

Inteligência Artificial para Tradutores: Proposta de Conteúdo Essencial

Li Wenyan

**Dissertação de Mestrado em Tradução
Especialização em Inglês**

Novembro, 2025

Dissertação apresentada para cumprimento dos requisitos necessários à obtenção do grau de Mestre em tradução, área de especialização em Inglês, realizada sob a orientação científica do Prof. Doutor Marco Neves.

AGRADECIMENTOS

Em primeiro lugar, expresso a minha sincera gratidão ao meu orientador, o Prof. Doutor Marco Neves, pelo seu acompanhamento e apoio ao longo de todo o mestrado, em particular no último ano. Agradeço-lhe pela orientação atenta, pela ajuda sempre pronta e pela confiança que me deu para concluir esta dissertação.

No início do mestrado, o regresso à vida académica depois de anos no mundo do trabalho foi um grande desafio. O novo ambiente deixou-me desconfortável. Costumava rir-me de mim própria e dizer que era como um pequeno peixe habituado ao lago que, de repente, passou a nadar no vasto oceano. Lembro-me bem da primeira noite em Lisboa, quando, em lágrimas, desabafei ao telefone com uma amiga: “Porque deixei as águas conhecidas para vir sozinha para uma cidade desconhecida?” No entanto, com o tempo, acabei por me apaixonar por Lisboa.

Agradeço ao professor João Biléu pela pronta emissão da declaração da Faculdade no início do curso, que facilitou o meu processo no AIMA e a obtenção do título de residência sem dificuldades.

Durante este percurso, adquiri um conhecimento valioso na área de tradução. Agradeço à Faculdade e a todos os professores pelas aprendizagens transmitidas.

Agradeço profundamente à minha mãe, pelo apoio e conforto em todos os momentos de fragilidade.

À minha irmã, pela força e incentivo constante quando me sentia perdida.

Aos meus amigos, pela presença, pelas conversas sinceras e pela amizade.

Por fim, agradeço à minha sobrinha de cinco anos, cujo carinho e as palavras “Tia, tenho saudade tuas” são sempre o presente mais doce nas nossas chamadas.

E à minha sobrinha bebé, filha do meu irmão mais jovem, cuja simples presença é suficiente para me fazer sorrir e esquecer as preocupações.

Inteligência Artificial Para Tradutores: Proposta de Conteúdo Essencial

Li Wenyan

RESUMO

O presente trabalho adota uma metodologia quantitativa, baseado no enquadramento teórico da literacia em IA, focando-se nos conhecimentos fundamentais que os tradutores possuem nesta área. A partir de uma análise multidimensional, analisam-se as diferenças entre dois grupos de participantes (N = 67) em IA. Os resultados revelam diferenças significativas nas preferências de ferramentas, frequência de utilização e níveis de compreensão tecnológica. De modo geral, os inquiridos demonstram consciência básica das limitações e questões éticas da IA, evidenciando um nível moderado de literacia, com persistência de lacunas a melhorar.

As dificuldades principais concentram-se na compreensão cognitiva, nas competências operacionais, na avaliação dos resultados e nas preocupações éticas e de segurança. A maioria dos participantes apoia a integração precoce da IA na formação em tradução. Conclui-se que a integração da IA generativa (GenAI) nos currículos de tradução é necessária para reduzir lacunas de conhecimento e reforçar de forma sistemática a literacia em IA.

PALAVRAS-CHAVE: Inteligência Artificial (IA), IA generativa (GenAI), Literacia em IA, tradução, tecnologia, modelos de linguagem de grande escala (LLM), ChatGPT

Artificial Intelligence for Translators: Proposal of Core Content

Li Wenyan

ABSTRACT

The present study adopts a quantitative methodology, grounded in the theoretical framework of AI literacy, focusing on the fundamental knowledge that translators should acquire in this field. Employing a multidimensional analysis, differences between two groups of participants ($N = 67$) in context of AI are examined. The results indicate significant variations in tool preferences, frequency of use, and levels of technological understanding. Overall, respondents demonstrate a basic awareness of AI's limitations and ethical issues, reflecting a moderate level of literacy, although notable gaps remain.

The main difficulties are concentrated in cognitive understanding, operational skills, evaluation of outputs, and ethical and security concerns. Most participants support the early integration of AI into translation training. These findings suggest that incorporating generative AI (GenAI) into translation curricula is necessary to reduce cognitive gaps and systematically enhance AI literacy.

KEYWORDS: Artificial Intelligence (AI), generative AI (GenAI), AI literacy, translation, technology, large language models (LLMs), ChatGPT

Índice

Lista de abreviaturas	i
1. Introdução	1
1.1 Literacia em IA	5
1.2 Projeto de prompts	7
1.2.1 O que é?	7
1.2.2 Abordagens principais	7
1.3 Colaboração homem-máquina: um novo modelo de prática	9
2. Revisão de Literatura	12
2.1 Origem, definição e classificação da Inteligência Artificial (IA).....	12
2.1.1 Origem da IA	12
2.1.2 Definição e classificação da IA.....	14
2.2 Machine Learning e Deep Learning no domínio da IA.....	15
2.2.1 Machine Learning (ML)	15
2.2.2 Abordagens de aprendizagens principais de ML	16
2.2.3 Arquiteturas de DL	20
2.2.4 Aplicação do DL em NLP.....	24
2.2.5 Desafios de sistemas inteligentes em ML e DL.....	24
2.3 Processamento de Linguagem Natural (NLP)	25
2.3.1 Definição e relevância do NLP	25
2.3.2 Tarefas de investigação do NLP	26
2.3.3 Aplicação e indicadores automáticos do NLP	26
2.3.4 Desafios do NLP	28
2.3.5 Conjuntos de dados e modelos state of the art (SOTA) em NLP	28
2.4 Evolução e estado atual da tradução automática (MT).....	31
2.4.1 Tradução automática baseada em regras (RBMT).....	32
2.4.2 Tradução automática baseada em exemplos (EBMT)	33
2.4.3 Tradução automática baseada em estatística (SMT).....	33

2.4.4 Tradução automática neuronal (NMT)	35
2.5 Transformações Tecnológicas na Tradução Escrita sob a Influência da GenAI	39
2.6 Sinergia entre Tradutor Humano e IA: Modelo de Colaboração e Aplicação	42
2.7 Literacias em IA e Necessidades Educativas dos Tradutores	46
2.8 Questão da Ética e Desafio em relação à IA	49
2.8.1 Preconceitos, transparência e privacidade de dados	49
2.8.2 Alucinações informativas e fiabilidade das respostas	50
2.8.3 Outras questões	52
3. Metodologia	54
3.1 Participantes da investigação	54
3.2 Elaboração do questionário	54
3.3 Recolha de dados	57
4. Resultados e análise	60
4.1 Situação de utilização de ferramentas de IA por inquiridos	60
4.2 Utilização e conhecimento de ferramentas de tradução por IA	61
4.3 Prática de tradução com IA: aplicação, perceções e literacia em IA	65
5. Discussão e conclusão	76
6. Referências	78
Apêndice A - Questionário em Português	i
Apêndice B - Questionário em inglês	viii
Apêndice C - Questionário em Chinês	xv

Índice de ilustrações

Tabelas:

<i>Tabela 1. Informações demográficas (N = 67).</i>	59
<i>Tabela 2. Forma de utilização de ferramentas de IA por curso.</i>	60
<i>Tabela 3. Preferência de ferramentas de IA por grupo linguístico.</i>	61
<i>Tabela 4. Distribuição semanal do tempo de uso da IA por diferentes grupos.</i>	63
<i>Tabela 5. Nível médio de compreensão dos princípios da IA entre grupos.</i>	64
<i>Tabela 6. Objetivos da utilização das ferramentas de IA nas etapas da tradução.</i> ...	66
<i>Tabela 7. Principais limitações da IA generativa entre diferentes grupos.</i>	67
<i>Tabela 8. Outros problemas éticos adicionais.</i>	69
<i>Tabela 9. Literacia necessária para o uso da IA.</i>	70
<i>Tabela 10. Competências essenciais na era da tradução impulsionada por IA.</i>	71
<i>Tabela 11. Papel dos Tradutores Humanos na Era da IA.</i>	72
<i>Tabela 12. Opinião sobre a integração precoce da IA no ensino da tradução.</i>	75

Figuras:

<i>Figura 1. Evolução da MT.</i>	32
<i>Figura 2. Breve História dos Modelos de Linguagem.</i>	42
<i>Figura 3. Panorama dos Modelos de Linguagem de Grande Escala (LLM).</i>	42
<i>Figura 4. Utilização de ferramentas de LLM.</i>	61
<i>Figura 5. Utilização semanal da IA por diferentes grupos.</i>	63
<i>Figura 6. Objetivos do uso de ferramentas de IA nas etapas do processo tradutório.</i>	66
<i>Figura 7. Distribuição dos problemas éticos da IA generativa.</i>	68

Lista de abreviaturas

IA – Inteligência artificial

LLM – Modelos de linguagem de grande escala

ML – *Machine Learning*

DL – *Deep Learning*

NLP – Processamento de Linguagem Natural

NLU – *Natural Language Understanding*

NLG – *Natural Language Generation*

CNNs – *Convolutional Neural Networks*

RNNs – *Recurrent Neural Networks*

GANs – *Generative Adversarial Networks*

LSTMs – Memória de Longo e Curto Prazo

GRU – *Gated Recurrent Unit*

TA – Tradução automática

RBMT – Tradução automática baseada em regras

EBMT – Tradução automática baseada em exemplos

SMT – Tradução automática baseada em estatística

NMT – Tradução automática neuronal

CAT – Tradução assistida por computadores

TMS – Sistemas de gestão da tradução

PE – Pós-edição

PEMT – Pós-edição da tradução automática

SB-NMT – *Synchronous Bidirectional Neural Machine Translation*

SOTA – *State of the art*

LP – Língua de partida

LC – Língua de chegada

TP – Texto de partida

TC – Texto de chegada

BT – *Back-translation*

HITL – *Human-in-the-Loop*

OOV – *out-of-vocabulary*

1. Introdução

A Inteligência Artificial generativa (GenAI) tem ganhado uma notável proeminência nos últimos anos. Os Prêmios Nobel da Física e da Química foram atribuídos a pesquisas relacionadas com a inteligência artificial (IA) (Matos, 2024). Sendo uma das tecnologias chave que impulsionam a transformação digital e a Quarta Revolução Industrial (Kirov & Malamin, 2022), a tecnologia de IA passou a atrair rapidamente a atenção mundial a partir do final de novembro de 2022, quando a OpenAI lançou o modelo 3.5 do *Chat Generative pre-trained Transformer* (ChatGPT) (J. Zhang & Doherty, 2025, p. 2).

O ChatGPT, enquanto modelo de linguagem de grande escala (LLM), é amplamente reconhecido como o chatbot mais avançado a nível global (Rudolph et al., 2023, p. 342; Zhao et al., 2023, p. 10). O *New York Times* qualificou-o como “o próximo grande fator de disrupção da indústria”, e afirmou que “poderia mudar o mundo” (Rudolph et al., 2023, p. 343). Em 7 de agosto de 2025, a OpenAI lançou oficialmente o GPT-5, apresentado pela direção da empresa como “*the best model in the world, [...]*” no domínio da programação e da escrita, sublinhando que, em comparação com as versões anteriores, o GPT-5 proporciona pela primeira vez uma experiência comparável ao diálogo com especialistas de nível de doutoramento (Heath, 2025).

Face à crescente incorporação da IA na tradução, é fundamental compreendê-la não apenas como uma ferramenta tecnológica, mas também como uma área que exige formação específica para os tradutores. Assim, o presente trabalho procura identificar quais os saberes e competências relacionadas com a IA que são indispensáveis na prática da tradução contemporânea.

Os LLM constituem a base da GenAI no âmbito da geração de texto e do processamento da linguagem (Hao & Zhang, 2025, p. 468), representam um avanço significativo no processamento de linguagem natural (NLP). Os modelos são treinados com vastos conjuntos de dados extraídos da internet, permitindo aos modelos identificar padrões, sinais contextuais e relações entre dados (Kwok et al., 2025, p. 2), como GPT-

3, PaLM e LLaMA (Zhao et al., 2023, p. 4). Com recurso a técnicas avançadas de aprendizagem profunda (DL) e de NLP, os modelos demonstram capacidade elevada na compreensão da linguagem e na produção de textos comparáveis aos criados por seres humanos (Kwok et al., 2025, p. 2), estabelecendo integrações de carácter natural e intuitivo com os utilizadores (Gokul, 2023, p. 1; Rudolph et al., 2023, p. 342; Hadi et al., 2024, p. 1).

Do ponto de vista técnico, a GenAI e a tradução automática neuronal (NMT) apresentam distinções tanto ao nível do design como da funcionalidade. Os sistemas de NMT são concebidos especificamente para a tradução e recorrem a técnicas de DL e de redes neuronais para produzir automaticamente traduções de uma língua natural para outra. Em contraste, a GenAI apresenta um design mais abrangente, concebida para gerar diferentes tipos de conteúdos, como texto, imagens e outros formatos, em resposta a *prompts* fornecidos pelo utilizador. Um exemplo é a série *Generative Pre-Training* (GPT), desenvolvida pela OpenAI (Kwok et al., 2025, p. 2; Zhao et al., 2023, p. 7). São desenvolvidas para uma gama mais ampla de tarefas de NLP, entre as quais a tradução é apenas uma das suas múltiplas aplicações (J. Zhang & Doherty, 2025, p. 2).

Embora as ferramentas de GenAI não tenham sido concebidas especificamente para tarefas de tradução, têm demonstrado um potencial elevado para gerar traduções comparáveis, ou até superiores às traduções dos sistemas de NMT (J. Zhang & Doherty, 2025, p. 2), particularmente em termos de precisão e fluência (Algaraady & Mahyoob, 2025, p. 1; Kwok et al., 2025, p. 2). Na literatura (J. Zhang & Doherty, 2025; Algaraady & Mahyoob, 2025; Belhassen & Hamda, 2025; Kimera et al., 2024a; Krüger, 2024; Omar & Salih, 2024), não há distinção clara entre NMT e GenAI, apesar das diferenças existentes ao nível do desenho e da funcionalidade de cada sistema. Dado que ambas recorrem a técnicas de DL e a redes neuronais artificiais para modelizar frases mediante a previsão da probabilidade de sequências lexicais, é frequente considerá-las sob a designação geral de tecnologias de IA (J. Zhang & Doherty, 2025, p. 2). Do mesmo modo, o presente trabalho considera a NMT e a GenAI como formas de tradução

baseada em IA, com particular atenção à utilização das ferramentas de GenAI no setor da tradução.

A GenAI tem potencial para alterar profundamente os fluxos de trabalho dos tradutores profissionais e influenciar os métodos de aprendizagem dos estudantes de tradução (Belhassen & Hamda, 2025, p. 107; Kwok et al., 2025, p. 2). Por um lado, a GenAI apresenta vantagens em relação aos tradutores humanos, nomeadamente na eficiência na tradução de textos extensos, na precisão terminológica e na consistência estilística (J. Zhang et al., 2025, pp. 420–421); além disso, ao contrário dos sistemas tradicionais de tradução automática (MT), a GenAI permite otimizar os resultados da tradução por meio de *prompts*, o que promove um novo paradigma de tradução caracterizado pela interatividade e pela adaptabilidade (Krüger, 2024, p. 12; Kwok et al., 2025, p. 2). Importa ainda salientar que, segundo R. Chen & Guo (2024), a GenAI tem vindo a contribuir para a transformação do modelo de prática de tradução, integrando-se nas fases de preparação de pré-tradução, de tradução e de revisão de pós-tradução, promovendo um processo inteligente e colaborativo, centrado no tradutor humano e orientado pela lógica da “colaboração humano-máquina” (R. Chen & Guo, 2024). De igual modo, a GenAI serve como um assistente de tradução avançado, com capacidade de visualizar os textos de partida (TP) para facilitar a sua compreensão, bem como de pesquisar e recuperar diversas informações para apoiar todo o processo de tradução (W. Zhang et al., 2025, p. 641). A interatividade potencia a motivação e o interesse dos tradutores pela aprendizagem (Nguyen et al., 2025, p. 140), reduz a complexidade da tradução de textos desafiantes e contribui para reforçar a confiança dos tradutores no seu trabalho (W. Zhang et al., 2025, p. 641).

Por outro lado, a utilização da GenAI apresenta também limitações e desafios ao lidar com tarefas complexas, particularmente aquelas que exigem criatividade, consciência cultural e compreensão profunda e matizada, uma vez que as ferramentas de GenAI revelam fragilidades significativas (Belhassen & Hamda, 2025, pp. 108-114). Adicionalmente, essas ferramentas enfrentam frequentemente dificuldades na interpretação de expressões idiomáticas, metáforas, e significados dependentes do

contexto (Mohd Saad et al., 2025, p. 4898; Nguyen et al., 2025, p. 137), o que evidencia a necessidade de edição e revisão dos resultados produzidos pela IA, assim como a necessidade da supervisão humana (Belhassen & Hamda, 2025, pp. 108-114). A dependência excessiva destas ferramentas pode ainda comprometer o desenvolvimento de competências fundamentais de tradução, como a adaptação cultural, a criatividade linguística e a capacidade de resolução de problemas e o julgamento (Belhassen & Hamda, 2025, p. 108; Nguyen et al., 2025, p. 141). Além disso, um estudo indica que a GenAI apresenta limitações no que diz respeito à atualização das bases de dados. Zhao et al. (2023, p. 63) referem que os LLM têm dificuldades ao lidar com tarefas que exigem conhecimentos mais recentes, além dos dados de treino. Embora possam recorrer a fontes externas de conhecimento, como motores de pesquisa, continua a ser um desafio atualizar eficazmente o conhecimento interno ou integrar informação especializada nos modelos. Outra limitação é que a GenAI enfrenta dificuldades na compreensão de línguas não inglesas, como o chinês, mostra limitações em termos de transparência e de mecanismos de responsabilização e, ao não divulgar as fontes de informação, pode resultar em violação de propriedade intelectual, de direitos de autor e de outras restrições legais (W. Zhang et al., 2025, p. 643). Acresce que a sua capacidade de gerar conteúdos semelhantes aos produzidos por humanos aumenta o risco de difusão de informação enganosa e de materiais manipulativos (Krüger, 2024, p. 17), como *deepfakes*, dificultando a distinção entre factos e mentiras (OECD, 2025, p. 20).

Neste contexto, torna-se essencial compreender corretamente os benefícios decorrentes do desenvolvimento das tecnologias de IA, reconhecê-las, compreendê-las e utilizá-las eficazmente, a fim de aumentar significativamente a nossa produtividade. Ao mesmo tempo, é igualmente importante evitar uma dependência excessiva da IA, preservando uma atitude racional e um pensamento crítico, de modo a transformá-la num verdadeiro o nosso “segundo assistente”.

1.1 Literacia em IA

A IA já ultrapassou o setor informático e passou a integrar o quotidiano em áreas como o comércio, a ciência e a educação, sendo utilizada para otimizar processos e automatizar tarefas simples. Esta presença generalizada torna essencial compreender o seu funcionamento e implicações (J. Zhang & Doherty, 2025, p. 4).

A literacia em IA é muito mais abrangente do que a literacia necessária no âmbito da tradução; nos Estudos de Tradução, há mais tratamento da MT do que da IA. A literacia em MT foca-se no pensamento crítico dos utilizadores em vez de competências tecnológicas (Bowker & Buitrago-Ciro, 2019).

