase simbólica às abordagens estatísticas, e destas às redes neurais. Essa mesma lógica evolutiva, também explica o surgimento dos LLMs como consequência do esgotamento dos paradigmas anteriores.

Os LLMs (Large Language Models) são modelos de inteligência artificial treinados com grandes volumes de dados textuais, capazes de executar tarefas diversas de linguagem natural, como tradução, geração, resumo, interpretação e avaliação automática de textos. Esses modelos têm sido cada vez mais integrados a sistemas de tradução por sua versatilidade e desempenho expressivo, conforme destacam Vaswani et al. (2017) ao introduzirem a arquitetura Transformer, base estrutural tanto dos NMTs quanto dos LLMs contemporâneos.

Um dos estudos analisados, conduzido por Sizov et al. (2024) e apresentado no Workshop on Machine Translation (WMT24), realizou uma análise comparativa entre traduções humanas, saídas de sistemas NMT e textos gerados por LLMs. A pesquisa destacou-se por sua ênfase em explicabilidade, utilizando métodos como Leave One Out (LOO), técnica que remove, um a um, elementos do texto de entrada para observar o impacto de cada item na resposta final do modelo e Integrated Gradients (IG), que calcula a contribuição de cada palavra de entrada para a saída do modelo ao longo de um caminho de interpolação. Esses métodos

refletem a busca por transparência e interpretabilidade e apontam a necessidade de compreender os processos internos dos modelos para legitimar seu uso em contextos linguísticos complexos.

A tabela 1 mostra o desempenho do classificador de suficiência em diferentes ranks (top-1, top-3, top-5) utilizando os métodos LOO e IG para os sistemas tradução humana (HT), NMT e LLM. Os maiores scores para cada método estão destacados em verde (LOO) e cinza (IG), com os maiores scores em negrito para evidenciar os pontos fortes de cada método.

Tabela 1: Desempenho do classificador de suficiência em diferentes ranks (top-1, top-3, top-5)

System	LOO			IG		
	top-1	top-3	top-5	top-1	top-3	top-5
HT	0.64	0.66	0.66	0.51	0.56	0.57
DeepL	0.60	0.73	0.72	0.53	0.61	0.71
Google Translate	0.78	0.70	0.76	0.50	0.50	0.83
M2M-100-418M	0.57	0.70	0.76	0.57	0.75	0.75
NLLB-600M	0.50	0.73	0.69	0.58	0.50	0.71
TowerInstruct-7B-v0.2	0.54	0.70	0.74	0.51	0.55	0.54
Aya-101-13B	0.53	0.69	0.76	0.53	0.72	0.68
Gemma-7B	0.54	0.65	0.63	0.55	0.55	0.53
Llama-3.1-IT-8B	0.50	0.73	0.76	0.51	0.64	0.65
Mean	0.58	0.70	0.72	0.53	0.60	0.66

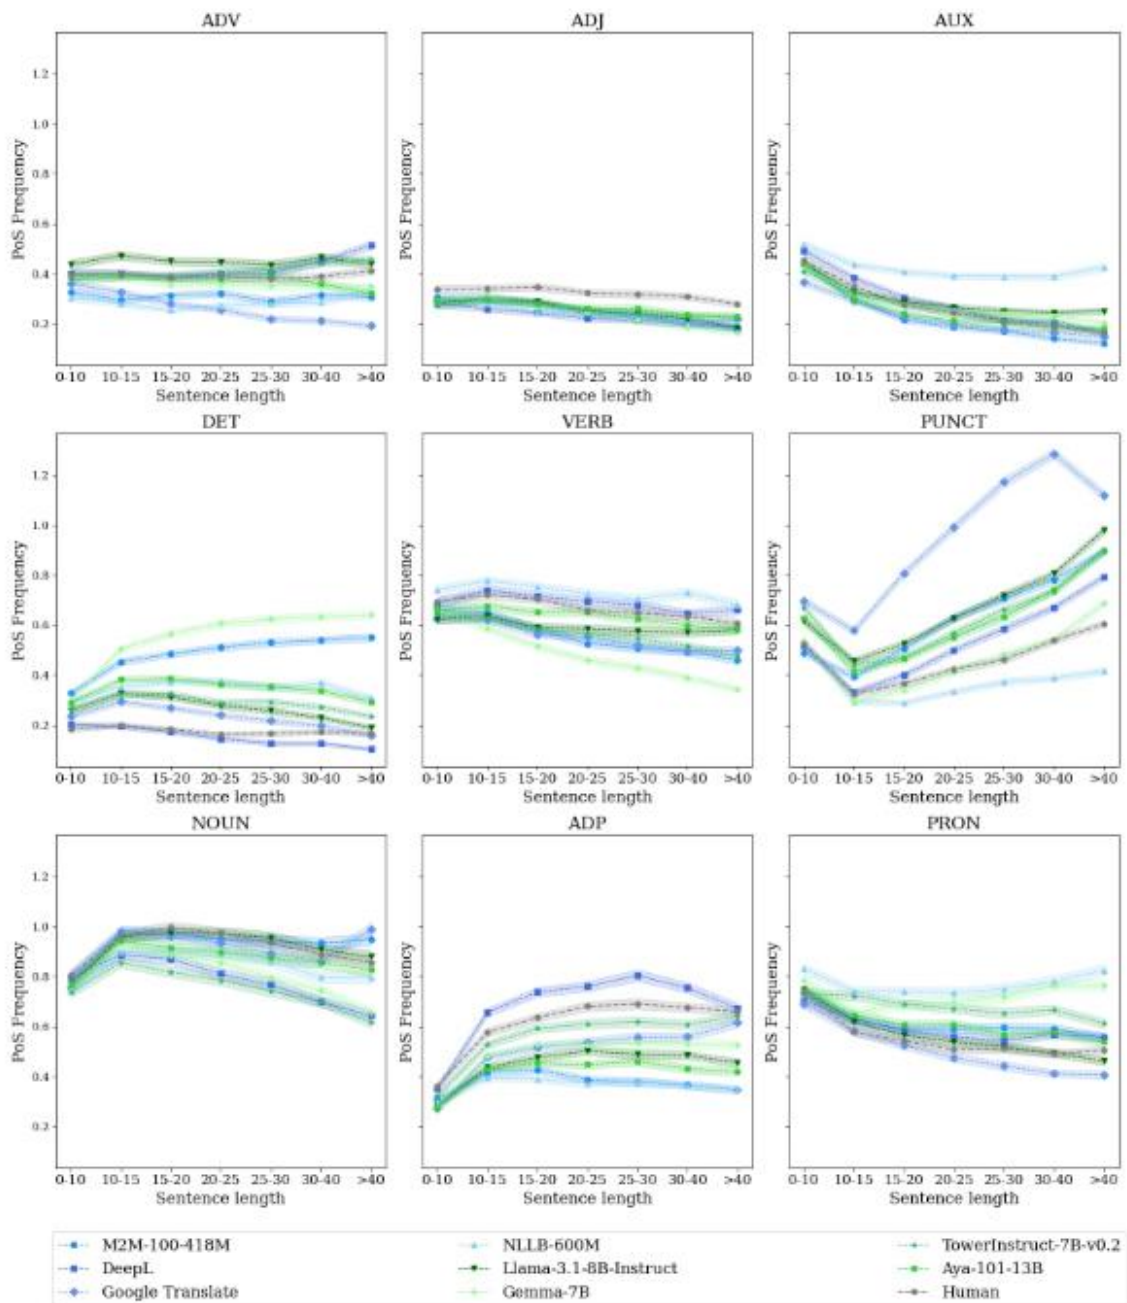
Fonte: Sizov *et al*, 2024

Os resultados revelaram que traduções automáticas tanto geradas por NMTs quanto por LLMs são mais facilmente reconhecíveis como artificiais quando comparadas a traduções humanas, devido à presença persistente de artefatos linguísticos conhecidos como "translationese" como indicador de uma artificialidade textual inerente aos processos de tradução automática. Esse fenômeno ocorre mesmo em traduções com alta pontuação em métricas como BLEU ou COMET, indicando que a fluência superficial não garante naturalidade discursiva autêntica.