Segundo a afirmação de J. Zhang & Doherty (2025, p. 4), a literacia em IA refere-se ao conjunto de competências essenciais para lidar com as tecnologias impulsionadas por IA nos domínios da vida quotidiana, da educação e do trabalho. Long & Magerko (2020, p. 2) apresentam uma definição mais detalhada de literacia em IA, entendida como um conjunto de competências que permite aos indivíduos avaliar criticamente estas tecnologias de IA, comunicar e colaborar eficazmente com sistemas de IA, bem como utilizar essas ferramentas em diferentes contextos, incluindo em casa ou no local de trabalho. Já Ng et al. (2021, p. 4) definem a literacia em IA como a capacitação dos aprendentes para adquirirem conceitos, competências, conhecimentos e atitudes fundamentais, independentemente de conhecimentos prévios, abrangendo não só a utilização de aplicação de IA como também a compreensão das tecnologias subjacentes. OECD (2025, p. 6) define a literacia em IA como:

AI literacy represents the technical knowledge, durable skills, and future ready attitudes required to thrive in a world influenced by AI. It enables learners to engage, create with, manage, and design AI, while critically evaluating its benefits, risks, and ethical implications.

Trata-se de uma competência essencial para assegurar um uso informado e ético da tecnologia, bem como para manter uma vantagem competitiva no mercado de trabalho (J. Zhang & Doherty, 2025, pp. 4–5). Ng et al. (2021, p. 2) e Krüger (2024, p. 14) consideram a literacia em IA como uma das literacias mais relevantes do século XXI.

Como a literacia em IA é um domínio emergente no século XXI, os estudos existentes ainda são limitados (Ng et al., 2021, p. 2). Um dos contributos mais precoces nesta área é o de Touretzky et al. (2019, pp. 9797–9798), que propõe cinco conceitos centrais da IA, que constituem uma base para a definição de um quadro de referência destinado à formação em literacia em IA, i.e.:

- Perceptions: Computers perceive the world using sensors.
- Representation and reasoning: Agents maintain models of the world and use them for reasoning.
- Learning: Computers can learn from data.
- Natural interaction: Intelligent agents need multiple forms of knowledge to communicate effectively with humans.
- Societal impact: AI technologies influence society in both positive and negative ways.

Além disso, Ng et al. (2021, pp. 4–9) identificam no seu estudo quatro aspetos fundamentais da literacia em IA: conhecer e compreender, usar e aplicar, avaliar e criar, bem como a ética da IA. Os autores propõem de forma inovadora o mapeamento das três dimensões práticas da literacia em IA aos níveis cognitivos da taxonomia de Bloom¹: ‘conhecer e compreender a IA’ é associado aos dois níveis mais elementares, ‘usar e aplicar a IA’ corresponde à aplicação; e ‘avaliar e criar IA’ integra os três níveis superiores, salientando igualmente a importância do domínio cognitivo, da responsabilidade social e da consciência ética. É de notar ainda que Krüger (2024, p. 15) propõe um quadro de literacia em IA para tradutores, estruturado em cinco dimensões: fundamentação técnica, desempenho específico do domínio, interação, implementação e aspetos éticos/sociais. Estas dimensões correspondem, respetivamente, às questões: O que é a IA? O que a IA pode fazer? Como funciona a IA? Como deve a IA ser utilizada? e como é percebida a IA pelas pessoas?

Ao contrário da NMT, que se centra sobretudo na capacidade de pensamento crítico do utilizador, as ferramentas de GenAI, pela sua natureza interativa, requerem

¹ Segundo Ng et al. (2021, p. 4), a Taxonomia de Bloom é um modelo que permite categorizar os níveis de raciocínio e pensamento estruturado em diferentes contextos de aprendizagem, contendo seis níveis organizados de formas progressiva, sendo que cada um deve ser dominado antes de avançar para o seguinte.

tanto a capacidade de pensamento crítico como a formulação de *prompts* adequados, de modo a gerar resultados de tradução mais eficazes (J. Zhang & Doherty, 2025, p. 5).

1.2 Projeto de prompts

1.2.1 O que é?

Os *prompts* são instruções direcionadas a um LLM, com objetivo de orientar o seu comportamento, automatizar determinadas tarefas e garantir que os resultados produzidos correspondem a padrões definidos de qualidade ou de volume (Hadi et al., 2024, p.6) (*Prompt Engineering Guide*, 2024) (OpenAI). A formulação adequada de um *prompt* revela-se fundamental para garantir uma utilização eficaz dos LLM no apoio à realização de tarefas; a construção adequada de um *prompt* pode mitigar desafios como as alucinações da máquina (B. Chen et al., 2025, p. 3).

1.2.2 Abordagens principais

As técnicas formais de *prompting* incluem estratégias baseadas em instruções explícitas (i.e.: estabelecer instruções explícitas para orientar o modelo na execução de uma determinada tarefa) (Hadi et al., 2024, p. 6). Segundo a afirmação de B. Chen et al., um *prompt* detalhado e preciso permite ao modelo gerar conteúdos mais ajustados às exigências de cada cenário, ao reduzir a incerteza e orientar a resposta na direção correta. Além disso, estratégias na adaptação às especificidades do sistema (i.e.: colocar uma questão ao modelo para que este produza uma resposta), no recurso a exemplos de formatação (i.e.: apresentar um exemplo de pergunta e respetiva resposta e solicitar ao modelo que responda de modo semelhante), na utilização de *tokens* de controlo (i.e.: utilizar palavras-chave específicas no enunciado para orientar o modelo a responder de acordo com critérios previamente definidos) e em processos interativos ou iterativos (i.e.: ajustar progressivamente o *prompt* por meio de iterações sucessivas com o modelo até alcançar uma resposta de qualidade) que permitem refinar progressivamente as respostas dos modelos.

Tendo em conta a natureza não determinista dos LLM, B. Chen et al. (2025, p. 6) propõem um *resampling* no seu estudo, ou seja, executar o modelo várias vezes com os

mesmos *prompts* e selecionar a melhor saída, mitigando a variabilidade das respostas. Para além disso, existem também *one-shot prompting* (refere-se a fornecer ao modelo um único exemplo como base de aprendizagem) e *few-shot prompting* (refere-se a fornecer ao modelo múltiplos exemplos como base de aprendizagem) segundo a complexidade das tarefas e a capacidade de modelo. O *zero-shot prompting* utiliza um LLM pré-treinado para executar tarefas sem treino específico, utilizando o seu conhecimento geral adquirido previamente (B. Chen et al., 2025, p. 6). Acresce que para melhorar a capacidade de interpretação do modelo e evitar ambiguidades, o uso de três triplas para separar diferentes partes de um *prompt* ou para delimitar cadeias de várias linhas, a técnica mostra-se particularmente adequada para *prompts* complexos (B. Chen et al., 2025, pp. 5–6).

Hadi et al. (2024, p. 6) apresentam alguns conjuntos de comandos no âmbito do *prompting*, a partir dos quais podem ser identificados quatro cenários principais:

(a) definição de papel ou contexto, como “atua como o meu secretário/consultor jurídico/tutor de programação”, que orienta o LLM quanto ao comportamento esperado e às condições de funcionamento; B. Chen et al.(2025, p. 5) afirmam que o *role-prompting* refere-se a atribuir ao modelo um papel específico, e apresentam alguns exemplos, como o de especialista, o que se revela eficaz para orientar as respostas e garantir a sua adequação ao resultado pretendido;

(b) geração automática de *prompts*, isto é, o modelo gera instruções mais adequadas para executar uma determinada tarefa;

(c) encadeamento do raciocínio (*Chain of Thought*), que fornece uma sequência de instruções curtas e relacionadas para conduzir o modelo por passos explícitos de inferência; e

(d) *prompts* orientados para tarefas correntes, como pedidos de explicação, guias instrucionais, extração de informação e auxílio em programação (por exemplo, identifique erros de sintaxe neste código) (Hadi et al., 2024, p. 6).

Para além do *prompting* (instrução positiva), existem ainda o *negative prompting* (instrução negativa, refere-se a fornecer instruções ao modelo sobre o que deve evitar

gerar, permitindo refinar os resultados, moderar conteúdos e prevenir a produção de textos ofensivos, incorretos ou inadequados) e o *visual prompting* (instrução visual baseia-se em fornecer ao modelo de IA estímulos visuais ou não visuais, como imagens ou música, como ponto de partida ou referência, para orientar a geração de conteúdos de forma mais precisa e próxima das expectativas do utilizador) (Hadi et al., 2024, p. 7). Por outro lado, Hadi et al. (2024, p. 31) propõem no seu estudo que devido ao fenómeno de “*model drift*” ou “*prompt drift*”, o desempenho do GPT-3.5 e do GPT-4 pode variar significativamente ao longo do tempo, o que exige uma melhoria na elaboração dos *prompts* para manter a performance.

Através destas técnicas, é possível potenciar de forma significativa a capacidade de controlo do modelo, bem como melhorar o seu desempenho em diferentes tarefas e contextos de aplicação.

1.3 Colaboração homem-máquina: um novo modelo de prática

Embora as traduções produzidas pela IA sejam precisas e fluentes, a complexidade da linguagem humana e as limitações destes sistemas tornam necessária a intervenção dos tradutores humanos. Neste sentido, a pós-edição (PE) assume um papel essencial, sendo fundamental que os futuros tradutores aprendam a trabalhar em cooperação com a IA (J. Zhang & Doherty, 2025, p. 3).

A PE, enquanto uma etapa central do processo de tradução, implica a revisão e otimização, por parte de tradutores humanos, dos resultados da MT, com vista a garantir a sua precisão, a coerência e o estilo do texto final (Mohd Saad et al., 2025, p. 4899; Qing, 2022, p. 11). Tendo em conta a complexidade inerente à pós-edição da tradução automática (PEMT), é necessário ter competências linguísticas aprofundadas, uma consciência cultural apurada, uma gestão eficiente do tempo (Khasawneh & Khasawneh, 2023, p. 7126) e a capacidade de diagnosticar eficientemente os padrões de erro (Mohd Saad et al., 2025, p. 4899; Qing, 2022, p. 13). Todavia, os métodos tradicionais de MTPE revelam uma forte dependência dos tradutores humanos e, apesar de produzir traduções de qualidade, apresentam custos elevados, exigem mais tempo e apresentam limitações de escalabilidade para grandes volumes de dados (Z. Liu et al.,

2024, p. 1). Neste quadro, uma prática de tradução inovadora de “colaboração homem-máquina”, i.e.: o *Human-in-the-Loop* (HITL), enfatiza a intervenção do tradutor humano como elemento central do processo.

Em comparação com a abordagem de PEMT tradicional, as ferramentas de GenAI têm capacidade de responder rapidamente a quantidade massivas de conteúdo, aumentando a eficiência dos fluxos de trabalho (Brotsi, 2025a, p. 11). Mediante processos de afinação, é possível assimilar terminologia especializada e estilos discursivos próprios, viabilizando traduções adequadas a áreas específicas, como a medicina ou o direito (Khasawneh & Khasawneh, 2023, p. 7126).

Ainda assim, as capacidades humanas insubstituíveis incluem a interpretação contextual complexa que transcende as capacidades algorítmicas, a fluência cultural, a criatividade, o julgamento ético e o pensamento crítico (He, 2025, pp. 4-11). Além disso, a inteligência humana orienta a validar os resultados produzidos pela IA (Mohd Saad et al., 2025, p. 4901).

Tendo em conta a integração crescente da IA no processo de tradução, o presente trabalho visa analisar os conhecimentos de IA indispensáveis à prática da tradução. O estudo desenvolver-se-á com base nas seguintes questões de investigação (RQ):

RQ 1: Quais são as ferramentas de GenAI mais utilizadas por estudantes de tradução e tradutores profissionais?

RQ 2: Em que medida os estudantes de tradução e os profissionais da área utilizam e conhecem as ferramentas de tradução baseada em IA?

RQ 3: Em que fases de tradução os estudantes e os profissionais utilizam ferramentas de GenAI e como percebem as limitações e desafios éticos?

Para responder a estas perguntas, o estudo segue uma abordagem quantitativa, recorrendo a um questionário semiestruturado para a recolha de dados, integrando perguntas de escolha múltipla e perguntas abertas, de modo a recolher as informações de forma abrangente.

O presente trabalho procura oferecer aos estudantes e profissionais de tradução uma porta de entrada para a compreensão e aquisição dos conhecimentos fundamentais

de IA, constituindo uma inspiração para a futura prática profissional dos tradutores. Integrando os conhecimentos teóricos com as evidências empíricas, pretende-se não apenas promover uma compreensão crítica da tecnologia GenAI entre estudantes e profissionais de tradução, mas também proporcionar uma perspectiva estudantil e profissional acerca da pertinência de integrar esta tecnologia, de forma precoce, no ensino da tradução. Prevê-se, como hipótese inicial, que os resultados do estudo indiquem que os estudantes tendem a aplicar as tecnologias de GenAI sem avaliação crítica, sem conhecimento dos seus princípios técnicos subjacentes nem das suas implicações éticas. Por conseguinte, torna-se necessário integrar conteúdos de GenAI no ensino da tradução, a fim de colmatar estas lacunas de conhecimento e dotar os estudantes de uma literacia básica em IA.

A estrutura do presente trabalho é a seguinte: a segunda parte apresenta a revisão de literatura, organizada em oito temas; a terceira parte descreve a metodologia e o desenho do questionário; a quarta parte apresenta a análise multidimensional dos dados, segundo três questões de investigação; a quinta parte corresponde à discussão e às conclusões.

2. Revisão de Literatura

A presente revisão de literatura inclui 8 secções, as 4 primeiras abordam as tecnologias fundamentais associadas à IA, abrangendo a sua origem, a aprendizagem automática (ML) e a aprendizagem profunda (DL), o processamento de linguagem natural (NLP), a tradução automática (MT). Estas secções focam-se numa revisão sistemática e nos fundamentos teóricos. As 4 secções seguintes analisam a evolução histórica da GenAI, os modelos de colaboração entre tradutor humano e IA, a literacia em IA e as necessidades formativas, concluindo com uma reflexão sobre as principais questões éticas observadas em estudos empíricos.

2.1 Origem, definição e classificação da Inteligência Artificial (IA)

Conforme os estudos existentes, a IA como disciplina científica apareceu a partir da Segunda Guerra Mundial (1939-1945). No entanto, a ideia de construir uma máquina inteligente ou uma criatura artificial capaz de reproduzir as capacidades humanas é muito antiga (Teixeira, 1990). A sua origem e a sua linha temporal podem ser sintetizadas de seguinte forma:

2.1.1 Origem da IA

No que respeita à origem da IA, há uma antiga anedota da Idade Média sobre um boneco mecânico que teria recebido um teólogo como se fosse um mordomo. Embora a sua veracidade seja questionável, essa história pode ser considerada um dos primeiros passos para compreendermos o conceito da IA (Teixeira, 1990).

Além disso, as origens remotas da IA podem ser associadas às lendas de criaturas artificiais, como o Golém no final do século XVI, uma figura de barro que ganhou vida por magia, símbolo primitivo da criação de seres inteligentes (Kanglang & Afzaal, 2021, p. 65; Teixeira, 1990).

Nos séculos seguintes, destacaram-se autómatos como o flautista mecânico e o pato de Vaucanson, projetados para reproduzir com realismo funções humanas e biológicas (Teixeira, 1990, p. 5).

Entretanto, filósofos como Descartes² e La Mettrie³ foram pioneiros na reflexão sobre as implicações filosóficas da criação dos autómatos. Descartes sustentava a possibilidade de que os seres humanos possuíssem alma ou pensamento, enquanto La Mettrie defendia que o pensamento teria origem no corpo e no cérebro, e não numa alma imortal, acreditando que um autômato suficientemente complexo poderia pensar e comunicar (Teixeira, 1990, p. 6). No século XIX, o debate filosófico arrefeceu, mas o tema das criaturas artificiais permaneceu presente na literatura, nomeadamente no romance *Frankenstein*⁴, que abordou os riscos e dilemas da criação artificial (Teixeira, 1990, p. 7).

A IA apenas começou a emergir apenas no século XX. Durante e após a Segunda Guerra Mundial (1939-1945), o avanço dos estudos sobre o funcionamento do cérebro, impulsionado por investigações em neurociência e pela realização do Simpósio de Hixon (1948), levou à analogia entre o cérebro humano e o computador, i.e.: “a organização dos neurónios no cérebro é semelhante ao circuito elétrico de um computador, pelo que a mente humana poderia ser replicada por uma máquina, contribuindo assim para o surgimento de uma nova disciplina: a Inteligência Artificial (Teixeira, 1990, pp. 8–9).”

Nos meados do século XX, Alan Turing, um dos primeiros pioneiros da IA, propôs o célebre “o teste de Turing” (1950) (Ertel, 2025, p.5). No teste, um participante testado encontra-se numa sala com dois terminais, um ligado a uma máquina e outro ligado a um ser humano e o participante pode fazer perguntas a ambos os terminais. Se a máquina conseguir enganar o avaliador em pelo menos 30% das vezes, considera-se que a máquina passou no teste (Ertel, 2025). Segundo Ertel (2025, p.5), os modelos de

² René Descartes (1596-1650), filósofo racionalista do século XVII, é oficialmente reconhecido como o fundador da filosofia moderna (Teixeira, 1990, p.6).

³ La Mettrie (1709-1751), filósofo francês, publicou um livro com objetivo de contestar as ideias de Descartes (Teixeira, 1990, p. 6).

⁴ *Frankenstein*, ou *o Prometeu Moderno* foi um romance feito pela romancista inglesa *Mary Shelley*, foi publicado em 1818. A obra foi o primeiro romance de ficção científica do mundo. No século XX, a história foi adaptada ao teatro, ao cinema, ao mito, até foi ainda recriada nos livros de banda desenhada. O nome do grupo de música português Dr. Frankenstein também se inspirou no mito, segundo [infopédia](https://www.infopedia.pt).

linguagem avançados, como o ChatGPT, passam facilmente a versão original desse teste.

2.1.2 Definição e classificação da IA

O termo da IA foi definido inicialmente por John McCarthy, um dos pioneiros da área, em 1955. No ano seguinte, foi ele o responsável pela organização da conferência na Faculdade Darmouth, segundo Ertel (2025, pp.6 e 10), Liu e Afzaal (2021). Conforme a sua definição, “o objetivo da IA é desenvolver máquinas que se comportem como se fossem inteligentes (Ertel, 2025)”.

Além disso, a *Enciclopédia Britânica* define a IA como a capacidade de computadores ou robôs controlados por computadores para resolver problemas normalmente associados à inteligência humana superior (Ertel, 2025, p.2). Contudo, esta definição apresenta fragilidades: a abrangência excessiva e a falta de precisão por causa da incapacidade de distinguir entre competências instrumentais e intelectuais.

Este dilema foi resolvido pela definição do Elaine Rich, que descreve a IA como “o estudo sobre como capacitar os computadores a executar tarefas que, atualmente, as seres humanas fazem melhor” (Ertel, 2025, p.2). A definição destaca-se pela sua flexibilidade e pela referência comparativa às capacidades humanas, mantendo-se relevante mesmo em 2050 (Ertel, 2025, p.1). Além disso, J. Zhang & Doherty (2025) citaram no seu estudo uma definição simples da IA do *Oxford English Dictionary*⁵,

The capacity of computers or other machines to exhibit or simulate intelligent behaviour [. . .] and also the software used to perform tasks or produce output previously thought to require human intelligence.

Segundo Ludermir (2021), a IA divide-se em três tipos: IA Focada, IA Generalizada e IA Superinteligente. A IA Focada (ou IA fraca) dedica-se a desempenhar uma tarefa específica, sendo incapaz de atuar fora do âmbito para o qual foi projetada. Por outro lado, a IA Generalizada (ou IA forte) distingue-se pela capacidade de compreender, aprender e aplicar conhecimentos de forma similar às

⁵ https://www.oed.com/dictionary/artificial-intelligence_n?tab=meaning_and_use&tl=true#38531565

habilidades cognitivas humanas, sendo este o nível atualmente alcançado pela IA. Já a IA Superinteligente, que ultrapassaria amplamente a inteligência humana, permanece ainda inexistente.

2.2 Machine Learning e Deep Learning no domínio da IA

Esta secção centra-se na aprendizagem automática (ML) e na aprendizagem profunda (DL).

O ML e o DL são conceitos estreitamente relacionados na área IA. Taye (2023a, p. 3) considera a IA como o cérebro, o ML como um robô obediente, responsável pelo processo através do qual a IA adquire novas capacidades cognitivas, já o DL é descrito como um robô com capacidade de aprendizagem autónoma, sendo o sistema de autoformação mais eficaz atualmente disponível.

2.2.1 Machine Learning (ML)

No que diz respeito à ML, Taye recorre ao exemplo de um recém-nascido a aprender a reconhecer automóveis para ilustrar o seu funcionamento (Taye, 2023a, p. 1). Por sua vez, Ertel (2025, p.178) utiliza a analogia do processo de aprendizagem da matemática para explicar o modo como o ML opera, ou seja, o professor ensina o procedimento e os alunos o praticam com base em novos exemplos. Após um certo número de erros, os alunos acabaram por perceber a adição através de cerca de 50 exercícios. Conforme a situação acima, Tom Mitchael, um dos pioneiros nesta área, define o ML como o estudo de algoritmos que melhoram automaticamente com a experiência, segundo Ertel (2025, p.180).

O ML permite que os sistemas informáticos aprendam com exemplos, sem necessidade de programação explícita, segundo Janiesch et al. (2021a) e Taye (2023a, p. 2). Por meio da análise de vastos volumes de dados, os algoritmos de ML detetam padrões e efetuam previsões ou tomam decisões com base nesses mesmos padrões (Janiesch et al., 2021a). O que superou as limitações da abordagem tradicional, que durante os últimos 50 anos, focou em codificar conhecimentos e procedimentos

existentes e incorporá-los em máquinas, transferindo os conhecimentos dos programadores para uma forma que as máquinas possam executar, segundo Janiesch et al. (2021, p.685). No entanto, grande parte do conhecimento humano é tácito e difícil de expressar, como ensinar alguém a andar bicicleta ou reconhecer o rosto de um amigo. Tal fenómeno é conhecido como o “Paradoxo Polanyi”⁶ (Brynjolfsson, 2017, pp. 6-7), i.e.: sabemos mais do que podemos dizer. O ML ultrapassa esses limites na segunda era de máquina, pois as máquinas já conseguem reconhecer rostos através de aprendizagem com exemplos e feedback estruturado, resolvendo o clássico problema de Polanyi (Brynjolfsson, 2017, p. 7).

Por isso, os algoritmos de ML têm sido utilizados com êxito em múltiplos domínios, como a deteção de fraudes, a avaliação de crédito, a análise da melhor oferta subsequente (Janiesch et al., 2021a, p. 686). Entre as áreas mais relacionadas com a linguagem e a tradução incluem-se o reconhecimento de voz e de imagem, assim como o processamento de linguagem natural (NLP).

Contudo, os sistemas de ML não generalizam o seu conhecimento por motivo do seu treino para realizar tarefas específicas. Conforme Brynjolfsson (2017, p. 6), um dos maiores equívocos sobre os avanços da IA é acreditar que uma compreensão limitada de um computador implica inteligência geral. Como explica Brynjolfsson,

[...] um sistema de IA pode traduzir discurso em chinês, mas isso não significa que compreenda o significado dos caracteres, muito menos que saiba onde comer em Pequim (Brynjolfsson, 2017, p. 6).

2.2.2 Abordagens de aprendizagens principais de ML

Existem 5 abordagens de aprendizagens principais de ML: aprendizagem supervisionada, não supervisionada, aprendizagem semi-supervisionada, aprendizagem por reforço e aprendizagem profunda (Taye, 2023b).

⁶ O paradoxo de Polanyi, proposto pelo filósofo e polímata Michael Polanyi em 1964, destaca os limites da transmissão de conhecimento tácito, o que limitou a capacidade das máquinas de realizar tarefas com eficácia na economia durante décadas (Brynjolfsson, 2017, pp. 6-7).

A aprendizagem supervisionada consiste na utilização de conjuntos de dados previamente rotulados para o treino de um modelo. Neste tipo de abordagem, o conjunto de dados contém características de entrada e saídas conhecidas correspondentes, permitindo que o modelo aprenda o mapeamento entre estas entradas e saídas para realizar previsões (Janiesch et al., 2021a, p. 687; Mohamed et al., 2024, p. 25556) (Brynjolfsson, 2017, p. 7). O resultado correto na aprendizagem supervisionada é previamente conhecido, e o algoritmo ajusta progressivamente as suas previsões de modo a reduzir a diferença entre a saída prevista e a real (Taye, 2023b, p. 6). Os algoritmos da aprendizagem supervisionada são os algoritmos de regressão (com saída contínua) e de classificação (com saída discreta). No caso da regressão, procura-se a função ótima que melhor se ajuste aos pontos do conjunto de treino, destacando-se três categorias principais: regressão linear, regressão linear múltipla e regressão polinomial. Os algoritmos de classificação atribuem cada entrada à classe correspondente, determinando os dados na categoria apropriada; neste caso, a função preditiva produz uma saída discreta, cujo valor corresponde a uma das classes possíveis (Taye, 2023b, p. 6).

Por sua vez, a aprendizagem não supervisionada baseia-se em conjuntos de dados não rotulados para realizar o treino, com o objetivo de identificar estruturas ou padrões ocultos nos dados. Duas tarefas frequentes nesta abordagem, aplicadas à análise de dados, são o agrupamento (*clustering*) e a redução de dimensionalidade (*dimensionality reduction*) (Janiesch et al., 2021a, p. 687; Mohamed et al., 2024, p. 25556). Além disso, Brynjolfsson (2017, p. 7) afirma que o ser humano é um excelente aprendiz não supervisionado, na medida em que adquire maior parte do conhecimento sobre o mundo com poucos ou nenhuns dados rotulados. Taye (2023b, p. 7) propôs redes neuronais (NN) especiais designadas *autoencoders* (AE), que são redes neurais cujas saídas correspondem às entradas. Os *autoencoders* processam os dados de entrada, codificando-os numa forma comprimida e, em seguida, decodificando-os para reconstruir a entrada original. Para além disso, existe outra variante mais complexa, o *autoencoder* profundo (Deep AE), em que as camadas ocultas inferiores são utilizadas

para codificação, enquanto as camadas superiores são usadas para decodificação, sendo o treino realizado através da retropropagação do erro (Taye, 2023b, p. 7). Veja-se a secção 2.2.4 4) Auto-encoders.

A aprendizagem semisupervisionada constitui uma abordagem intermédia entre a aprendizagem supervisionada e a não supervisionada, combinando uma pequena quantidade de dados rotulados com um grande volume de dados não rotulados para efeitos de treino. Esta abordagem revela-se interessante por reduzir a necessidade de intervenção humana e os custos associados à obtenção de dados rotulados, tendo em conta a escassez dos conjuntos de dados rotulados, bem como a sua difícil obtenção e o elevado custo. O princípio da abordagem consiste em adotar abordagens de aprendizagem não supervisionada para identificar padrões e estruturas nos dados não rotulados e, em seguida, aplicar técnicas de aprendizagem supervisionada para explorar essa informação, aumentando assim a capacidade de previsão do modelo (Taye, 2023b, p. 7). A aprendizagem semi-supervisionada envolve três pressupostos fundamentais: o pressuposto da suavidade (*Smoothness Assumption*), o pressuposto de aglomeração (*Cluster Assumption*) e o pressuposto de variedade (*Manifold Assumption*) (Taye, 2023b, p. 7). Para alcançar um desempenho superior ao de uma arquitetura única, Taye (2023b, p. 7) propôs uma arquitetura de aprendizagem híbrida (*Hybrid Learning*), no qual são combinados os pontos fortes de diferentes arquiteturas, integrando componentes de aprendizagem supervisionada (ou “discriminativa”) e não supervisionada (ou “gerativa”) para construir uma rede neural profunda mais robusta e, assim, obter resultados mais eficazes.

A aprendizagem por reforço (*RL – Reinforcement Learning*) é um método de “aprendizagem por tentativa e erro”; ao contrário da aprendizagem supervisionada, não recebe a resposta correta como referência; em vez disso, aprende através da interação com o seu ambiente, com o objetivo de maximizar as recompensas acumuladas (Janiesch et al., 2021a, p. 687; Mohamed et al., 2024, p. 25556). Taye (2023b, p. 8) considera a RL como um processo de aprendizagem baseado em tentativa e erro. Os

agentes de aprendizagem (*Learning agents*) possuem objetivos definidos e, mediante a percepção do estado do ambiente, podem atuar de forma a modificá-lo e aproximar-se das metas estabelecidas. Na RL, o algoritmo aprende através de um sistema de recompensas e punições, no qual o agente recolhe informação do ambiente, recebendo recompensas por comportamentos adequados e penalizações por comportamentos inadequados; o agente procura maximizar as recompensas e minimizar as penalizações, sendo que o algoritmo não recebe instruções explícitas sobre como aprender, devendo descobrir autonomamente o processo de aprendizagem (Taye, 2023b, p. 8). As aplicações da aprendizagem por reforço incluem os veículos autónomos e o programa AlphaGo, sendo igualmente explorada no NLP (Taye, 2023b, p. 8). Outro exemplo de aplicação como Microsoft para otimizar a seleção de títulos de notícias no MSN, com base nos cliques dos utilizadores (Brynjolfsson, 2017, p. 8).

A aprendizagem profunda (DL – *Deep learning*) é um domínio especializado do ML que utiliza redes neurais, nomeadamente redes neurais multicamadas, para processar e aprender com características de dados complexas. Em contraste com o ML, o DL adquire conhecimento de forma autónoma a partir de vastos volumes de dados, conseguindo otimizar o seu desempenho à medida que a quantidade de dados aumenta (Taye, 2023b). O DL baseia-se em redes neurais artificiais (ANNs – *Artificial neural network*), que simulam os mecanismos de aprendizagem dos neurónios do cérebro humano (Taye, 2023b, p. 3). Mohamed et al. (2024, p. 25556) definem o “*Deep*”, no contexto do DL, como “a inclusão de múltiplas camadas ocultas no design da rede neuronal, o que permite a aquisição de representações hierárquicas dos dados”. Uma rede neuronal é constituída por uma camada de entrada, uma ou várias camadas ocultas e uma camada de saída, sendo os neurónios interligados através de conexões ponderadas entre camadas adjacentes, o que possibilita o processamento da informação (Mohamed et al., 2024, p. 25556). Segundo o resumo de Taye (2023b, p. 3), o DL permite a aprendizagem autónoma e hierárquica de características em múltiplos níveis. A arquitetura do DL é capaz de realizar a extração e transformação de características em toda a sua arquitetura, permitindo que as camadas iniciais processem dados simples

e as camadas superiores captem padrões mais complexos. Esta estrutura torna o DL particularmente adequado ao tratamento de grandes volumes de dados e de elevada complexidade. De acordo com Mohamed et al. (2024, p. 25556), os modelos DL, também designados por redes neurais profundas (DNNs – *Deep neural networks*), demonstram um desempenho superior em tarefas que envolvem a identificação de padrões complexos, tais como o reconhecimento de imagens e de voz, bem como o processamento de linguagem natural, entre outros.

A evolução do DL baseia-se na superação das restrições dos modelos pouco profundos, por meio da criação de arquiteturas mais profundas, impulsionada pela ampliação da escala de dados (ImageNet) e pelo aumento da capacidade computacional (GPU – *Graphical Processing Units*). Este avanço originou um crescimento exponencial e estendeu-se ao domínio generativo (GANs – *Generative Adversarial Networks*), tornando-se um dos principais motores da IA. Trata-se do resultado da ação conjunta da inovação algorítmica, da acumulação de dados e do progresso computacional (Taye, 2023b, p. 9).

Segundo Taye (2023b, p. 14), as DNNs revelam eficácia em contexto de aprendizagem supervisionada, a não supervisionada, a por reforço (RL) e a híbrida. Os métodos de DL atualmente utilizadas baseiam-se, na maior parte, em pré-treino não supervisionado e afinação supervisionada (Taye, 2023b, p. 22).

2.2.3 Arquiteturas de DL

Segundo Janiesch et al. (2021a, pp. 689–690), existem 5 grupos essenciais de arquiteturas de DL: “redes neurais convencionais (CNNs – *Convolutional Neural Networks*), redes neurais recorrentes (RNNs – *Recurrent Neural Networks*), representações distribuídas (*distributed representations*), autoencoders e redes neurais generativas adversariais (GANs – *Generative Adversarial Neural Networks*).”

Antes de apresentar as arquiteturas, precisa-se de conhecer o que são redes neuronais. Segundo Otter et al. (2021, p. 605), as redes neuronais são constituídas por *nodes* interligados, que processam entradas através de somas ponderadas e funções de

ativação não lineares. Durante o treino, os pesos são ajustados com base nos erros observados ou nos *nodes* de saída, recorrendo-se, nas redes modernas, ao algoritmo de retropropagação (*backpropagation*) em conjugação com o gradiente descendente estocástico (*stochastic gradient descent*).

A diferença principal entre os diversos tipos de redes neuronais reside na forma de conexão dos *nodes* e no número de camadas. As redes neuronais *feedforward* (FFNNs – *Feedforward neural networks*) constituem a forma mais básica; permitem que a informação flua apenas num sentido, não sendo permitida a formação de ciclos. Já as DNNs correspondem geralmente a redes que possuem múltiplas camadas ocultas. Redes com número muito elevado de camadas são consideradas como redes de profundidade extrema, como as seguintes:

1) Redes neuronais convolucionais (CNNs – *Convolutional Neural Networks*)

As CNNs são amplamente aplicadas em tarefas de visão computacional, reconhecimento de voz, processamento de imagens e vídeos, bem como no NLP. Estas redes exploram relações especiais nos dados e permitem a extração hierárquica de características que leva à identificação de objetos (Janiesch et al., 2021a, p. 690; Otter et al., 2021, p. 605). Porém, o seu desempenho depende fortemente da quantidade e da qualidade dos dados de treino, apresentando limitações tanto quando estes são insuficientes ou de baixa qualidade, como quando se mostram extremamente sensíveis ao ruído (Taye, 2023b, p. 14).

2) Redes Neuronais Recorrentes (RNNs – *Recurrent Neural Networks*)

As RNNs são concebidas para lidar com dados sequenciais, tais como séries temporais, sequências de eventos e linguagem natural, permitindo modelar dependências temporais através de mecanismos de memória (Janiesch et al., 2021a, p. 690). Taye (2023b, p. 14) refere que as RNNs podem ser combinadas com CNNs a fim de gerar descrições precisas. Embora as apresentem limitações, como o problema dos gradientes dissipados e a dificuldade em capturar dependência de longo alcance (Janiesch et al., 2021a, p. 690; Taye, 2023b, p. 14; Hadi et al., 2024, p. 1), a sua variante

avançada como a LSTMs (*long short-term memory*)⁷ com mecanismos de atenção avançados⁸, consegue superá-las. Acresce que uma variante simplificada da LSTMs, designada *gated recurrent unit* (GRU), demonstra um desempenho equivalente ou superior ao da LSTMs em diversas tarefas (Otter et al., 2021, p. 605; Khurana et al., 2023, p. 3722). As RNNs aplicam-se em previsão de séries temporais, predição do comportamento de processos e tarefas de NLP, como a transdução de sequência (*sequence transduction*), a tradução automática neuronal (Janiesch et al., 2021a, p. 690) e reconhecimento de voz (Hadi et al., 2024, p. 1).

Além disso, a autoatenção (*self-attention*), enquanto uma das variantes dos mecanismos de atenção, permite considerar as relações entre palavras na mesma frase. O mecanismo é amplamente utilizado num modelo de SOTA, i.e.: codificador–descodificador (*encoder-decoder*), o *Transformer*⁹. Segundo Otter et al. (2021, p. 606), este modelo organiza múltiplos codificadores e descodificadores em camadas empilhadas, integrando a autoatenção em cada unidade e atenção cruzada entre elas. Ao recorrer a várias atenções em paralelo e dispensar o uso de RNNs ou CNNs, o Transformer consegue modelar dependência de longo alcance de forma mais eficiente e melhorar o desempenho em tarefas de processamento de linguagem natural.

3) Representações distribuídas

Mais importante é que as representações distribuídas permitem o desenvolvimento de modelos de linguagem mais avançados. Estas representações, através da codificação de entidades linguísticas em vetores densos que preservam

⁷ Segundo Otter et al. (Otter et al., 2021, p. 605), nas LSTMs, os *nodes* são estruturados de forma a permitir que certas informações sejam retidas, esquecidas ou expostas. Ao contrário das RNNs genéticas, que tendem a perder gradualmente a informação ao longo do tempo, as LSTMs conseguem guardar dados relevantes durante mais tempo e descartar os dados que não são importantes.

⁸ Os mecanismos de atenção surgem como solução à limitação das RNNs em condensar todas a sequência num único vetor, permitindo atribuir pesos diferenciados aos elementos mais relevantes do contexto. Entre as variantes encontram-se a *convolucional*, a *intratemporal*, e a *gated e a self-attention*, esta última aplicada a palavras na mesma frase (Otter et al., 2021, pp. 605–606).

⁹ Segundo Vaswani et al. (2017), “o *Transformer* constitui a primeira arquitetura de rede neuronal que elimina totalmente tanto a recorrência como as operações convoluções, baseando-se unicamente em mecanismos de atenção para alcançar uma tradução automática eficiente e de elevada qualidade, constituindo assim a base para modelos subsequentes como o BERT e o GPT e” (Para mais detalhes, ver as secções 2.3.5.2 e 2.5).

relações semânticas, superam limitações de métodos clássicos e constituem a base para o desenvolvimento de modelos capazes de executar tarefas mais complexas de NLP, muitas vezes em combinação com RNNs (Janiesch et al., 2021a, p. 690).

4) Autoencoders

Os autoencoders consistem, em geral, numa fase de codificação, em que a entrada é comprimida numa representação de baixa dimensão, e numa fase de decodificação, em que a rede procura reconstruir a entrada original a partir das características aprendidas, sendo assim levada a reter a informação essencial e eliminar o ruído irrelevante. Pela simplificação e reconstituição de dados, permitem a aprendizagem não supervisionada de representações latentes úteis para redução de dimensionalidade. Adicionalmente, graças à sua capacidade de quantificação dos erros de reconstrução, geralmente mais elevados em amostras anómalas do que em instâncias normais, são amplamente aplicados na deteção de anomalias, como fraudes em mercados financeiros (Janiesch et al., 2021a, p. 690). No entanto, os autoencoders também apresentam limitações como a exigência de longos tempos de treino e o risco de gerar informações pouco claras quando os dados de treino não representam adequadamente os de teste (Taye, 2023b, p. 14).

5) Redes neurais adversárias generativas (GANs).

Segundo Janiesch et al. (2021a, p. 690), as GANs são modelos capazes de aprender distribuições de probabilidade a partir de dados de treino, compostas por um gerador e um discriminador em treino competitivo, permitem criar novos dados realistas a partir de distribuições aprendidas, com elevado potencial para aplicações criativas, como na criação artística, no design ou na conversação de conteúdos entre representações distintas, mas também apresenta riscos significativos, como a produção de *deepfakes* (Janiesch et al., 2021a, p. 690). Adicionalmente, segundo Taye (2023b, p. 14), dado que a eficácia tanto do gerador como do discriminador é crucial para o sucesso do modelo, o processo de treino pode apresentar-se lento, devido ao recurso a funções de perda distintas.