Um achado importante do estudo é que os LLMs se aproximam mais da linguagem humana do que os NMTs em aspectos como o uso de advérbios, verbos auxiliares e construções sintáticas menos padronizadas. Ainda assim, mantêm uma espécie de 'impressão digital linguística', conhecida como que os diferencia dos textos nativos. Essa constatação reforça a necessidade de novas métricas de avaliação da qualidade tradutória, coerente com o argumento de Koehn (2009, apud Poibeu, 2017) de que a mensuração automatizada deve considerar dimensões semânticas, estilísticas e discursivas

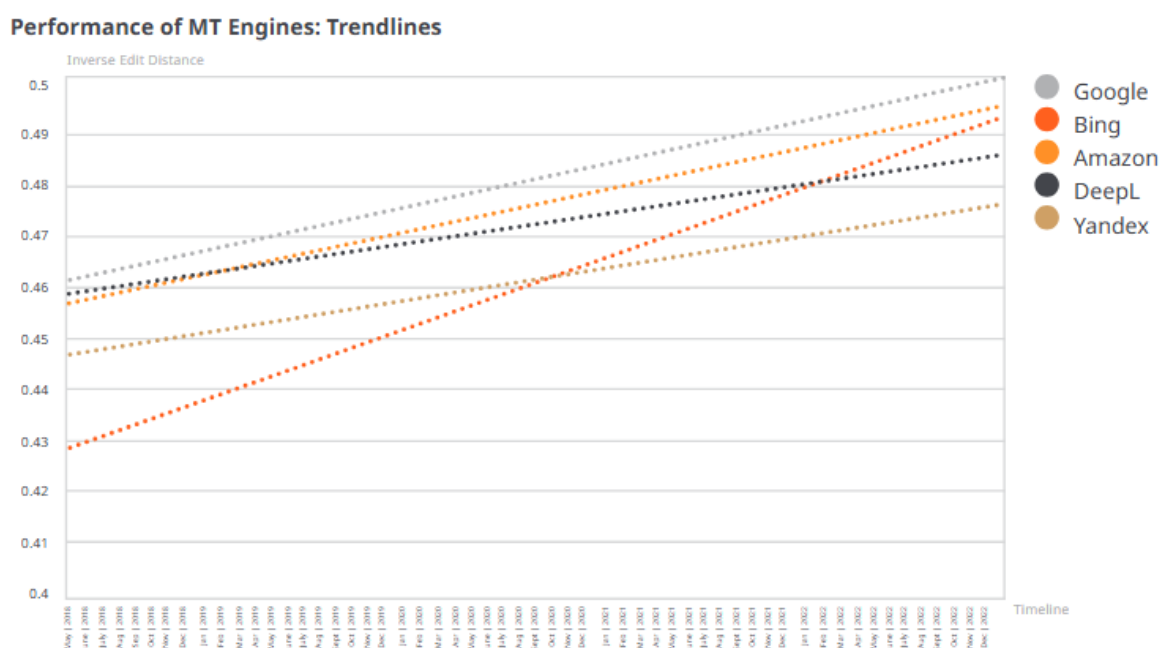
O gráfico 1 mostra a frequência das principais categorias de PoS (part-of-speech / partes do discurso) identificadas pelo método LOO em diferentes faixas de comprimento de sentença. O eixo x de cada subgráfico representa o comprimento da sentença, dividido em intervalos (0–10, 10–15, 15–20, etc.), enquanto o eixo y mostra a frequência da PoS, indicando com que frequência cada categoria gramatical aparece nas sentenças de diferentes tamanhos.

Gráfico 1: Frequência das principais categorias de PoS (part-of-speech / partes do discurso)



O relatório técnico da Lionbridge (2023) complementa essa análise ao oferecer um panorama do desempenho atual dos principais motores de tradução automática baseados em NMT. A análise aponta que os principais modelos da indústria vêm demonstrando progresso marginal nos últimos anos, com desempenho equivalente entre si. Esse achatamento da curva de desenvolvimento sugere o esgotamento do paradigma da NMT, indicando uma possível transição fenômeno que ecoa o ciclo de substituição tecnológica descrito por Hutchins (1995).

Gráfico 2: linha de evolução das cinco maiores engines(modelos de sistema) de tradução automática



Fonte: Lionbridge,2023

Em contraste, os LLMs, mesmo sem treinamento exclusivo para tarefas tradutórias, vêm demonstrando resultados comparáveis ou superiores aos dos motores especializados. O modelo GPT-4, por exemplo, superou um dos cinco principais sistemas de NMT no par linguístico inglês-chinês. A vantagem dos LLMs reside na capacidade de modelar conhecimento de mundo, capturar relações de longo alcance e interpretar nuances linguísticas e discursivas tradicionalmente inacessíveis aos NMTs. O que confirma as observações de Vaswani et al. (2017) sobre o papel da atenção contextual como base da performance linguística avançada.

Esses resultados sugerem que o futuro da tradução automática deve se basear em modelos híbridos, nos quais o poder generativo dos LLMs será combinado com ajustes finos específicos para domínios ou idiomas, aumentando a eficácia em contextos multilíngues e complexos. Essa hipótese está em consonância com as projeções de Chiang e Lee (2023 apud Sato et al., 2024), que defende a integração entre aprendizado generalista e especialização local como chave para o avanço sustentável da tradução automática.

A ascensão dos LLMs no campo da tradução também se evidencia em aplicações inovadoras, como demonstra o estudo de Sato et al. (2024), também apresentado no WMT24, que explora o uso de LLMs como avaliadores autônomos da qualidade de traduções. Trazendo uma proposta na qual o próprio modelo atua como juiz da adequação e fluência textual.

A tabela 2 compara as previsões do GPT-4o mini com os julgamentos humanos de Avaliação direta (direct assessment) que foram obtidos previamente por avaliadores que analisaram as traduções geradas por sistemas de tradução automáticas de pares linguísticos como por exemplo inglês-telugu essas traduções visavam, em geral, a sentença-fonte e a tradução produzida, atribuindo notas contínuas de 0 a 100 com base na preservação do significado e na fluência. Essas notas servem como referência para avaliar o desempenho do modelo. Utilizando três métricas complementares: Spearman (ρ): avalia a concordância na ordenação relativa das traduções verifica se o modelo classifica as sentenças como mais ou menos qualitativas na mesma sequência que os humanos, independentemente dos valores absolutos das notas; Pearson (r): mede a correlação linear entre as notas de cada par de tradução, no caso os valores numéricos exatos previstos pelo modelo e os atribuídos pelos humanos e Kendall (τ) que avalia a concordância ordinal, porém de forma mais conservadora, contando pares concordantes e discordantes examinando, para cada par de traduções, se a ordem relativa é a mesma nas duas classificações.

Tabela 2: Correlações de Spearman (ρ), Pearson (r) e Kendall (τ)

Method	Setting	En-Gu			En-Hi			En-Ta			En-Te		
		ρ	r	τ	ρ	r	τ	ρ	r	τ	ρ	r	τ
Single generation													
	Zero-shot	0.205	0.501	0.337	0.379	0.434	0.291	0.277	0.514	0.514	0.271	0.280	0.208
	Three-shot	0.413	0.491	0.309	0.390	0.400	0.282	0.463	0.420	0.344	0.294	0.305	0.226
	Fine-tuned	0.599	0.659	0.453	0.510	0.639	0.367	0.618	0.704	0.453	0.283	0.263	0.205
Multi generation													
$score_{mean}$	Zero-shot	0.453	0.505	0.328	0.389	0.449	0.277	0.514	0.529	0.373	0.274	0.275	0.193
	Three-shot	0.447	0.512	0.319	0.422	0.426	0.294	0.498	0.428	0.358	0.290	0.303	0.205
	Fine-tuned	0.680	0.717	0.506	0.564	0.686	0.409	0.661	0.747	0.487	0.392	0.361	0.270
$score_{prob}$	Zero-shot	0.451	0.499	0.323	0.394	0.447	0.275	0.519	0.521	0.368	0.274	0.276	0.190
	Three-shot	0.448	0.514	0.319	0.423	0.427	0.295	0.500	0.426	0.358	0.290	0.303	0.202
	Fine-tuned	0.683	0.715	0.508	0.568	0.690	0.412	0.663	0.746	0.489	0.399	0.360	0.277

Fonte: Sato et al., 2024.

Neste estudo, o modelo GPT-4o mini foi testado como sistema de estimação da qualidade de tradução (Quality Estimation QE) em nível de sentença, sem recorrer a traduções humanas de referência. Avaliado em diferentes configurações zero-shot⁹, three-shot¹⁰ e ¹¹fine-tuning, o modelo demonstrou desempenho superior quando ajustado com essas configurações específicas. Essa abordagem mostrou que o aprendizado com exemplos direcionados melhora substancialmente o desempenho em tarefas específicas, mesmo para modelos originalmente generalistas.