2.2.4 Aplicação do DL em NLP

Segundo Taye (2023b, p. 17), o DL é aplicado em múltiplas áreas do NLP, incluindo tradução de voz, tradução automática, compreensão semântica computacional, etc., destacando-se sobretudo no processamento de imagens e em NLP. O ChatGPT, desenvolvido pela OpenAI, é uma técnica de NLP baseada em algoritmos de DL que permite às máquinas compreender e gerar diálogos em linguagem natural semelhantes aos humanos (Taye, 2023b, p. 18).

2.2.5 Desafios de sistemas inteligentes em ML e DL

A construção de modelos de ML e DL enfrenta o desafio de gerir o triângulo entre arquiteturas, hiperparâmetros e dados de treino, exigindo escolhas cuidadosas face a múltiplos *trade-offs* (ex.: precisão vs. custos computacionais), ausência de diretrizes padronizadas, dependência de competências técnicas e dificuldades de transposição dos resultados laboratoriais para cenários reais (Janiesch et al., 2021a, p. 691).

A consciência do viés e da deriva nos dados constitui um desafio central, pois incorporam vieses intrínsecos e sujeitos a variações ao longo do tempo (Janiesch et al., 2021a, p. 691) (Brynjolfsson, 2017, p. 10). Como evidenciado pelo viés de género presente no sistema de recrutamento da Amazon e pelo viés racial identificado na Google Vision AI. Adicionalmente, a alteração temporal das distribuições de dados pode comprometer a validade dos modelos em cenários reais, o que se revela precisamente na necessidade de revisão dos dados, de monitorização e atualização contínuas, bem como do restabelecimento de uma visão crítica (Janiesch et al., 2021a, pp. 691–692). Este tema será retomado na secção 2.8.

Outro desafio decorre da complexidade de modelos de DL, frequentemente descritos como “caixas-pretas” devido à sua reduzida explicabilidade. Brynjolfsson (2017, p. 10) caracteriza este fenómeno como uma espécie de versão inversa do paradoxo de Polanyi, i.e.: as máquinas sabem mais do que podem nos explicar. Esta limitação, acrescida das exigências legais de transparência, tem impulsionado o desenvolvimento da IA Explicável (XAI—*Explainable AI*) como solução para tornar

as previsões mais interpretáveis. Na prática, os investigadores enfrentam o dilema entre optar por modelos de maior precisão, mas pouco transparentes, ou por modelos ligeiramente menos precisos, mas mais compreensíveis, sendo ainda possível recorrer a técnicas de XAI para aumentar a explicabilidade dos modelos complexos (Janiesch et al., 2021a, p. 692).

Por fim, a limitação de recursos e a necessidade de *transfer learning* constituem um desafio central, pois, embora esta abordagem permita reutilizar modelos, frequentemente pré-treinados, e viabilize a difusão de sistemas inteligentes, inclusive por meio de mercados emergentes de *AI as a Service* (AIaaS), coloca em evidência riscos relacionados com vieses, ataques adversários, falta de explicabilidade e ausência de diretrizes claras para uma utilização responsável (Janiesch et al., 2021a, pp. 692–693). Para além disso, Brynjolfsson (2017, p. 9) acrescenta ainda que, à medida que esta modalidade se amplia e a concorrência entre as grandes empresas de IA se reforça, criam-se igualmente condições para a sua adoção com custos cada vez mais baixos.

2.3 Processamento de Linguagem Natural (NLP)

Esta secção sintetiza os fundamentos do Processamento de Linguagem Natural (NLP) na tradução, incluindo a sua definição, relevância, principais tarefas, aplicações, desafios, conjuntos de dados e modelos de *state of the art* (SOTA). Segundo D. Khurana et al. (2023, p. 3714), o NLP desempenhou um papel crucial na redução a distância entre humanos e computadores, tornando-se um importante domínio da investigação em IA.

2.3.1 Definição e relevância do NLP

Segundo a afirmação de Khurana et al. (2023, pp. 3714 – 3715), “o NLP, enquanto um ramo da IA e da Linguística, dedica-se a permitir que os computadores compreendam enunciados ou palavras escritas em línguas humanas, abrangendo tanto a compreensão da linguagem natural (NLU – *Natural Language Understanding*) como a geração da linguagem natural (NLG)”. Tal como a afirmação de Mohamed et al. (2024, p. 25555), o NLP constitui uma ponte entre seres humanos e computadores, ao facilitar

a comunicação através de uma compreensão, tratamento e produção mais eficazes da linguagem. Os avanços das tecnologias de NLP criam condições essenciais para o desenvolvimento subsequente dos LLM (Modelos de linguagem de grande escala).

2.3.2 Tarefas de investigação do NLP

O NLP inclui diversas áreas de investigação, entre as quais se destacam a tradução automática (MT – *Machine Translation*); o reconhecimento de entidades nomeadas (NER – *Named Entity Recognition*), utilizado na extração e classificação de informações, e o *optical character recognition* (OCR), que converte textos impressos ou manuscritos em formatos legíveis por máquina (Khurana et al., 2023, p. 3714).

A sumarização automática (*Automatic Summarization*), que gera textos resumidos e compreensíveis; a resolução de correferência (*Co-Reference Resolution*), que identifica palavras que remetem para o mesmo objeto; a análise do discurso (*Discourse Analysis*), que estuda a estrutura e o contexto social do texto; a segmentação morfológica (*Morphological Segmentation*), que divide as palavras em morfemas com significado; e a marcação de partes do discurso (*POS Tagging*), que determina a categoria de cada palavra numa frase (Khurana et al., 2023, pp. 3714–3715).

2.3.3 Aplicação e indicadores automáticos do NLP

As tarefas específicas do NLP, como a MT, o NER, o *Morphological Segmentation*, o *POS Tagging* e o *Discourse Analysis*, têm contribuído significativamente para o desenvolvimento da MT e de outras aplicações relacionadas com a tradução. Aqui apresentam-se apenas aquelas com ligação direta à tradução e à linguagem.

A MT consiste na conversão de texto de uma língua natural para outra, utilizando motores estatísticos que analisam grandes conjuntos de dados paralelos para estimar probabilidades de correspondência, como o Google Translate (GT). Desde setembro de 2016, a Google utiliza redes neuronais e técnicas de DL. Para avaliar a qualidade das traduções, surgiram indicadores automáticos como o *word error rate* (WER), o

position-independent word error rate, o *generation string accuracy* (GSA), o *multi-reference word error rate*, o *BLEU score*¹⁰ e o *NIST score*¹¹. Para além disso, o *GLUE*¹² *score* avalia a compreensão linguística dos modelos de NLU. Estes indicadores visam aproximar-se da avaliação humana em termos de fluência e adequação (Khurana et al., 2023, p. 3724).

Outra aplicação é a extração de informação (IE – *Information Extraction*), que identifica entidades relevantes, como nomes, locais, eventos ou datas, permitindo sintetizar dados textuais. A IE é amplamente utilizada na descoberta de conhecimento (*discovery of knowledge*), recorrendo a técnicas como *POS tagging*, *chunking or shadow parsing*, remoção de *stopword*, *Stemming*, identificação de expressões compostas e desambiguação lexical (*WSD – Word Sense Disambiguation*), possibilitando resumos, construção de bases de dados, identificação de palavras-chave e classificação de textos segundo categorias predefinidas (Khurana et al., 2023, pp. 3725–3726).

Por fim, os sistemas de diálogo permitem fornecer suporte ou executar ações específicas. Sistemas de diálogos iniciais centravam-se em aplicações simples, como sistemas de cinema em casa, os sistemas atuais exploram todos os níveis da linguagem,

¹⁰ O *BLEU score*, sigla de *Bilingual Evaluation Understudy*, é um indicador utilizado para avaliar a qualidade da tradução automática (MT). Este índice compara o resultado produzido pelo sistema de tradução com um conjunto de traduções de referência considerada de alta qualidade, calculando um valor entre 0 e 1 que reflete o grau de correspondência (Papineni et al., 2001). Geralmente, uma pontuação mais elevada indica uma tradução de melhor qualidade. No entanto, o BLEU apresenta também algumas limitações, nomeadamente por não ter em conta aspetos semânticos ou de fluidez textual (Khurana et al., 2023, p. 3736) (“BLEU,” 2025).

¹¹ O *NIST score*, sigla de *National Institute of Standards and Technology score*, é o outro indicador de avaliação mais utilizado da MT. O objetivo principal é avaliar a semelhança entre a MT e as traduções de referência humanas. O método baseia-se na comparação entre vários textos de referência e o resultado produzido automaticamente, atribuindo uma pontuação média ponderada de semelhança. Em comparação com o BLEU, que se concentra mais na repetição de segmentos textuais, o NIST valoriza sobretudo a consistência global do texto (Doddington, 2002).

¹² O *GLUE score*, sigla de *General Language Understanding Evaluation*, é um conjunto de tarefas de NLU. O *benchmark* integra nove tarefas distintas, que incluem *question answering*, análise de sentimentos e inferência textual, sendo acompanhado de uma plataforma em linha para avaliação, comparação e análise de modelos. De acordo com Wang et al. (2019, pp. 1–4) e Khurana et al. (2023, p. 3736), as tarefas principais avaliadas no GLUE incluem o CoLA (*Corpus of Linguistic Acceptability*), o SST-2 (*Stanford Sentiment Treebank*), o MRPC (*Microsoft Research Paraphrase corpus*), o QQP (*Quora Question Pairs*), o STS-B (*Semantic Textual Similarity Benchmark*), o MNLI (*Multi-Genre Natural Language Inference*), o QNLI (*The Stanford Question Answering Dataset*), o RTE (*The Recognizing Textual Entailment*) e o WNLI (*The Winograd Schema Challenge*).

viabilizando interações naturais, como o assistente da Google, a Cortana da Microsoft, a Siri da Apple ou a Alexa da Amazon (Khurana et al., 2023, p. 3727).

2.3.4 Desafios do NLP

Conforme Khurana et al. (2023, pp. 3736–3737), o NLP já se desenvolveu bastante em relação às línguas mais comuns, mas também apresenta desafios significativos relacionados com compreensão de contexto, ambiguidade e diferenças culturais. Por exemplo, uma mesma palavra ou expressão pode ter significados distintos consoante o contexto; existem sinónimos de diferentes graus de complexidade; homónimos podem ser interpretados de várias formas; as frases ligadas a culturas específicas podem ter múltiplas interpretações, representando um desafio para os modelos de NLP (Khurana et al., 2023, pp. 3636–3637).

Adicionalmente, ambiguidades do ponto de vista pragmático não podem ser ignoradas, uma vez que os textos pragmáticos vão além dos significados semânticos literais das palavras e precisam compreensão dos sentidos implícitos (Khurana et al., 2023, p. 3718). Mais é difícil que uma única abordagem alcance objetivos como a interpretação, a análise e a manipulação dos dados da língua natural.

Por fim, existem desafios específicos para cada língua, visto que as ferramentas e técnicas mais utilizadas são concebidas sobretudo para línguas indo-europeias, havendo menor investigação sobre línguas asiáticas ou do Médio Oriente. Além disso, há também desafios no tratamento de línguas não-padrão, pois a gíria comum e as línguas não-padrão são frequentemente difíceis de utilizar com as ferramentas de NLP padrão, que muitas vezes não conseguem ser implementadas de forma eficaz (Khurana et al., 2023, p. 3723).

2.3.5 Conjuntos de dados e modelos state of the art (SOTA) em NLP

2.3.5.1 Conjuntos de dados em NLP

Esta secção apresenta uma síntese dos conjuntos de dados mais relevantes a tradução no âmbito do NLP. Porém, importa-se clarificar o conceito de *corpus* e as principais tipologias.

Segundo Khurana et al. (2023, p. 3730), um corpus é uma coleção de dados linguísticos compilado a partir de textos escritos ou transcritos a partir de gravação de voz, utilizada para testar hipóteses linguísticas, como o uso de sons, palavra ou construção sintática numa determinada língua ou cultura. Os autores resumem 8 (oito) corpora: anotado e não anotado, de referência e de monitorização, multilingue e paralelo, de referência e de voz (*speech corpus*), entre os quais, o corpus multilingue é uma coleção de pequenos corpora monolingués construídos segundo o mesmo procedimento de amostragem e categorias, em diferentes línguas; o corpus paralelo contém textos numa língua e as respetivas traduções noutras, alinhadas frase a frase ou segmento a segmento; enquanto o corpus de referência permite comparar diferentes línguas, o outro corpus de referência, segundo os autores, abrange textos orais e escritos, em variantes formais e informais. Além disso, este corpus representa distintos contextos sociais e situacionais.

Os conjuntos de dados mais utilizados na tradução destinam-se à modelação da linguagem e à MT. A modelação da linguagem analisa dados textuais para calcular a probabilidade de ocorrência das palavras, permitindo ao modelo aprender características da língua e prever ou gerar frases contextualizadas (Khurana et al., 2023, p. 3731). Os dados provêm de corpora como WikiText-103, WikiText-2, *Penn Treebank* (extraído de textos jornalísticos) e recursos institucionais, como o TDIL da Índia (Khurana et al., 2023, p. 3731).

Os conjuntos de dados de MT provêm principalmente de corpora paralelos e monolingués de diversas fontes, incluindo pares de frases multilingues (Tatoeba), registos parlamentares (Europarl), corpora de tarefas específicas de tradução (WMT, IWSLT) e recursos regionais ou nacionais (como o *IIT Bombay English-Hindi*), incluindo diferentes combinações de linguísticas e tamanhos de corpus. Por exemplo,

o WMT, fornece pares de tradução inglês-alemão e inglês-francês com milhões de frases codificadas em *Byte-Pair Encoding*.

2.3.5.2 Modelos SOTA em NLP

Esta secção apresenta uma síntese dos modelos de SOTA em NLP até 2018. No entanto, menciona apenas dois modelos com relevância direta para a tradução.

O mais relevante são redes neurais, cujo elemento central é a incorporação de *word embeddings*, representações vetoriais que permitem identificar semelhanças semânticas. As redes neurais foram inicialmente implementadas em arquitetura *feedforward* e CNNs, avançando posteriormente para RNNs, capaz de captar o contexto de uma palavra em relação à palavras circundantes, e para a sua variantes como LSTMs, aplicada na previsão de palavras e previsão de tópicos de frases (Khurana et al., 2023, pp. 3734–3735). As GRUs (*Gated Recurrent Units*), uma variante simplificada das LSTMs, com melhor desempenho em várias tarefas (Khurana et al., 2023, p. 3722). E as LSTMs bidirectionais permitem observar a disposição das palavras em ambas as direções (Khurana et al., 2023, p.3735). O outro modelo referido aplica-se à arquitetura codificador-decodificador na MT e ao reconhecimento de voz, entre outras.

O BERT (*Bi-directional Encoder Representations from Transformers*) é um modelo de linguagem pré-treinado capaz de captar simultaneamente informações contextuais e resolver a ambiguidade lexical. Pré-treino (BookCorpus¹³ + Wikipedia¹⁴) em grande escala de formas não supervisionada, pode ser ajustado (*fine-tuned*) para diferentes tarefas de NLP. É de notar que, devido à limitação de comprimento máximo de entrada de 512 *tokens*, textos longos devem ser segmentados para processamento (Khurana et al., 2023, p. 3735). Outros estudos sobre o BERT incluem Devlin et al. (2019), Liu et al. (2019) e Sanh et al. (2020). Importa referir que o modelo anterior do

¹³ Segundo Zhao et al. (2023, p. 13), o BookCorpus é utilizado frequentemente em modelos de pequena escala como o GPT e o GPT-2 (veja Secção 2.5.1), reúne mais de 11.000 livros e abrange uma grande variedade de temas e géneros, como romances e biografias.

¹⁴ Segundo Zhao et al. (2023, p. 14), a Wikipedia é uma enciclopédia online composta por grandes volumes de artigos de qualidade elevada, escritos em estilo expositivo e acompanhados de referências. Disponível em várias línguas, é amplamente utilizada em modelos de linguagem, sobretudo através de versões filtradas em inglês, como o caso do GPT-3, LaMDA e LLaMA.

BERT, o GPT (*Generative Pre-Training*), recorreu a pré-treino generativo e a afinação discriminativa (*Discriminative Fine-tuning*) para melhorar a compreensão da linguagem. Os detalhes relativos ao GPT são apresentados na secção 2.5.

2.4 Evolução e estado atual da tradução automática (MT)

Esta secção visa resumir a evolução e o estado atual da MT, incluindo a tradução automática baseada em regras (RBMT – *Rule Based Machine Translation*), em exemplos (EBMT – *Example Based Machine Translation*), em estatística (SMT – *Statistical Based Machine Translation*) e a tradução automática neuronal (NMT – *Neural Machine Translation*).

Sharma et al. (2023) realizam uma análise sistemática da evolução da MT, investigando desde modelos tradicionais até os modelos mais recentes e avançados, com o objetivo de fornecer uma compreensão aprofundada, uma avaliação comparativa das diferentes arquiteturas e a identificação de direções futuras na área.

Segundo a opinião de Sharma et al. (2023, p.1), a MT pretence à subárea do NLP que tem como objetivo realizar a tradução automática de uma língua natural para outra. A sua origem remonta ao conceito de automatização concebido em 1933 por Peter Petrovich Troyanskii. E mais tarde a ideia de automatização da tarefa de tradução foi retomada pelo A.D. Booth e Warner Weaver, em 1946.

De forma geral, o percurso de desenvolvimento da MT pode ser resumido da seguinte forma, a abordagem baseada em regras artificiais, passa para a abordagem estatística, posteriormente, para a abordagem baseada em DL. A linha temporal pode ser apresentada da seguinte forma (Figura 1):

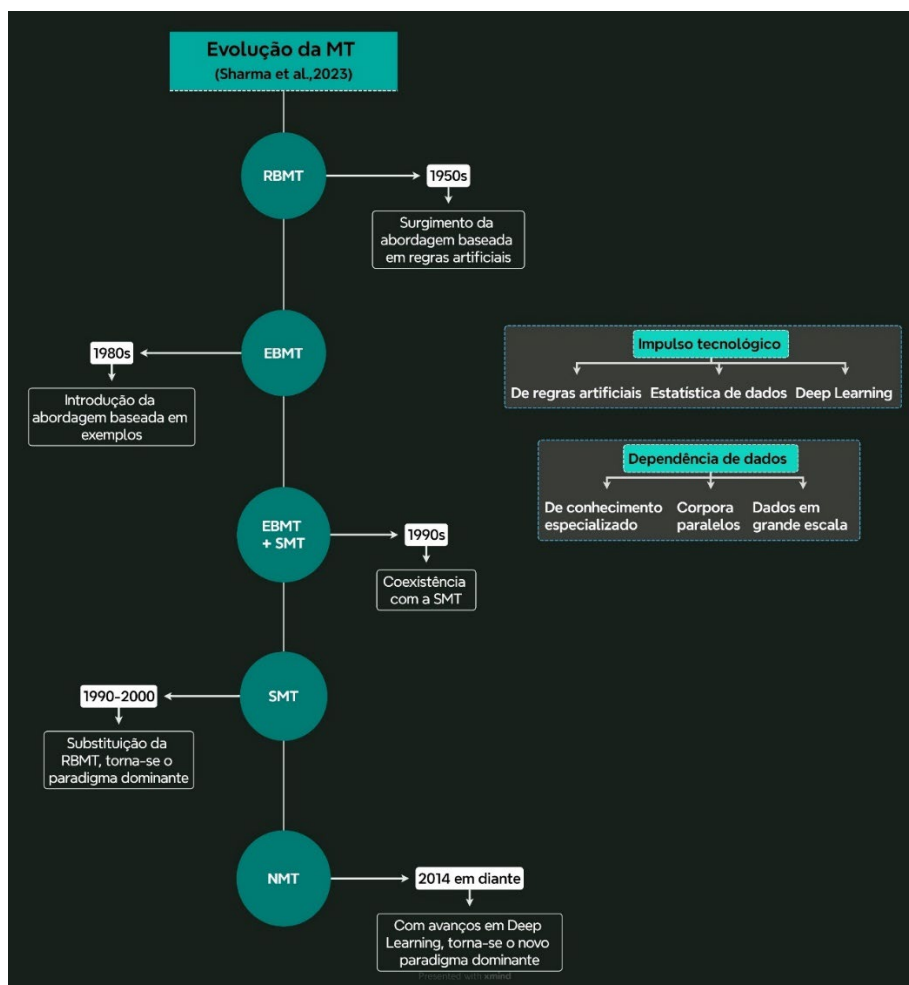


Figura 1. Evolução da MT.

(Elaboração própria)

2.4.1 Tradução automática baseada em regras (RBMT)

Segundo Sharma et al. (2023), a RBMT, composta por regras e léxico, com regras criadas artificialmente a partir de conhecimentos linguísticos, é um sistema de tradução que segue uma abordagem orientada pelo conhecimento. Por conseguinte, a sua utilização depende fortemente de recursos linguísticos, como dicionários bilingues, gramáticas e dicionários morfológicos. A dependência limita a utilização só para pares de língua com estruturas sintáticas, semânticas e morfológicas semelhantes, também dá origem a custos elevados de conceção e manutenção, capacidade limitada da resolução de ambiguidades, bem como uma fluência reduzida.

2.4.2 Tradução automática baseada em exemplos (EBMT)

Segundo Sharma et al. (2023), a EBMT foi concebida por Nagao, em 1981, como resposta aos problemas enfrentados pela RBMT. A ideia essencial baseia-se em corpora bilíngues e bases de dados de exemplos, através de combinação a frase de entrada com exemplos existentes e gerar a tradução com base na semelhança. O seu modo de funcionamento é semelhante ao da memória de tradução no MemoQ. Como descrito por Sharma et al. (2023), a EBMT é também conhecida como “tradução baseada em memória”.

2.4.3 Tradução automática baseada em estatística (SMT)

Segundo Mohamed et al. (2024), “existem duas metodologias estatísticas fundamentais no domínio da MT, que são a EBMT e SMT.” Ambas as metodologias utilizam modelos estatísticos baseados em parâmetros extraídos de corpora bilíngues alinhados, e com custos reduzidos em comparação com RBMT. Contudo, apresentam-se dificuldades no caso de idiomas com recursos limitados, sendo a escassez de dados e a arquitetura complexa, conforme descrito por Sharma et al. (2023).

Considerando que a SMT tem dependido de grandes corpora paralelos, alguns estudos têm demonstrado que é possível recorrer exclusivamente a corpora monolíngues, utilizando métodos híbridos não supervisionados, para treinar sistemas de SMT e de tradução automática neuronal (NMT). Para além disso, uma revisão recente das técnicas de aprendizagem profunda para NMT mostra que a combinação de modelação linguística por redes neurais com dados monolíngues pode melhorar o desempenho de sistemas de MT.

Artetxe et al (2018) demonstra no seu estudo que, tirando pleno partido da arquitetura modular da SMT, incluindo mapeamentos de *embeddings* translinguísticos, ajustamento dos hiperparâmetros através de uma variante não supervisionada do *MERT* (*Minimum Error Rate Training*) e melhoria adicionalmente a qualidade da tradução por meio de retrotradução iterativa (*BT – back-translation*), é possível melhorar substancialmente a utilidade e o desempenho de sistemas de tradução automática não

supervisionados, aproximando-os do nível de sistemas supervisionados, mesmo na ausência de corpora paralelos. Nos testes realizados nas tarefas de tradução do WMT 2014¹⁵ (Inglês-Alemão e Inglês-Francês), obtiveram-se melhorias significativas: 14,08 BLEU em Inglês-Alemão e 26,22 BLEU em Inglês-Francês, o que representa um ganho de 7 a 10 pontos BLEU face a sistemas não supervisionados anteriores, reduzindo a diferença para sistemas SMT supervisionados (Moses + Europarl) para apenas 2 a 5 pontos BLEU. O estudo estabelece as bases para a SMT não supervisionados, mas evidencia ainda um limite de desempenho. Para além disso, propõe uma outra abordagem híbrida com a NMT, ou seja, recorre-se ao sistema SMT não supervisionado para gerar um corpus paralelo sintético, utilizando-o depois para treinar um sistema NMT através de BT iterativa, combinando assim as vantagens de ambas as abordagens.

Artetxe et al. (2019) concretizam esta abordagem híbrida no estudo subsequente, propõem um método de SMT não supervisionado com uma base teórica mais sólida, incorporando informação de subpalavras (*subword*), bem como um processo de afinação não supervisionada mais rigoroso e um refinamento conjunto bidirecional (*joint refinement*), tornando assim a tabela de frases gerada mais robusta. Os autores utilizam esta SMT melhorada para inicializar um modelo NMT bidirecional, formando um sistema híbrido SMT+NMT. Esta abordagem obteve, em tarefas do WMT 2014/2016 para inglês-francês e inglês-alemão, pontuações BLEU superiores em 5 a 7 pontos face aos sistemas não supervisionados de referência, e ainda melhorias adicionais de 5 a 9 pontos em relação a soluções híbridas SMT-NMT anteriores. Em alguns casos, os resultados superaram mesmo o melhor sistema supervisionado do WMT 2014, demonstrando que a combinação SMT+NMT pode servir como uma alternativa viável.

¹⁵ O WMT (*Workshop on Machine Translation*) é um dos principais encontros internacionais dedicados à tradução automática, criado em 2006 no âmbito da NAACL (*North American Chapter of the Association for Computational Linguistics*). O WMT tem como objetivo promover a partilha de conhecimentos e experiências entre investigadores da academia e da indústria, abrangendo temas como tradução de frases, tradução em línguas com poucos recursos, avaliação de qualidade e sistemas multilingues. Desde a conferência da ACL em Berlim, em 2016, o WMT passou de um simples workshop a uma *Conference on Machine Translation* independente, mantendo-se até hoje como uma das principais referências para quem investiga esta área.

Khalilov et al. (2008) propõem uma combinação de modelação linguística por redes neurais (*Neural Network Language Models – NNLM*) para melhorar o desempenho dos sistemas de SMT com pequenos conjuntos de dados de treino. O estudo demonstra o potencial da aplicação da modelação linguística por redes neurais na SMT para melhorar a fluência e a adequação da tradução, realizando experiências num pequeno corpus de tradução italiano-inglês (cerca de 150.000 palavras) com um corpus básico de expressões de viagem. Os resultados demonstraram o potencial da aplicação da modelação linguística por redes neurais (*NNLM*) para melhorar a fluência da tradução e o desempenho geral na SMT.

2.4.4 Tradução automática neuronal (NMT)

A tradução automática neuronal (NMT) apresenta diferenças face à SMT tradicional, segundo Sharma et al. (2023), por meio da integração de abordagens de DL, que têm conseguido mitigar os problemas de escassez de dados de certa forma, através da substituição da representação simbólica por representações distribuídas. Adicionalmente, a NMT utiliza uma abordagem *end-to-end*: um único modelo neuronal é capaz de traduzir diretamente uma frase de uma língua para outra. Este modelo é normalmente composto por dois módulos principais: o codificador, responsável por interpretar a frase original, e o decodificador, encarregado de gerar a frase traduzida (Otter et al., 2021, p. 605). Segundo Bahdanau et al. (2016), a SMT tradicional assemelha-se a uma “linha de montagem modular”, em contraste com a NMT que equivale a uma “caixa negra integrada”, treinada de forma *end-to-end* e capaz de gerar diretamente a frase na língua de chegada (LC) a partir da frase na língua de partida (LP). A introdução do mecanismo de atenção permite ao modelo centrar-se, durante a tradução, nas palavras mais relevantes do texto de partida (TP) (Otter et al., 2021, p. 606). Porém, a filosofia de funcionamento da NMT apresenta as certas limitações. Em primeiro lugar, a falta de explicabilidade, também é conhecido pela “caixa preta”, ou seja, as redes neuronais funcionam como uma caixa preta, o que dificultou a compreensão da sua lógica interna. Ademais, a abordagem depende fortemente de

grandes quantidades de dados bilíngues de elevada qualidade. De acordo com Sharma et al. (2023a) , “[...] *NMT is data-hungry*”: quando tais dados são escassos, o desempenho da tradução tende a ser insatisfatório, a limitação mesma tem sido discutida pelos diversos estudos, como os estudos de Cheng et al. (2016), Bahdanau et al. (2016), Gulcehre et al. (2017), Burlot & Yvon (2019) e Zhou et al. (2019) . Para além disso, há problemas de palavras *out-of-vocabulary* (OOV) e de dificuldade no processamento de frases longas (Sharma et al., 2023).

Considerando a escassez de corpora paralelos em grande escala, elevada qualidade e ampla cobertura, Cheng et al. (2016) propõem uma abordagem de treinamento bidirecional semi-supervisionada combinada com autoencoders, permitindo que a NMT explore de forma mais aprofundada dados monolíngues em ambos os sentidos, ultrapassando as limitações impostas pela falta de dados paralelos. Em concreto, a abordagem recorre a concatenação de dados rotulados (corpora paralelos) e não rotulados (corpora monolíngues), integrando os autoencoders nos corpora monolíngues, no qual os modelos de tradução fonte-alvo e alvo-fonte servem como codificador e decodificador. Com um corpus paralelo chinês-inglês e dois corpora monolíngues em chinês e inglês que provêm do *GIGAWORD* (*parte da Xinhua News Agency*), verificado no conjunto de dados NIST chinês-inglês, a abordagem superou aos sistemas SMT e NMT mais avançados em tarefas de tradução bidirecional. Para além disso, os autores propõem também recorrer a técnica de Vocabulário-Alvo de grande escala¹⁶ para superar a limitação de palavras OOV, sugerem validar esta abordagem em mais pares de línguas e diferentes arquiteturas de NMT, além de

¹⁶ De acordo com Jean et al. (2015) , a técnica do Vocabulário-Alvo de grande escala recorre a “amostragem por importância” para reduzir o custo computacional do treino, sem aumentar a complexidade, permitindo que o modelo de NMT possa aprender eficazmente com um vocabulário muito mais alargado. Tendo em conta a riqueza vocabular dos corpora monolíngues (que incluem palavras OOV nos corpora paralelos), estas palavras não registadas podem levar a uma cobertura insuficiente do vocabulário, limitando a capacidade do modelo de aprender boas representações e, assim, prejudicando a qualidade da tradução. Ao integrar a técnica do Vocabulário-Alvo de grande escala dos Jean et al. (2015), o modelo consegue abranger também palavras raras ou de baixa frequência presentes nos corpora monolíngues, reduzindo significativamente o número de palavras OOV.

indicarem como linha de investigação futura o reforço da ligação entre os modelos de tradução de origem para destino e de destino para origem.

Bahdanau et al. (2016), ao considerarem as limitações do modelo tradicional codificador – decodificador, nomeadamente o facto de o codificador comprimir a frase na LP num vetor de comprimento fixo, a partir do qual o decodificador gera a frase na LC, o que leva a uma perda de qualidade à medida que a frase se torna mais longa, propuseram a introdução de um mecanismo de alinhamento no âmbito da NMT, denominado como *RNNsearch*. Esta abordagem superou a limitação do vetor fixo, melhorando significativamente a qualidade da tradução de frases longas e complexas. No caso da tradução inglês-francês, o *RNNsearch* apresentou um desempenho equivalente ao sistema de tradução por frases (SMT) mais avançado, demonstrando maior estabilidade e robustez para frases longas. No entanto, importa salientar que o modelo foi treinado com uma lista de vocabulário fixo (*shortlist*), limitado às 30 000 palavras mais frequentes (Bahdanau et al., 2016, p.5). Assim, se surgirem palavras fora desta lista, o modelo trata-as como “[UNK]” (palavra desconhecida), o que revela que ainda há lacunas no tratamento de palavras raras.

Gulcehre et al. (2015) (2017) demonstram que é possível melhorar o desempenho da NMT através da utilização eficaz de corpora monolíngues nos seus estudos em 2015 e 2017. Nesse sentido, os autores propõem duas abordagens, i.e., a combinação do modelo de linguagem com o sistema de tradução neuronal ao nível da camada de saída (fusão superficial), e a fusão desses modelos ao nível das camadas ocultas (fusão profunda). Estas metodologias foram avaliadas empiricamente em tarefas de tradução de baixo recurso (turco-ínglês), em domínio específico (como traduções de mensagens em chinês-ínglês) e em tarefas de alto recurso (checo-ínglês e alemão-ínglês). Os resultados indicam que, em contextos de tradução com menos paralelos ou em domínios específicos, a integração de um modelo de linguagem monolíngue através de fusão profunda contribui para melhorar significativamente a qualidade da tradução, sobretudo quando os recursos paralelos são limitados e existe uma elevada correspondência de

domínio (Gulcehre et al., 2015, 2017). Outro estudo semelhante, como o de Domhan & Hieber (2017) apresentou a introdução de um mecanismo de aprendizagem multitarefa no decodificador da NMT, permitindo a integração de dados monolíngues sem necessidade de pré-processamento (pré-tradução ou pré-treino). Embora os resultados obtidos sejam inferiores à abordagem de corpora paralelos, este estudo abre novas perspectivas para a otimização dos processos de treino na NMT.

A BT (*back - translation*) é considerado a abordagem mais eficaz para aproveitar dados monolíngues (Sennrich et al., 2016), consistindo em gerar corpora paralelos artificiais a partir de textos monolíngues na LC. Contudo, esta abordagem apresenta limitações, como os custos computacionais elevados e a dificuldade em determinar a quantidade e a qualidade adequadas dos dados de BT (Burlot & Yvon, 2019). Os autores exploram sistematicamente as questões fundamentais do BT, como o impacto das diferentes formas de gerar corpora paralelos artificiais na qualidade da tradução, as características linguísticas das frases de BT, bem como a possibilidade de simular o BT. Os resultados confirmam a eficácia do BT, apresentando métodos alternativos mais económicos, como “*stupid back-translation*” e GANs. Concluem ainda uma comparação com a integração de modelo de linguagem apresentado do Gulcehre et al. (2017), o resultado demonstra que o BT é mais preferível à integração do modelo de linguagem.

Zhou et al. (2019) propõem um modelo de tradução automática neural bidirecional síncrona (SB-NMT– *Synchronous Bidirectional Neural Machine Translation*) para resolver os problemas de saída desequilibrada a que descodificação unidirecional leva. O modelo permite que a descodificação da esquerda para a direita (*L2R – left-to-right decoding*) e da direita para a esquerda (*R2L – right-to-left decoding*) sejam realizadas simultaneamente e utilizadas mutuamente, aproveitando plenamente as informações contextuais históricas e futuras. Para além disso, o estudo integra a atenção bidirecional síncrona num modelo único da NMT. Os resultados experimentais

demonstram melhorias substanciais em relação ao modelo *Transformer*, e nas tarefas de tradução Chinês-Inglês e Inglês-Alemão até alcança resultados de SOTA.

Tan et al. (2020) realizam uma avaliação sistemática do estado atual da NMT, abrangendo arquiteturas (*architectures*), estratégias de descodificação (*decoding tactics*), métodos de aumento de dados (*data augmentation methods*), abordagens de interpretabilidade (*interpretation approaches*) e metodologias de avaliação (*evaluation methodology*). O estudo reúne um resumo dos recursos paralelos e monolíngues disponíveis publicamente, bem como das ferramentas mais utilizadas na área da NMT. Os autores destacam questões centrais que permanecem em aberto, tal como o caso da interpretabilidade da NMT, nomeadamente a necessidade de compreender como e por que razão o sistema produz determinados resultados de tradução, identificando eventuais limitações ou fragilidades do modelo, o desenvolvimento de arquiteturas mais eficientes (superando o *Transformer*) e a exploração mais abrangente de dados monolíngues. A integração efetiva do conhecimento humano na NMT continua a ser um desafio por resolver.

2.5 Transformações Tecnológicas na Tradução Escrita sob a Influência da GenAI

Esta secção aborda os estudos iniciais do OpenAI, bem como apresenta alguns dos LLM mais relevantes atualmente no mercado.

O avanço decisivo nos LLM ocorreu com a introdução da arquitetura *Transformer* no trabalho seminal *Attention is All You Need* de Vaswani et al. (2017). O *Transformer* permite o processamento paralelo e o tratamento eficiente de dependência de longo alcance, estabelecendo as bases para modelos como a série GPT da OpenAI e o BERT da Google, que alcançam resultados inovadores em diversas tarefas linguísticas. Estes modelos, frequentemente pré-treinados em grandes volumes de texto, permitem uma compreensão contextual mais precisa e a geração de texto coerente e relevante, transformando aplicações como *chatbots*, resumo automático, perguntas e respostas (*question answering*) e MT (Hadi et al., 2024, p. 1; Khowaja et al., 2024).

Radford et al. (2018) exploram uma abordagem semissupervisionada, que combina pré-treino generativo (GPT—*Generative Pre-training*) e afinação discriminativa (*Discriminative Fine-tuning*), para melhorar a compreensão da linguagem. Este trabalho corresponde à primeira versão do GPT. O processo de treino divide-se em duas etapas: na primeira fase, treina-se um modelo de linguagem de grande capacidade sobre um vasto corpus textual que contém um conjunto de 7.000 livros inéditos e únicos do BooksCorpus; em seguida, o modelo previamente pré-treinado é aplicado a tarefas específicas com dados anotados, como inferência em linguagem natural, perguntas e respostas (*question answering*) e semelhança semântica, entre outras. Assim sendo, procede-se apenas a uma afinação para que o modelo geral se adapte à nova tarefa. Este modelo estabeleceu novos SOTA em múltiplas tarefas (9/12) de NLP (Radford et al., 2018). O estudo construiu uma base sólida para a evolução de modelos de linguagem avançados.

O estudo seguinte apresenta um argumento mais ousado: quando um modelo de linguagem atinge uma dimensão suficientemente grande, torna-se capaz de executar tarefas a jusante diretamente através de *prompts (zero-shot)*, sem necessidade de afinação explícita (Radford et al., 2019). Os autores recorreram a um novo conjunto de dados, o *WebText* (40 GB), extraído a partir de hiperligações para páginas da Web com elevada valorização no *Reddit*¹⁷. Os resultados demonstram que o modelo de linguagem, que é designado pelos autores como GPT-2, treinado com o *WebText* apresenta um desempenho notável, alcançando o SOTA em 7/8 de dados, embora os resultados em outras tarefas de NLP, como tradução, sumarização e perguntas e respostas (*question answering*), revelem-se insatisfatórios. Os autores confirmam que os modelos de linguagem podem, através da escala, realizar aprendizagem multitarefa (*Multitask Learning*) em *zero-shot*; contudo, importa referir que o desempenho de *zero-shot*

¹⁷ Segundo Zhao et al. (2023, p. 13), “[...] *Reddit* is a social media platform that allows users to submit links and text posts, which other users can evaluate through ‘upvotes’ or ‘downvotes’. Posts that receive a high number of upvotes are generally regarded as valuable and can be used to construct high-quality datasets. *WebText* is a notable corpus derived from highly upvoted *Reddit* links, although it is not publicly accessible [...]”

permanece significativamente inferior ao dos modelos supervisionados e que a geração de conteúdos pode refletir incorreções factuais relacionadas com a qualidade dos dados de treino (Radford et al., 2019).