Com esse ajuste, o GPT-4o mini atingiu coeficientes de correlação de Spearman de até 0.735 no par inglês-híndi. Além disso, o modelo alcançou o primeiro lugar em tarefas nos pares inglês-gujarati e inglês-híndi, e obteve desempenho competitivo em inglês-tâmil e inglês-telugu, apesar da complexidade morfosintática desses idiomas, que é um desafio recorrente ao discutir os limites da tradução automática em línguas com poucos recursos.

Apesar dos avanços, o estudo também revelou limitações relevantes. O desempenho do modelo foi significativamente inferior no par inglês-telugu (correlação de 0.460), evidenciando os desafios persistentes na avaliação de línguas com poucos dados e estrutura gramatical complexa. Essa limitação aponta para a necessidade de LLMs mais especializados por idioma, como um possível “TeluguGPT”, capazes de lidar com as especificidades linguísticas e culturais de línguas menos representadas perspectiva também enfatizada por Chiang e Lee (2023 apud Sato et al., 2024).

A análise integrada dos três estudos revela uma reconfiguração do ecossistema da tradução automática. Os LLMs, inicialmente concebidos para tarefas gerais de linguagem natural, demonstram-se capazes não apenas de traduzir com qualidade competitiva, mas também de avaliar traduções com robustez. Com isso, a distinção entre tradução humana e automática tende a se tornar cada vez mais sutil, embora ainda perceptível em função dos traços linguísticos artificiais que persistem.

Esse novo paradigma oferece uma série de benefícios, como maior naturalidade nas traduções, versatilidade para múltiplas tarefas linguísticas e potencial para reduzir custos e acelerar fluxos de trabalho multilíngues. Por outro lado, desafios importantes permanecem: a

⁹ Tiro zero: o modelo recebe apenas a instrução de avaliar a qualidade em uma escala de 0 a 100, sem nenhum exemplo prévio

¹⁰ Três tiros: a mesma instrução é acompanhada de três exemplos completos (sentença-fonte, tradução e respectivo score humano), permitindo que o modelo “aprenda no prompt” o padrão esperado

¹¹ Ajuste fino: o GPT-4o mini foi efetivamente retreinado (fine-tuned) pela equipe com os 7.000 pares de sentenças e scores humanos do conjunto de treinamento do WMT23, tornando-o especializado na tarefa de QE para esses pares linguísticos

persistência do *translationese*¹², a dificuldade de adaptação a idiomas sub-representados e os riscos associados ao viés algorítmico e à opacidade dos critérios decisórios desses modelos riscos que exigem abordagens de interpretabilidade e auditoria linguística.

Diante desse cenário, é possível traçar algumas perspectivas para o futuro da tradução automática com base em inteligência artificial generativa. Em primeiro lugar, os dados sugerem que o caminho baseado exclusivamente em NMT está se aproximando de um ponto de saturação (Lionbridge, 2023). O desempenho dos principais modelos não apresenta avanços significativos, o que reforça a ideia de que novos caminhos tecnológicos precisam ser explorados. Nesse sentido, os LLMs surgem como alternativa promissora.

Sua capacidade de captar nuances contextuais, manter coerência discursiva e operar com flexibilidade em múltiplos domínios os torna aptos a substituir ou complementar os modelos tradicionais (Vaswani et al., 2017; Chiang e Lee (2023 apud Sato et al., 2024)). Além de atuarem como tradutores, os LLMs também se consolidam como avaliadores de qualidade, o que permite sua integração em diferentes etapas dos fluxos de tradução automática os permitindo um papel multifuncional como avaliador e como tradutor.

Esse uso duplo amplia sua aplicabilidade e fortalece a tendência de automação mais abrangente dos processos linguísticos. No entanto, sua adoção plena depende da superação de barreiras ainda latentes. Entre elas, destacam-se os traços de artificialidade textual, os desafios de desempenho em idiomas com poucos dados e a necessidade de métricas mais sensíveis à naturalidade e fluidez do discurso.

Conclui-se, portanto, que o futuro da tradução automática será marcado por modelos híbridos, fluxos mais automatizados e um papel renovado para o tradutor humano que, mesmo diante da sofisticação das ferramentas, continuará exercendo função essencial de revisão crítica, adequação estilística e responsabilidade ética. A incorporação dos LLMs representa um avanço expressivo, mas sua consolidação como padrão tecnológico exigirá abordagens complementares, sensíveis à diversidade linguística e à complexidade cultural inerente à linguagem humana.