Brown et al. (2020) analisam o impacto de aumento da escala do modelo, na sequência do estudo sobre *zero-shot*, considerando 175 mil milhões de parâmetros no desempenho da aprendizagem de *few-shot*. Os resultados mostram que, em várias tarefas de NLP, o GPT-3 atinge ou supera modelos afinados de referência. No caso da tradução, o modelo apresenta resultados comparáveis à NMT não supervisionada ao traduzir para inglês (romeno - inglês, francês - inglês e alemão - inglês), mas apresenta um desempenho fraco na direção de saída do inglês (inglês-romeno), explicado pela predominância de dados em inglês no treino (93%) face aos dados em outras línguas (7%). Importa salientar que o GPT-3 foi treinado sobretudo com os dados de treino provenientes do *Common Crawl*¹⁸, que é um conjunto de textos da Internet não filtrados, pelo que os resultados de tradução devem ser interpretados de forma crítica. Em contraste com estudos anteriores, os autores discutem explicitamente os impactos sociais do GPT-3, com destaque para as questões éticas, bem como os desafios computacionais associados.

Hadi et al. (2024) realizam uma revisão abrangente dos aspetos técnicos da GenAI e dos panoramas dos LLM (veja as figuras 2 e 3), incluindo os avanços mais recentes, os modelos de SOTA, a classificação de tarefas, as áreas de aplicação e os principais desafios colocados pelas ferramentas baseados em IA, bem como as suas potencialidade, limitações e tendências futuras. Os autores apresentam de forma sistemática a tecnologia dos *prompts*, abordando os *prompt engineering*, os negativos (*Negative Prompting*) e os visuais (*visual prompting*), acompanhados de exemplos práticos de aplicação. Para além disso, expõem de modo estruturado os *plugins* do GPT e diversos casos de utilização, apresentando ainda um conjunto de diretrizes para o uso

¹⁸ Segundo Rudolph et al. (2023), “A *Common Crawl* é uma organização sem fins lucrativos que procede à recolha de conteúdos da Web e disponibiliza gratuitamente os seus arquivos e conjuntos de dados ao público.”

responsável e eficaz dos LLM, como a proteção da privacidade, a mitigação do viés, a abordagem das implicações éticas e a promoção da transparência, entre outras; salientando a importância simultânea do refinamento técnico e da responsabilidade ética. Discutem igualmente as limitações e fragilidades dos LLM, tais como restrição do comprimento do contexto, a atualização e o refinamento do conhecimento, fenómenos de alucinação, falhas de raciocínio, entre outros, bem como as questões ainda em aberto, como problemas de direitos de autor, contaminação dos dados de treino com conteúdos gerados por IA. Finalmente, oferecem uma perspetiva sobre o futuro dos LLM, salientando aplicações de baixo risco com supervisão humana, o desenvolvimento de modelos de menor escala (SLMs – *Small Language Models*) e a democratização da IA.

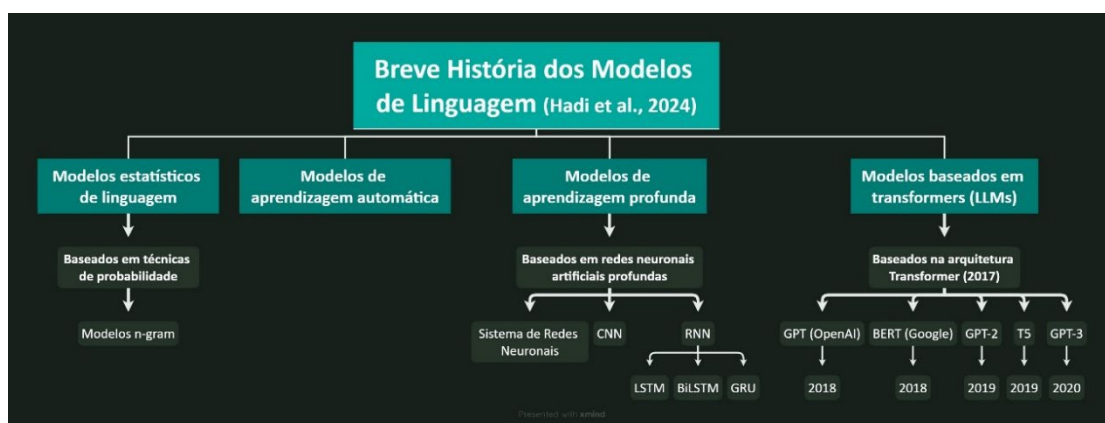


Figura 2. Breve História dos Modelos de Linguagem.
(Elaboração própria)



Figura 3. Panorama dos Modelos de Linguagem de Grande Escala (LLM).
(Elaboração própria)

2.6 Sinergia entre Tradutor Humano e IA: Modelo de Colaboração e Aplicação

Esta secção foca-se principalmente na análise do modelo de colaboração entre tradutores e a IA.

Mohd Saad et al. (2025) analisam a colaboração entre tradutores e a IA na era digital, com base no paradigma da PEMT e no modelo *Human-in-the-Loop (HITL)*. Este modelo combina a vantagem da IA em termos de velocidade e escala com as capacidades insubstituíveis dos tradutores humanos, nomeadamente nuances culturais, compreensão contextual, criatividade, avaliação ética. Esta realidade transforma o papel dos tradutores, que deixa de ser apenas um linguista para assumir funções como um validador de qualidade, editor e consultor cultural. Os autores sublinham a importância de os tradutores desenvolverem competências tecnológicas avançadas, como domínio de ferramentas de tradução assistida por computadores (CAT) e sistemas de gestão da tradução (*TMS- Translation Management Systems*) e colaboração com motores de MT personalizados. Destaca-se também a necessidade de competências específicas na PE, tais como sensibilidade linguística, identificação de padrões de erro, melhoria do estilo e fluência textual, etc. O conhecimento especializado em áreas como direito, medicina, finanças ou engenharia torna-se uma vantagem competitiva relevante.

Kwok et al. (2025) analisam os efeitos da PE com recurso ao GPT no fenómeno da simplificação de tradução, com base na hipótese da simplificação, segundo a qual os textos traduzidos tendem a mais simples do que os textos de partida (TP). O estudo recorre à análise quantitativa, centrada em duas dimensões principais, lexical e sintática, avaliando traduções produzidas por estudantes da Universidade de Hong Kong antes e depois da intervenção com o GPT. Os resultados mostram que a pós-edição aumentou significativamente a densidade, diversidade e sofisticação lexical, mitigando a tendência para a simplificação. Ao nível de complexidade sintática, observou-se uma maior formalização e normalização, embora persistam controvérsias. A análise qualitativa demonstra que os textos pós-editados pelo GPT apresentam vantagens, como maior clareza estrutural, formalidade e concisão. No entanto, identificam-se limitações, nomeadamente a uniformização estilística e a inadequação a certos géneros

específicos, como textos literários. O estudo fornece contributos relevantes para a integração da GenAI no ensino da tradução.

Castaldo et al. (2025) exploram a viabilidade da PE de traduções produzidas por LLM em textos literários, e analisam o tempo necessário, a qualidade e o nível de criatividade dessas traduções, através da comparação do desempenho do GPT-4, do GPT-3.5 e de um modelo Mistral-7¹⁹ adaptado para literatura. Os autores selecionam excertos do romance *Oryx and Crake*²⁰, traduzidos do inglês para o italiano, e colaboram com quatro tradutores profissionais especializados em tradução literária e editorial para traduzir e pós-editar os excertos respetivos. O estudo contém tradutores literários reais, textos literários complexos, comparações entre diferentes LLM e ferramentas especializadas desenvolvidas internamente para recolha dados de forma abrangentes. Os resultados indicam que a utilização do LLM para gerar traduções e seguida por PE, reduz significativamente o tempo de edição, e mantém também um nível da criatividade semelhante ao nível da tradução humana, com diferenças mínimas, mas com um aumento considerável da produtividade, evidenciando o potencial dos LLM para apoiar eficazmente a tradução literária em idiomas de elevados cursos.

Algaraady e Mahyoob (2025) analisam de maneira comparativa o desempenho do GPT-4o e de tradutores humanos na PEMT do inglês para o árabe, com base em textos gerados pelo *Google Translate* em diferentes domínios, avaliando as respetivas vantagens e limitações nas áreas de desporto, de negócios, de medicina e de literatura. Os resultados demonstram que os tradutores humanos superam o GPT-4o na maioria dos indicadores de qualidade (como precisão, consistência terminologia e adaptação cultural, entre outros); a PE do GPT-4o apresenta melhor desempenho em termos de

¹⁹ O Mistral-7B é um modelo de LLM, de código aberto, desenvolvido pela empresa francesa Mistral AI, com 7,3 mil milhões de parâmetros. Trata-se de um modelo leve, mas de elevado desempenho, com suporte para janelas de contexto longas (até 32 mil tokens) e adequado para gerar e compreender textos complexos. A versão do *literary-adapted* resulta de um *fine-tuning* do Mistral-7B para o tornar mais apto a lidar com tarefas literárias. Para mais informações sobre o modelo, o desempenho e os detalhes do ajuste por instruções, consulte o estudo [Mistral 7B](#). A expressão acima é citada a partir da página do [sítio](#).

²⁰ Segundo os autores, *Oryx and Crake* é um romance da autora canadiana Margaret Atwood, é selecionado pelo uso extensivo de neologismos divertidos e instigantes, imagens vívidas e linguagem ricamente detalhada, o que constitui um desafio significativo para a tradução (Castaldo et al., 2025).

eficácia; quanto à fluência, ambas demonstram equivalência; É importante referir que a PE do GPT-4o apresenta desempenho inferior na terminologia médica, em expressões culturalmente específicas (como expressões idiomáticas) e em estruturas gramaticais complexas, a utilização de *prompts* específicos pode otimizar os resultados, mas não consegue substituir totalmente a edição humana.

Num estudo semelhante, Raunak et al. (2023) investigam a utilização de LLM de última geração (SOTA), como o GPT-4 e o gpt-3.5-turbo, para pós-editar diretamente os resultados da NMT, neste caso o Microsoft Translator e as traduções fornecidas pelos diferentes sistemas NMT, com erros anotados segundo MQM (*Multidimensional Quality Metrics Framework*) (Freitag et al., 2021) em quatro pares de idiomas, através vários indicadores de avaliação. Os autores avaliam os impactos dos LLM na melhoria da tradução automática. O estudo compara os resultados de PE com e sem CoT (*Chain of Thought*) e a tradução gerada diretamente por LLM em *zero-shot*²¹. Os resultados verificam que, com CoT, as traduções pós-editadas aproximam-se mais da tradução inicial, enquanto sem CoT tendem a ficar mais próximo de tradução em *zero-shot*. A pós-edição direta com o GPT-4 melhora significativamente a qualidade do sistema WMT22, superando o desempenho do GPT-3.5-turbo. O GPT-4 apresenta uma taxa elevada de acertos na correção de *human-annotated error spans*; e um ERR (*Edit Realization Rate*) significativamente superior ao do GPT-3.5-turbo. Contudo, os autores alertam para a ocorrência de *hallucinated edits*, recomendando a utilização do GPT-4 com cautela como ferramentas de pós-edição em traduções especializadas.

Chen e Guo (2024) exploram um paradigma aplicável de colaboração entre tradutores humanos e ferramentas de tradução baseada em IA, demonstrando que o modelo homem-máquina assegura um processamento estável e de elevada qualidade em textos complexos. O estudo analisou a tradução de um livro interdisciplinar (psicologia, medicina, sociologia) do inglês para o chinês, rico em referências culturais e eventos históricos, com elevada complexidade linguística e cultural. Analisam

²¹ Segundo Raunak et al. (2023), *zero-shot* refere-se à tradução gerada por uma LLM sem necessidade de exemplos prévios.

sistematicamente a colaboração em todas as fases do processo. Na pré-tradução, recorreram a três LLM para extrair terminologias bilíngues, classificá-las por disciplina, validá-las com especialistas e criar uma memória de tradução (TM) no CAT, garantindo rigor e consistência. Durante a tradução, utilizaram GPT integrado no CAT para gerar o rascunho preliminar, seguido de avaliação automática de qualidade (QE) e classificação da IA (*superior/excellent/good/needs improvement*) no CAT. A TB (*Term Bases*) e a TM funcionam em tempo real, assegurando uniformidade terminológica e estilística, complementadas por verificação automática (QA) para detetar omissões, repetições e termos em falta. Na pós-tradução, realiza-se revisão integral (ortografia, gramática e consistência terminológica), QA final e normalização da formatação, obtendo-se a versão final pronto para entrega. Finalmente, os autores reafirmam a insubstituibilidade do tradutor humano, sublinham a importância da aprendizagem contínua e apresentam estratégias para a otimizar a colaboração.

2.7 Literacias em IA e Necessidades Educativas dos Tradutores

Mohd Saad et al. (2025) analisam as capacidades insubstituíveis dos tradutores humanos na era da IA, sobretudo a compreensão cultural, a criatividade, a avaliação ética e o pensamento crítico. Destacam também a transformação do papel profissional do tradutor, incluindo novas competências necessárias, literacia tecnológica e transformação dos modelos de prestação de serviços. Estas alterações reforçam a importância de promover a literacia em IA aliada a uma educação adaptada às exigências contemporâneas.

Tian (2024) aborda os desafios e potenciais do ensino de tradução no contexto da inteligência digital, propondo a integração de tecnologias avançadas como IA, LLM e CAT em programas de formação de tradutores. O autor aponta desafios como a qualidade e a aplicabilidade dos dados de treino, a dependência excessiva da tecnologia, os riscos para a integridade académica, a reconfiguração das interações entre docentes e estudantes, as normas éticas e a proteção da privacidade dos dados estudantis. Como resposta, sugere a construção de corpora atualizados, reforço do ensino de PE, a criação

de ambientes de ensino híbridos, a avaliação de vieses algorítmicos, a promoção do ensino inclusivo e a literacia digital dos estudantes.

Nguyen et al. (2025), através de uma revisão sistemática, analisam oito benefícios e sete desafios da integração de ferramentas de tradução baseadas em IA no ensino superior, oferecendo recomendações específicas. Ambos os estudos sugerem a necessidade de investigações longitudinais e avaliações de efeito para aferir o impacto das tecnologias na proficiência em tradução e na preparação profissional, bem como a importância de estudos empíricos sobre os efeitos da PE por IA no contexto educativo.

Zhang et al. (2025) exploram como a literacia em IA influencia a autoeficácia (ALSE – *AI learning self-efficacy*) e a ansiedade (FLCA – *Foreign language classroom anxiety*) em aulas de inglês como língua estrangeira (EFL – *English as a foreign Language*), afetando a disposição para a sua vontade de comunicação (WTC – *Willingness to Communicate*). Num estudo com 517 estudantes de licenciatura na província de Anhui, na China, que utilizaram AI para apoio em expressão oral em Inglês, os resultados indicam que a literacia em IA aumenta indiretamente a WTC ao elevar a ALSE e reduzir a FLCA, com estes fatores psicológicos (ALSE e FLCA) a funcionarem enquanto mediadores essenciais.

Xu et al. (2025) adotam uma abordagem mista (quantitativa e qualitativa) para investigar a literacia em IA na qualidade da tradução científica, através da tradução de dois textos científicos em inglês para chinês, **um texto de natureza conceitual** (CTP – *conceptual technical passage*) e outro operacional (OTP – *operational technical passage*), com opção de utilizar ferramentas online (como GenAI e NMT). Os resultados demonstram que a literacia em IA melhora significativamente a qualidade do CTP; contudo não do OTP, evidenciando que a IA complementa conhecimentos especializados, enquanto a competência bilingue continua a ser determinante. As limitações incluem pequena amostra, elevada homogeneidade. E as abordagens de

*think-aloud*²² e entrevistas pós-experiência poderão ter influenciado o comportamento dos participantes de certa forma.

Belhassen & Hamda (2025) investigam a dependência, confiança, percepções e atitudes dos 150 estudantes de tradução face ao uso de ferramentas de IA. Os resultados revelam que 90% utilizam ferramentas de IA, 66,7% dependem inteiramente delas; 70% consideram que a tradução correta, 33,3% duvidam da capacidade para tarefas complexas. A maioria confia na consistência e na eficácia destas tecnologias, mas reconhece a necessidade de supervisão humana e as suas limitações na gestão de tarefas complexas. Os autores concluem que a IA deve complementar, em vez de substituir os tradutores, destacando o modelo de colaboração homem-máquina e a importância da literacia em IA, incluindo competências em PEMT, pensamento crítico, sensibilidade cultural e consciência ética.

W. Zhang et al. (2025) investigam os cenários de utilização das GenAI na prática de tradução numa universidade sino-estrangeira, segundo a perspectiva de estudantes de tradução. Identificam os benefícios e as preocupações percebidas pelos estudantes na utilização da GenAI, defendem a consideração desta perspectiva e apresentam estratégias de suporte em dimensões pedagógicas, de governação e operacionais, enfatizando a literacia em IA. A integração da perspectiva real dos estudantes constitui uma perspectiva inovadora.

J. Zhang & Doherty (2025) distinguem NMT e tradução baseada em IA, analisando a literacia em IA de estudantes novatos com base nos quatro componentes-chave propostos por NG et al. (2021). Os resultados mostram o nível do conhecimento geral dos termos, mas compreensão limitada dos mecanismos técnicos e funcionamento real da GenAI e da NMT, interpretações erradas e informações desatualizadas. A

²² Segundo Başer & Çetİner (2023, pp. 275–276), o *think-aloud protocols* (TAPs) é uma das abordagens mais utilizadas no estudo da tradução. Trata-se de uma abordagem online que recolhe dados em tempo real durante o processo de tradução, é diferente das abordagens offline, que os recolhem após a conclusão do processo. As metodologias online dividem-se em duas subcategorias: observação do comportamento e dados de relato verbal online. O TAPs, enquanto subcategoria dos dados de relato verbal online, é frequentemente usado para recolher informações dos participantes durante tarefas de escrita ou tradução.

utilização da IA é de 100%, servindo para tradução, leitura, redação e comunicação, mas apenas 17,65% recorrem à PE integral. Na avaliação, a IA melhora a eficiência e a qualidade, mas há preocupações sobre deterioração das competências lógica e crítica. Quanto à consciência ética, a maioria reconhece questões de confidencialidade, de direitos de autor, de preconceitos, de responsabilidade, mas apresenta literacia ética fraca, havendo necessidade de um ensino sistemático.

2.8 Questão da Ética e Desafio em relação à IA

À semelhança do que ocorre na engenharia genética, as ferramentas de GenAI enfrentam múltiplos desafios éticos, entre os quais se destaca a questão dos dados de treino.

2.8.1 Preconceitos, transparência e privacidade de dados

Como os LLM são treinados com grandes volumes de dados disponíveis na internet, os preconceitos culturais, de género ou raciais presentes nesses dados tendem a ser reproduzidos pelos modelos (Al-Kadery & Almotiry, 2025).

Brynjolfsson (2017) salienta que os algoritmos podem herdar preconceitos raciais, de género ou sociais embutidos nos dados de treino, fenómeno igualmente observado por Mohd Saad et al. (2025, pp. 4899-4901). Li (2025, pp. 204–205) aborda o sexismo na tecnologia da IA, salientando que a incorporação de valores humanos nas bases de dados pode amplificar a discriminação de género. De forma semelhante, Krüger (2024, p. 21) discute a distorção epistémica induzida pela IA, entendida como a potencial representação distorcida da realidade resultante da reprodução de estereótipos nos dados de treino.

Com a expansão da IA, essas desigualdades manifestam-se em domínios como o recrutamento, a justiça, a avaliação de crédito e a produção de conteúdos audiovisuais, como evidenciado em casos da Google, Bing e LinkedIn, onde anúncios de emprego privilegiaram homens em detrimento de mulheres. Para além dos preconceitos decorrentes dos algoritmos e dos dados de treino (OECD, 2025, p. 19). Hadi et al. (2024, p. 30) salientam ainda o enviesamento gerado pela interação com os utilizadores, uma

vez que perguntas carregadas de preconceitos podem levar os *chatbots* a reproduzir e a reforçar essas distorções. De igual modo, esses enviesamentos estendem-se ao domínio da tradução linguística mediada por IA, contribuindo para a marginalização das línguas menos utilizadas (Al-Kadery & Almotiry, 2025, p. 2; Kimera et al., 2024b).

Além das questões de preconceito e discriminação, colocam-se também desafios técnicos significativos relacionados com a transparência e a interpretabilidade destes modelos de IA.

A natureza de “*black box*” dos LLM limita a compreensão da lógica de decisão, dificultando a identificação e a correção de preconceitos ou de outras questões éticas (Khowaja et al., 2024, p. 2543). Além disso, a complexidade estrutural resultante do recurso a redes neuronais profundas, aliada ao facto de estes modelos integrarem centenas de milhares de parâmetros (Zhao et al., 2023, p. 4), como no caso do GPT-3, com 175 mil milhões (Brown et al., 2020, p. 9; B. Chen et al., 2025, p. 4), e do GPT-2, com 1,5 mil milhões (Rudolph et al., 2023, p. 344), colocando desafios adicionais à sua interpretabilidade (Hadi et al., 2024, p. 31).

Ahmadova (2025, p. 8) afirma que os sistemas públicos de MT podem armazenar ou analisar os dados introduzidos, expondo informações sensíveis a terceiros não autorizados. Por isso, a proteção dos dados dos clientes, a utilização dos sistemas de MT seguros e de código fechado, assim como a codificação dos materiais antes do seu processamento, tornam-se particularmente relevantes. A informação aos clientes sobre utilização da MT é essencial para garantir a sua compreensão das limitações e implicações associadas.

2.8.2 Alucinações informativas e fiabilidade das respostas

A questão de alucinação é outra a que devemos dar maior atenção. Devido à natureza probabilística, os LLM geram conteúdos que parecem credíveis, mas que são factualmente incorretos (Zhao et al., 2023, p. 83). Segundo Hadi et al. (2024, p. 31), as alucinações informativas nos LLM consistem na geração de conteúdos incorretos ou enganosos, resultantes de inferências baseadas em padrões aprendidos durante o treino,

o que compromete a fiabilidade sobretudo em contextos sensíveis. Verificou-se que o ChatGPT, por vezes, gera alucinações (Zhao et al., 2023, p. 62), como a invenção de referências inexistentes (Rudolph et al., 2023, p. 356). Hadi et al. (2024, p. 24) abordam os riscos associados às ferramentas de IA para a revisão de literatura, como PDFGPT, nomeadamente a geração de citações falsas. Esta questão pode comprometer a credibilidade dos autores e dificultar a verificação de fontes. Mas os autores mencionam que ferramentas como o WebChatGPT²³ têm sido desenvolvidas para detetar e eliminar citações falsas, assegurando a integridade das referências.

B. Chen et al. (2025, p. 21) propõem uma recuperação de informação aumentada (*Retrieval augmentation*) no seu estudo para mitigar o problema de alucinação, a estratégia implica inserir no *prompt* a informação relevante proveniente de fontes externas, utilizada como conhecimento de base. Por outro lado, existem também outra estratégia, como o *Chain-of-Verification* (CoVe): o modelo realiza primeiro um raciocínio interno e, durante a autoavaliação, seguido de uma autocorreção. E os autores sugerem que a combinação com *retrieval augmentation* reforça a qualidade das respostas. De igual modo, o UNIWEB, através da utilização da Web como fonte geral de conhecimento, transforma tarefas intensivas em conhecimento num formato unificado de texto para texto. Acresce que, para evitar a geração de conteúdos tóxicos, tendenciosos ou prejudiciais, Zhao et al. (2023, pp. 6–7) referem o *alignment tuning*, que é uma técnica de *reinforcement learning with human feedback* (RLHF) que permite alinhar os LLM com valores humanos, assegurando respostas de maior qualidade e inofensivas, exemplos como o InstructGPT e o ChatGPT.

Considerando que os textos gerados por LLM dependem da correspondência de padrões (Brotsi, 2025b, p. 11; Kwok et al., 2025, p. 2), probabilidade estatística (Mohd Saad et al., 2025, pp. 4898–4899; Touretzky et al., 2019, p. 9797) e qualidade dos dados (R. Chen & Guo, 2024, p. 237), os tradutores humanos assumem um papel como guardiões éticos (Mohd Saad et al., 2025, p. 4900). Acresce que a capacidade da IA

²³ <https://www.webchatgpt.app>

para gerar conteúdos semelhantes aos humanos implica riscos de informação falsa e desinformação (Yong et al., 2024, p. 1; Zhao et al., 2023, p. 3), pelo que os tradutores devem aplicar o pensamento crítico e adotar uma postura responsável que assegure a utilização ética da tecnologia (Ng et al., 2021, p. 9).

2.8.3 Outras questões

Os problemas éticos decorrentes do uso indevido de modelos têm-se tornado cada vez mais frequentes. Como referem Al-Kadery & Almotiry (2025, p. 9), casos de manuais de produtos chineses traduzidos automaticamente para árabe resultaram em traduções incorretas e até ridículas, prejudicando a reputação das marcas e levando à retirada do produto de mercados estrangeiros.

Além disso, a utilização inadequada destas ferramentas por estudantes, nomeadamente em situações de plágio, compromete a integridade académica (Khowaja et al., 2024, p. 2544). Segundo os autores, ações de sensibilização, formação e regulação, aliadas a mecanismos técnicos de proteção e cooperação educativa, podem mitigar esses riscos e promover uma utilização responsável no contexto académico (Khowaja et al., 2024, pp. 2542–2545).

Outro risco preocupante é a manipulação intencional dos LLM para gerar conteúdos tendenciosos ou prejudiciais (Zhao et al., 2023, p. 83). Yong et al. (2024) demonstram que ataques de *jailbreak* baseados em tradução permitem contornar as medidas de segurança do GPT-4, revelando fragilidades na generalização entre línguas de alto e baixo recurso (Yong et al., 2024, pp. 1–2).

A questão dos direitos de autor constituem uma preocupação relevante: o treino dos LLM com dados protegidos levanta sérios problemas legais e éticos, uma vez que muitas fontes públicas e conteúdos pessoais são utilizados sem consentimento (Hadi et al., 2024, p. 32). Khowaja et al. (2024, pp. 2536–2537) referem que os dados utilizados no treino do ChatGPT provêm de fontes públicas e de informação pessoal, como sítios, artigos e livros, muitas vezes sem consentimento, sendo provável que comentários, avaliações de produtos e textos de blogues de utilizadores também tenham sido

incluídos, o que representa um risco de violação de privacidade e de divulgação de dados.

Por fim, a contaminação de dados de treino com conteúdo gerado por IA compromete a fiabilidade e a criatividade humana, tornando essencial o desenvolvimento de mecanismos de deteção fiáveis antes da sua utilização (Hadi et al., 2024, p. 32).

A secção seguinte será apresentada a metodologia deste trabalho, que se inspira nos métodos e resultados de estudos existente, adotando uma abordagem relativamente flexível e recorrendo a um questionário para responder a três questões de investigação.

3. Metodologia

A maioria dos estudos empíricos sobre a aplicação da IA na tradução recorrem a escalas de Likert de cinco ou seis pontos, com o intuito de avaliar as atitudes dos estudantes face às tecnologias de tradução (S. Tian et al., 2023), níveis de confiança e dependência da IA (Belhassen & Hamda, 2025) e a aplicação da IA na melhoria da PEMT (Khasawneh & Khasawneh, 2023). Esta metodologia tem sido amplamente adotada pela sua estrutura simples, fácil compreensão e eficácia na medição de conceitos abstratos (Spector, P. E., 1992, pp. 1–2). Por outro lado, alguns estudos optam por perguntas abertas, permitindo que os participantes expressem livremente as suas opiniões (J. Zhang, 2023; J. Zhang & Doherty, 2025; Al-Kadery & Almotiry, 2025; W. Zhang et al., 2025).

Com base nos resultados dos estudos empíricos existentes, o presente trabalho adota um questionário de escolha múltipla, com opções derivadas da síntese dos estudos existentes, nomeadamente dos questionários abertos utilizado por J. Zhang (2023), J. Zhang & Doherty (2025) e W. Zhang et al. (2025). Para mitigar as limitações das respostas pré-instaladas e capturar perspetivas mais personalizadas, cada pergunta inclui uma opção aberta, encorajando os participantes a expressarem-se livremente e a fornecerem contributos inesperados pela investigadora, enriquecendo assim as dimensões do trabalho. Além disso, aplicam-se igualmente as reflexões de R. Chen & Guo (2024) sobre o modelo de colaboração homem-máquina. Assim, as opções da questão 12 foram elaboradas com base nas formas específicas de utilização de ferramentas de IA na prática de tradução, visando confirmar em que fases do processo de tradução os inquiridos recorrem às ferramentas de IA.

3.1 Participantes da investigação

Para garantir a diversidade dos participantes, o estudo inclui estudantes especializados em linguísticas e em tradução, bem como tradutores profissionais, sem restrições de idade ou formação académica.

3.2 Elaboração do questionário

O questionário tem como objetivo recolher e analisar as perceções de estudantes e profissionais de tradução relativamente à IA, às experiências de utilização, às competências essenciais de literacia em IA e às necessidades de aprendizagem.

O questionário foi elaborado na plataforma *Qualtrics* em português e inglês, as duas línguas de ensino utilizadas na Universidade Nova de Lisboa – Faculdade de Ciências Sociais e Humanas (UNL – FCSH). Além disso, foi concebida também uma versão em chinês, destinada a participantes sem conhecimentos suficientes de português ou inglês, permitindo-lhes escolher a língua mais familiar.

O título do questionário foi acompanhado de uma breve apresentação da investigadora, incluindo o objetivo do estudo, as condições de armazenamento de dados, a garantia de confidencialidade, os direitos dos inquiridos e os contactos necessários.

Este questionário inclui 18 perguntas e divide-se em 3 secções:

- Secção I: recolhe o perfil dos inquiridos (6 perguntas: género, idade, formação académica, área de especialização, língua materna e línguas de trabalho);
- Secção II: utilização e familiaridade com ferramentas de tradução baseadas em IA (5 perguntas), respondendo principalmente às questões de investigação 1 e 2;
- Secção III: utilização de ferramentas de IA na prática da tradução, consciência das suas limitações e das questões éticas associadas, bem como competências de literacia em IA (7 perguntas), visando responder à questão de investigação 3.

As secções II e III do questionário incluem perguntas de escolha múltipla e perguntas abertas, assim como um formato de escala Likert de cinco pontos que variam de “não conhece” a “conhecimento profundo”. O formato de escala Likert, a fim de avaliar o nível de compreensão dos princípios fundamentais da IA. As perguntas abertas visam compreender as perspetivas dos inquiridos, no contexto da era da IA, relativamente ao papel dos tradutores humanos, às dificuldades na utilização de ferramentas de IA e às opiniões sobre a integração precoce da tecnologia no ensino da tradução.

Para evitar respostas incompletas, todas as perguntas foram definidas como obrigatórias, o que garante maior validade e eficiência na recolha de dados.

Acresce ainda que, para assegurar a validade e a usabilidade do questionário, dois estudantes de mestrado e dois estudantes de doutoramento realizaram um pré-teste das três versões. Os estudantes de mestrado forneceram feedback sobre a versão em chinês, enquanto os dois estudantes de doutoramento avaliaram as versões em português e inglês, de modo a avaliar a validade e a compreensibilidade das perguntas. Com base nos comentários recebidos, o questionário foi revisto, aperfeiçoado e finalizado para a recolha formal de dados.

Os feedbacks dos dois estudantes de mestrado:

- a. Estudante de história: a pergunta sobre o nível de compreensão dos princípios fundamentais da IA era ambígua, devido à especialização dos conceitos. Recomenda-se definir explicitamente cada nível de conhecimento com critérios objetivos, por exemplo: “não conhece”, “conhecimento limitado” e “conhecimento médio”, segundo a familiaridade e compreensão do termo;
- b. Estudante de MPLSE (Mestrado em Português como Língua Segunda e Estrangeira): devido à incerteza sobre a área de termos como *Machine Learning* ou *Deep Learning*, preencheu “conhecimento médio”. Este feedback é semelhante ao feedback do estudante de História

Segundo os feedbacks dos dois estudantes de mestrado, a investigadora adicionou uma instrução à pergunta original para orientar o preenchimento.

Os comentários de doutoramento sintetizam-se em 4 pontos:

1. Informações demográficas: apesar da recomendação de usar frases completas, continuou a ser utilizada forma original, devido à legibilidade elevada;
2. Pergunta sobre limitações da GenAI (13): a opção específica para línguas chinesas foi alterada para “Desempenho limitado em línguas de baixos recursos”, tornando a opção mais generalizável.
3. Pergunta aberta final: a área de resposta foi dividida em três secções para isolar cada pergunta e permitir respostas mais explícitas.

4. Configuração da navegação do questionário (7): a mensagem de encerramento foi personalizada em português, inglês e chinês, de acordo com a resposta do participante (“Sim” ou “Não”), garantindo consistência e melhorar experiência de leitura. Na versão em português, ao seleccionar “Não”, aparece a mensagem de encerramento pós-personaliza “Agradecemos a sua participação. A sua resposta foi registada”; ao seleccionar “Sim” e concluir todas as perguntas, surge “Agradecemos a sua participação. A sua resposta foi registada com sucesso”;

A versão em inglês e chinês seguem a mesma lógica.

3.3 Recolha de dados

O questionário foi disponibilizado online, através de links do *Qualtrics*, entre 17 e 23 de outubro de 2025, num período de sete dias, em comunidades profissionais de tradução da investigadora.

A recolha de dados decorreu principalmente através das comunidades profissionais de tradução da investigadora, grupos de estudantes de mestrado, contactos com profissionais da área e endereço de e-mail obtidos em estudos existentes. Além disso, procurou-se igualmente contactar várias empresas espanholas de tradução, como a Dixit e a STAR, entre outras, mas não se obteve resposta.

As comunidades de tradução incluíam profissionais de várias línguas e especializações. Os pares linguísticos abrangem combinações entre o chinês e o inglês, o português, o espanhol, o japonês e o coreano. As áreas de especialização dos participantes incluíam ciência da computação, localização de jogos, legendagem audiovisual, medicina clínica, gestão e engenharia química e tecnologia, entre outras.

O questionário foi também divulgado junto de estudantes de licenciatura e mestrado em Tradução da NOVA FCSH. Posteriormente, foram realizados contactos direccionados a profissionais da área, como tradutores freelancers, a tempo parcial, revisores de áudio em português, tradutores de curtas-metragens, estudantes universitários de línguas estrangeiras e doutorandos em Estudos de Tradução. Para

incentivar a participação, cada participante recebeu uma compensação simbólica de 3 yuan renminbi (menos de 0,5 euros), após a validação das respostas.

Os e-mails foram obtidos junto de autores de publicações relevantes. Na mensagem de convite, apresentei-me, expliquei o objetivo da investigação, pedi desculpa pelo incómodo eventual e salientei a importância das respostas para a validade do estudo. Obtiveram-se respostas de alguns académicos, incluindo a professora Lúcia, da Universidade Politécnica de Macau, a professora Nguyen, da University of Social Sciences & Humanities, Vietnam National University Ho Chi Minh City, e um investigador da Saudi Electronic University (Arábia Saudita). A todos os docentes e investigadores que colaboraram e demonstraram disponibilidade, expressei o meu sincero agradecimento.

A recolha dos dados terminou à meia-noite do dia 23 de outubro, com 87 respostas obtidas (53 em português, 25 em inglês e 9 em chinês). Após análise e exclusão dos questionários inválidos, a amostra final com 67 respostas válidas: 38 em português, 20 em inglês e 8 em chinês. Foram excluídos 20 questionários por respostas incompletas, demasiado simples ou incoerentes. A caracterização demográfica da amostra encontra-se na Tabela 1.

Item	Descrição	Frequência	Percentagem
Género	Feminino	50	74,63%
	Masculino	17	25,37%
Idade	18-24 anos	26	38,24%
	25-34 anos	28	41,18%
	35-44 anos	9	13,44%
	45-54 anos	3	4,41%
	55 anos ou mais	1	1,47%
Formação académica	Estudante de licenciatura	10	14,93%
	Estudante de mestrado	22	32,84%
	Estudante de doutoramento	3	4,48%
	Profissional da tradução	32	47,76%
Área de especialização	Tradução	34	50,75%
	Línguas	23	34,33%
	Educação	3	4,48%

	Outro (Ciência da Computação, Gestão, Medicina Clínica, etc)	7	10,44%
Língua materna	Chinês	49	73,13%
	Português	16	23,88%
	Outro (alemão, vietnamita)	2	2,99%
Línguas de trabalho	Inglês	31	46,27%
	Par de línguas português–inglês	17	25,37%
	Pares de línguas com o espanhol	6	8,96%
	Português	4	5,97%
	Par de línguas inglês–francês	3	4,48%
	Par de línguas inglês–alemão	2	2,99%
	Par de línguas inglês–japonês	2	2,99%
	Par de línguas inglês–italiano	1	1,49%
	Par de línguas português–francês	1	1,49%

Tabela 1. Informações demográficas (N = 67).

Fonte: Elaboração da investigadora.

A maioria dos participantes é do sexo feminino, com idades entre os 18 e os 24 anos (38,24%) e entre os 25 e os 34 anos (41,18%), com uma idade média de 28,9 anos. Predominam estudantes de mestrado (32,84%) e profissionais da tradução (29,85%), seguindo de estudantes de licenciatura (14,93%) e de doutoramento (4,48%). Mais de metade (50,75%) tem a tradução como principal área de estudo, seguida das línguas (34,33%). Quanto às línguas maternas, a maioria fala chinês (73,13%) ou português (23,88%). Além disso, há ainda falantes de alemão e vietnamita (2,99%). As línguas de trabalho (segundas línguas) mais comuns são o inglês (46,37%), o português (25,37%), o espanhol (8,96%) e outras, como o francês, o alemão, o japonês e o coreano.

4. Resultados e análise

4.1 Situação de utilização de ferramentas de IA por inquiridos

No contexto profissional (Tabela 2), todos os inquiridos utilizam ferramentas de IA na tradução, incluindo NMT, CAT com IA integrada e LLM, até há um inquirido que usa sistemas internos de investigação e desenvolvimento. A utilização da NMT (64,18%) é ligeiramente superior à das CAT com IA integrada (52,24%) e dos LLM (52,24%), possivelmente devido à sua simplicidade operacional e à maturidade da tecnologia, que não precisa de *prompts*.

Curso	NMT	CAT	LLM	Outros
Tradução	24	20	20	0
Línguas	15	11	11	0
Educação	1	1	1	0
Outro (especifique, se faz favor)	3	3	3	1
Total	43	35	35	1
Percentagem	64.18%	52.24%	52.24%	1.49%

Tabela 2. Forma de utilização de ferramentas de IA por curso.

Fonte: Elaboração da investigadora.

No que respeita à utilização do LLM, de acordo com os dados apresentados na Figura 4, o ChatGPT e o DeepSeek são o LLM mais utilizadas pelos participantes (18 menções), seguido do Doubao (13), Gemini (9) e Kimi (8). Além disso, Claude e Microsoft Copilot também apresentam frequência elevada, enquanto Perplexity e Zhipu Qingyan surgem em menor escala. Outras ferramentas, como Grok 3, AliTongyi Qianwen e Tengxun Yuanbao, registam uso reduzido, e LLaMA, Mistral Large, Ernie Bot e Falcon Arabic não foram mencionados pelos participantes neste inquérito.