¹² Translationese refere-se ao conjunto de características linguísticas recorrentes em textos traduzidos que os distinguem de textos originalmente produzidos por falantes nativos da língua-alvo. Esses traços incluem maior literalidade, uso excessivo de pontuação e determinantes, além da subutilização de advérbios e verbos auxiliares, resultando em estruturas mais rígidas e menos naturais em comparação ao discurso nativo.

5 CONCLUSÃO

Ao longo desta pesquisa, foi possível compreender em profundidade o desenvolvimento histórico, técnico e social das tecnologias de tradução automática e suas transformações impulsionadas pela inteligência artificial. A análise bibliográfica, aliada a estudos recentes, demonstrou que o campo da tradução tem passado por reconfigurações significativas, impulsionadas especialmente pela ascensão de modelos baseados em aprendizado profundo, como os modelos neurais (NMT) e, mais recentemente, os Grandes Modelos de Linguagem (LLMs), como o GPT-4.

O objetivo geral de verificar as possíveis intervenções da inteligência artificial na tradução foi plenamente contemplado, à medida que se evidenciou que tais intervenções já ocorrem em diversas frentes: da produção de traduções rápidas e eficientes à avaliação automatizada da qualidade textual. A IA não apenas automatiza a tradução, mas começa a assumir funções anteriormente reservadas ao julgamento humano, como a análise de fluência, coesão discursiva e até a atribuição de escores qualitativos sem a necessidade de referência humana.

Em relação ao primeiro objetivo específico investigar os resultados de pesquisas anteriores sobre o uso da tecnologia na tradução, a pesquisa demonstrou que desde os primórdios, com o RBMT baseado em regras, passando pela SMT estatística até a NMT neural, o campo vem evoluindo com base na tentativa de tornar as traduções mais naturais e contextualmente adequadas. Ao revisitar esses paradigmas e suas limitações, percebe-se que o progresso tem sido contínuo, ainda que cada nova tecnologia traga consigo novos desafios.

O segundo objetivo específico, que consistia em comparar resultados de pesquisas anteriores com as tendências atuais, também foi atendido por meio da análise dos estudos recentes apresentados no *Workshop on Machine Translation (WMT24)* e de relatórios técnicos do setor. Esses dados apontam para uma estagnação do modelo NMT em termos de inovação e desempenho, ao mesmo tempo em que os LLMs demonstram resultados superiores em diversas tarefas linguísticas, mesmo sem treinamento específico para tradução. Essa comparação mostra

uma mudança clara de paradigma, com os LLMs oferecendo maior flexibilidade, coerência e compreensão contextual do que os motores especializados tradicionais.

Quanto ao terceiro objetivo, presumir as possibilidades de intervenção da IA na tradução, os dados levantados apontam para um cenário futuro de sistemas híbridos. A combinação de IA generativa com personalizações por idioma ou domínio tende a consolidar-se como um novo padrão técnico. No entanto, mesmo com os avanços expressivos, ainda existem limitações relevantes: a persistência do *translationese*, o baixo desempenho em idiomas com poucos recursos, a presença de vieses algorítmicos e a ausência de métricas adequadas para avaliar a naturalidade discursiva. Tais desafios indicam que o papel do tradutor humano continuará sendo indispensável, especialmente nas etapas de revisão, adaptação estilística e tomada de decisões éticas e culturais.

Dessa forma, conclui-se que a inteligência artificial não elimina o papel do tradutor, mas transforma profundamente sua função. A IA deve ser vista como uma aliada, capaz de otimizar processos, ampliar o alcance de produções multilíngues e democratizar o acesso à informação, mas que ainda depende da mediação humana para garantir qualidade, sensibilidade cultural e responsabilidade ética. Reiterando o papel prospectivo da presente pesquisa, e reconhecendo as suas limitações, especialmente relacionadas as perspectivas futuras, que, mesmo embasadas em diversas fontes de pesquisa e teorias, tratam-se, como o nome sugere, de uma prospecção de futuras evoluções tecnológicas na área e futuras relações entre tradutores e máquinas de tradução automática, tornando-se impossível alegar com absoluta certeza que esse aspecto do trabalho irá prever completamente as constantes futuras. Posto isso, o estudo sugere que o futuro da tradução não será apenas automatizado, mas colaborativo marcado pela sinergia entre inteligência artificial e inteligência humana.

REFERÊNCIAS

- AMAZON WEB SERVICES. Introducing Amazon Translate: real-time text language translation. Blog AWS, [s.l.], 2022 (ou ano da última atualização, se disponível). Disponível em: <https://aws.amazon.com/pt/blogs/aws/introducing-amazon-translate-real-time-text-language-translation/>. Acesso em: 26 dez. 2024.
- ASSOCIATION FOR COMPUTATIONAL LINGUISTICS. **Proceedings of the Ninth Conference on Machine Translation (WMT24)**. Singapura: ACL Anthology, 2024. Disponível em: <https://aclanthology.org/volumes/2024.wmt-1/>. Acesso em: 25 abr. 2025.
- DEEPL. DeepL Translator. [s.l.], [2025?]. Disponível em: <https://www.deepl.com/pt-BR/translator>. Acesso em: 26 dez. 2024.
- GOODFELLOW, I.; POUGET-ABADIE, J.; MIRZA, M.; XU, B.; WARDE-FARLEY, D.; OZAIR, S.; BENGIO, Y. Generative adversarial nets. In: **Advances in Neural Information Processing Systems**, 2014, vol. 27.
- GOOGLE. Google Tradutor. Google, [s.l.], [2025?] (ano da última atualização ou sem data). Disponível em: <https://translate.google.com.br/?sl=auto&tl=pt&op=translate>. Acesso em: 26 dez. 2024.
- HUTCHINS, W. John. **Machine Translation: a brief history**. 1995.
- HUTCHINS, W. John. **Machine Translation: A concise history**. 2006.
- KINGMA, D. P.; WELING, M. **Auto-Encoding Variational Bayes**. arXiv preprint arXiv:1312.6114, 2013.
- LIONBRIDGE. The Lionbridge 2023 Machine Translation Report. Waltham, MA, 2023. Disponível em: <https://www.lionbridge.com/whitepaper/the-lionbridge-2023-machine-translation-report/>. Acesso em: 22 abr. 2025.
- MANNING, Christopher D.; SCHÜTZE, Hinrich. **Foundations of Statistical Natural Language Processing**. Cambridge: The MIT Press, 1999.
- MELO, Sheila de Souza Corrêa de. **Tradução automática e competência tradutória: repensando interseções**. Rónai: Revista de Estudos Clássicos e Tradutórios, v. 1, n. 1, p. 60-72, 2013.
- MICROSOFT. Bing Translator. [s.l.], [2025?]. Disponível em: <https://www.bing.com/translator?cc=br>. Acesso em: 26 dez. 2024.
- POIBEAU, Thierry. **Machine Translation**. Cambridge: The MIT Press, 2009.
- RAPIDTRANSLATE. Best translation software. RapidTranslate, 2024. Disponível em: https://www.rapidtranslate.org/br/resources/best-translation-software#5_Best_Machine_Translation_Software. Acesso em: 26 dez. 2024.
- SATO, Ayako; NAKAJIMA, Kyotaro; KIM, Hwicheon; CHEN, Zhousi; KOMACHI, Mamoru. TMU-HIT's Submission for the WMT24 Quality Estimation Shared Task: Is GPT-4 a Good Evaluator for Machine Translation? In: **WORKSHOP ON MACHINE TRANSLATION (WMT)**, 2024.
- SIZOV, Fedor; ESPAÑA-BONET, Cristina; VAN GENABITH, Josef; XIE, Roy; CHOWDHURY, Koel Dutta. Analysing translation artifacts: a comparative study of LLMs, NMTs, and human translations. In: **WORKSHOP ON MACHINE TRANSLATION (WMT)**, 2024.
- SYSTRAN. SYSTRAN Translate. [s.l.], [2025?]. Disponível em: <https://www.systransoft.com/translate/>. Acesso em: 26 dez. 2024.
- VASWANI, A.; SHAZEER, N.; PARMAR, N.; USZKOREIT, J.; JONES, L.; GOMEZ, A. N.; KAISER, L.; POLOSUKHIN, I. Attention Is All You Need. In: **Advances in Neural Information Processing Systems**, 2017.