Figura 4. Utilização de ferramentas de LLM.

Fonte: Elaboração da investigadora.

Segundo a tabela 3, entre os inquiridos de língua materna chinesa, o ChatGPT (33 menções), o DeepSeek (28) e o Doubao (16) revelam-se as ferramentas mais populares, seguidas pelo Kimi e pelo Gemini. Por sua vez, os inquiridos de língua materna portuguesa demonstram uma preferência mais acentuada pelo ChatGPT (9), sendo o Gemini (7) e o Perplexity (4) também relativamente apreciados. Importa salientar que o ChatGPT foi referido por todos os quatro grupos linguísticos, o que demonstra que continua a ser a ferramenta de IA predominante. Este resultado corresponde aos resultados do estudo de Belhassen & Hamda (2025).

Língua Materna	Frequência							
	ChatGPT	DeepSeek	Doubao	Gemini	Kimi	Claude	Perplexity	Copilot
Chinês	33	28	16	6	9	5	1	2
Português	9	0	–	7	–	1	4	–
Alemão	1	–	–	1	–	–	–	1
vietnamita	1	–	–	–	–	–	–	1

Tabela 3. Preferência de ferramentas de IA por grupo linguístico.

Fonte: Elaboração da investigadora.

4.2 Utilização e conhecimento de ferramentas de tradução por IA

Neste inquérito, observou-se um fenómeno interessante, i.e.: existe uma diferença significativa entre estudantes e profissionais de tradução relativa à frequência e à duração da utilização da IA (Q10). Concretamente, para o grupo de estudantes, o tempo semanal de utilização concentra-se sobretudo nas faixas “menos de 1 hora” e “1–3 horas”, e segue-se o intervalo “3–7 horas” (veja a Figura 5).

No entanto, entre os profissionais de tradução, o tempo de utilização apresenta um padrão polarizado, concentrando-se nos intervalos “1–3 horas” (7 participantes) e “mais de 15 horas” (6 participantes) (veja a Figura 5). Importa ainda salientar que, ao contrário dos estudantes, nenhum profissional indicou utilizar a IA “menos de 1 hora por semana” (veja a Tabela 4).

A polarização observada no tempo de utilização da IA entre os profissionais de tradução pode estar relacionada ao perfil e ao contexto de atuação destes. Por um lado, alguns tradutores, sobretudo aqueles de maior idade ou com menor familiaridade tecnológica, tende a recorrer à IA de forma mais moderada, limitando o seu uso a tarefas pontuais. Por outro lado, profissionais provenientes de áreas como Ciência da Computação, Gestão ou Medicina Clínica, que estão bem representadas na amostra, podem depender mais intensamente destas ferramentas devido à complexidade técnica das tarefas e à necessidade de lidar com grandes volumes de conteúdo especializado, o que justifica o uso prolongado.

De forma geral, verifica-se que, nas faixas “até 7 horas semanais”, os estudantes apresentam frequências mais elevadas, enquanto nas faixas “superiores a 7 horas”, os profissionais de tradução revelam uma frequência e duração de utilização significativamente superiores (vejam-se a Tabela 4 e a Figura 5).

Categoria	Menos de 1 hora	1-3 horas	3-7 horas	7-10 horas	10-15 horas	Mais de 15 horas	Total
Estudantes	12	11	5	3	1	3	35
Profissional da tradução	0	7	2	5	4	6	24

Outro (especifique, se faz favor)	2	1	3	1	1	0	8
Total	14	19	10	9	6	9	67

Tabela 4. Distribuição semanal do tempo de uso da IA por diferentes grupos.

Fonte: Elaboração da investigadora.

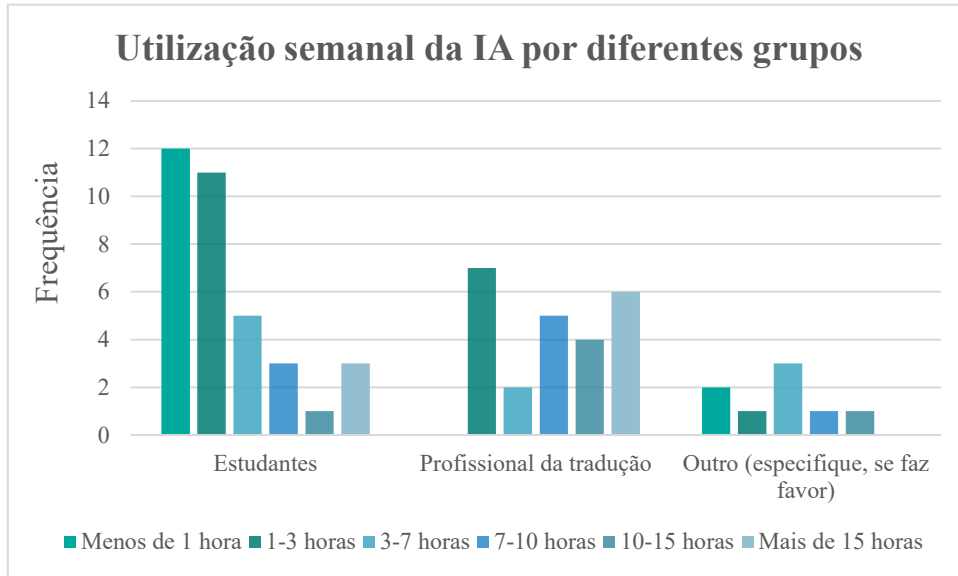


Figura 5. Utilização semanal da IA por diferentes grupos.

Fonte: Elaboração da investigadora.

Quanto ao nível de compreensão dos princípios da IA (Q11). Segundo os resultados na Tabela 5, com base numa escala de Likert de cinco pontos (em que 1 significa “não conhece” e 5 “conhecimento profundo), verifica-se uma diferença clara entre os diferentes grupos de participantes relativa ao nível de compreensão dos princípios fundamentais da IA (tais como ML, DL, RL, NLP, LLM, entre outros).

De forma geral, os profissionais da tradução apresentam médias mais elevadas do que os estudantes, o que evidencia uma melhor compreensão teórica das tecnologias de IA. Por exemplo, no caso de ML, MTPE e LLM, as médias dos profissionais são de 3,04, 3,67 e 3,17, respetivamente, enquanto as médias dos estudantes são de 2,94, 3,60 e 2,91. Por outro lado, os estudantes de tradução apresentam médias ligeiramente superiores na compreensão de corpus (3,06 face a 2,88), em comparação com os profissionais. Em contrapartida, em princípios mais complexos, como RL e NLP, as médias de três grupos ficam abaixo de 3 pontos, o que reflete que o nível de

conhecimento ainda é fraco. O grupo “Outros” apresenta médias inferiores as médias de 2,5, o que mostra um nível de conhecimento relativamente reduzido.

No geral, os profissionais da tradução demonstram um nível de literacia em IA mais elevado do que os estudantes. Contudo, a compreensão mais profunda dos princípios da IA, nomeadamente do RL, NLP e dos algoritmos, continua a necessitar de maior reforço.

Princípios	Categoria	Média	Número de participantes com conhecimento
ML	Estudantes	2.94	35
	Profissional da tradução	3.04	24
	Outros	2.50	8
DL	Estudantes	2.80	35
	Profissional da tradução	2.29	24
	Outros	2.38	8
RL	Estudantes	2.11	35
	Profissional da tradução	1.88	24
	Outros	1.50	8
NLP	Estudantes	2.74	35
	Profissional da tradução	2.13	24
	Outros	1.75	8
Corpus	Estudantes	3.06	35
	Profissional da tradução	2.88	24
	Outros	2.50	8
MTPE	Estudantes	3.60	35
	Profissional da tradução	3.67	24
	Outros	2.25	8
LLM	Estudantes	2.91	35
	Profissional da tradução	3.17	24
	Outros	2.38	8
Big Data	Estudantes	2.57	35
	Profissional da tradução	2.79	24
	Outros	2.88	8
Algorithm	Estudantes	2.57	35
	Profissional da tradução	2.33	24
	Outros	2.38	8

Tabela 5. Nível médio de compreensão dos princípios da IA entre grupos.

Fonte: Elaboração da investigadora.

4.3 Prática de tradução com IA: aplicação, percepções e literacia em IA

Quanto à aplicação da IA nas etapas da tradução (Q12). Segundo os dados (Tabela 6), na pré-tradução, a “Pesquisa de contexto e de informação” e a “Consulta e extração de terminologia” são as aplicações mais recorrentes (48 e 47 menções, veja-se Figura 6), revelando o papel essencial das ferramentas de IA como auxiliares eficientes na preparação de pré-tradução. Importa salientar que os profissionais da tradução recorrem frequentemente à IA para a “Análise e compreensão do texto de partida” (10 menções), o que revela uma necessidade mais profunda de apoio na interpretação de textos complexos.

Na tradução, a IA é sobretudo usada para “Geração de rascunho inicial da tradução” (39 menções) e “Fornecimento de sugestões de tradução” (38 menções), funções mais exploradas pelos estudantes do que pelos profissionais (Tabela 6).

Por fim, na pós-tradução, a “Deteção de erros linguísticos” e a “Melhoria da qualidade, fluência e legibilidade do texto” tornam-se principais aplicações (Figura 6), o que demonstra que a IA é amplamente vista como ferramenta de revisão e controlo de qualidade automatizado.

Etapa	Objetivos da utilização	Estudantes	Profissional da tradução	Outros	Total
Pré- tradução	Consulta e extração de terminologia	23	16	8	47
	Pesquisa de contexto e de informação	22	20	6	48
	Análise e compreensão do texto de partida	5	10	1	16
	Definição prévia de estilo e requisito de tradução	8	5	4	17
Tradução	Geração de rascunho inicial da tradução	18	16	5	39
	Procura de referências para expressões específicas ou estruturas fráscas	16	13	3	32
	Fornecimento de sugestões de tradução	22	12	4	38
Pós- tradução	Deteção de erros linguísticos	18	12	4	34
	Verificação da precisão e consistência terminológica	8	11	4	23
	Melhoria da qualidade, fluência e legibilidade do texto	13	16	5	34
	Outros (especifique, se faz favor):	0	0	0	0

Tabela 6. Objetivos da utilização das ferramentas de IA nas etapas da tradução.

Fonte: Elaboração da investigadora.




Figura 6. Objetivos do uso de ferramentas de IA nas etapas do processo tradutório.

Fonte: Elaboração da investigadora.

Principais limitações da IA generativa	Frequência			
	Estudantes	Profissional da tradução	Outros	Total
Compreensão limitada (dependência de correspondência de padrões, probabilidade estatística e qualidade dos dados)	19	13	4	36
Interpretação fraca de lidar com sensibilidades culturais (ex.: expressões idiomáticas, metáforas, humor, ironia, conceitos culturais específicos)	21	12	4	37
Baixa criatividade e adaptação estilística	12	9	3	24
Conhecimento desatualizado e dificuldade em integrar informação especializada	10	10	3	23
Desempenho limitado em línguas de baixos recursos	14	8	1	23
Falta de transparência, responsabilização e rastreabilidade das fontes	14	11	4	29
Preconceitos potenciais presentes no texto gerado	12	8	0	20
Risco de violação de direitos de autor e de propriedade intelectual	18	6	1	25

Potencial para gerar desinformação ou conteúdos manipulados (ex.: <i>deepseeks</i>)	20	16	4	40
Impacto negativo no desenvolvimento das competências de tradução humanas	19	9	5	33
Outras limitações (especifique, se faz favor):	2	1	0	3

Tabela 7. Principais limitações da IA generativa entre diferentes grupos.

Fonte: Elaboração da investigadora.

Relativamente à perceção das limitações da IA (Q13). Segundo os dados (a tabela 7), a limitação mais referida foi o “Potencial para gerar desinformação ou conteúdos manipulados” (40 menções), sobretudo entre estudantes (20) e profissionais da tradução (16). Este resultado indica que ambos os grupos revelam uma maior sensibilidade aos riscos associados à veracidade e à ética no uso da GenAI. Para complementar a análise quantitativa, alguns comentários adicionais dos estudantes serão apresentados a seguir.

Em seguida surge “Interpretação fraca de lidar com sensibilidades culturais” (37 menções), mencionada com especial destaque pelos estudantes (21), o que demonstra uma preocupação mais elevada quanto à capacidade da IA para compreender adequadamente os contextos linguísticos e culturais.

Para além destas duas limitações, os estudantes também manifestam preocupação com a “Compreensão limitada” e com o “Impacto negativo no desenvolvimento das competências de tradução humanas”, o que revela que se interessam tanto pelas limitações técnicas da IA como pelas suas implicações na evolução das competências próprias.

Entre os profissionais, as principais preocupações foram igualmente o “Potencial para gerar desinformação ou conteúdos manipulados” (16), seguido da “Compreensão limitada” (13) e da “Interpretação fraca de lidar com sensibilidades culturais” (12).

Além disso, dois estudantes referiram, nas respostas adicionais, o problema das “alucinações” da IA e a eliminação de alguns postos de trabalho resultante da sua integração em processo de reestruturação. São os seguintes:

“A existência de alucinações (hallucinations). Ou seja, a tradução final pode, muitas vezes, conter mais conteúdo que o texto de partida pois a IA quer acrescentar/continuar o texto desnecessariamente.”

“Erradicar mão de obra de trabalho que está em risco de serem reestruturada pela IA.”

Um profissional de tradução mencionou ainda os erros e desvios de tradução provocados pela limitação do comprimento fixo do contexto. É o seguinte:

Low context length limitation & the accumulated “misled” output due to it.

上下文长度有限，导致错误翻译和理解偏差累加（翻到后面忘记前面）

Tradução da investigadora: Limitação na gestão de contextos extensos, o que resulta, por vezes, na acumulação de erros de tradução e de desvios de interpretação.

Em relação à perceção dos aspetos éticos da IA (Q14). Segundo os dados apresentados na Figura 7, verifica-se que a principal preocupação ética dos inquiridos é “Traduções incorretas ou enganosas, desonestidade académica, manipulação maliciosa” (44 menções), ocupando o primeiro lugar entre todos os potenciais problemas éticos (veja-se Figura 7), a mesma situação também manifesta na pergunta aberta (Q18). Em seguida, tanto os estudantes como os profissionais de tradução demonstram preocupação com a “Falta de privacidade e proteção de dados” (21 e 11 menções) e com a “Contaminação de dados de treino com conteúdos artificiais” (19 e 15 menções), o que revelam uma sensibilidade elevada relativamente à segurança dos dados (veja-se Figura 7). Além disso, o problema da “Alucinações e informação incorreta” também suscita uma atenção significativa por parte dos inquiridos.

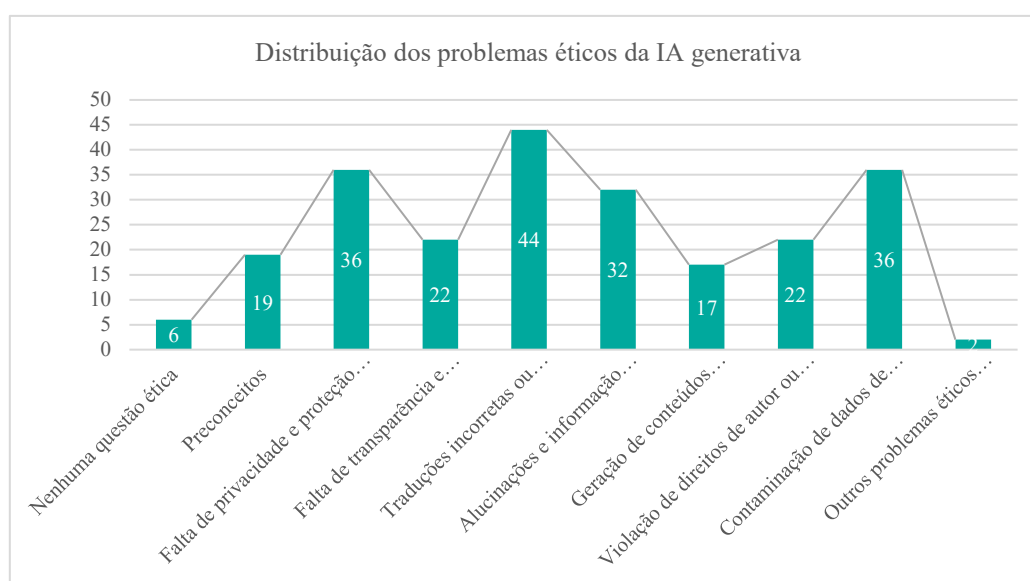


Figura 7. Distribuição dos problemas éticos da IA generativa.

Fonte: Elaboração da investigadora.

Adicionalmente, dois inquiridos manifestam preocupações com o uso inadequado da IA, que pode resultar numa dependência excessiva, bem como o impacto da sua difusão na redução das oportunidades para tradutores novatos (vejam-se Tabela 8).

Outros problemas éticos (especifique, se faz favor):	Categoria
Acredito que a falta de consciencialização do uso da IA possa gerar um uso descontrolado e até uma dependência da mesma, principalmente em ramos educativos.	Estudante de mestrado
Texto original: AI 翻译会接管相当数量的基础翻译任务，从而侵蚀行业新人的机会。 Tradução da investigadora: Reduzir as oportunidades dos tradutores novatos ao assumir certas tarefas básicas de tradução.	Profissional de tradução

Tabela 8. Outros problemas éticos adicionais.

Fonte: Elaboração da investigadora.

No que respeita à literacia necessária em IA (Q15). Conforme apresentado na Tabela 9, a “Avaliar a segurança e a sensibilidade do conteúdo a traduzir, para determinar se é adequado recorrer à IA” foi a prática mais referida (42 menções), ocupando o primeiro lugar tanto entre os estudantes (22) como entre os profissionais da tradução (18). Tal evidência demonstra um consenso geral sobre a importância de garantir a qualidade e a segurança dos conteúdos traduzidos. Em seguida, destaca-se “Informar previamente sobre o papel e o grau de intervenção da IA no processo de tradução”, com forte adesão entre os estudantes (26), superando amplamente os profissionais (10). Uma parte considerável dos inquiridos também considera que “Desde que o resultado traduzido seja rigoroso e de qualidade aceitável, não é necessário declarar explicitamente o uso de ferramentas de IA” (19).

Em síntese, na prática de tradução assistida por IA, a avaliação da segurança do conteúdo e a transparência são reconhecidas como requisitos éticos fundamentais. Contudo, os dados revelam uma dualidade quanto à obrigatoriedade dessa transparência: enquanto a comunicação prévia é valorizada por muitos, persiste uma parcela significativa de inquiridos que dispensa a declaração explícita do uso da IA, desde que o rigor terminológico e a qualidade final sejam assegurados.

Literacia em IA	Frequência			
	Estudantes	Profissional da tradução	Outros	Total
Obter autorização explícita e definir o âmbito de utilização da IA	14	9	4	27
Avaliar a segurança e a sensibilidade do conteúdo a traduzir, para determinar se é adequado recorrer à IA	22	18	2	42
Informar previamente sobre o papel e o grau de intervenção da IA no processo de tradução	26	10	5	41
Indicar claramente a contribuição da IA (ex.: em notas de rodapé ou secções explicativas)	15	6	5	26
Desde que o resultado traduzido seja rigoroso e de qualidade aceitável, não é necessário declarar explicitamente o uso de ferramentas de IA	8	10	1	19
Outras práticas (especifique, se faz favor)	1	0	0	1

Tabela 9. Literacia necessária para o uso da IA.

Fonte: Elaboração da investigadora.

Quanto às competências essenciais para tradutores na colaboração da IA (Q16). Segundo a Tabela 10, a “Compreensão intercultural e sensibilidade cultural” é a competência mais valorizada, sendo mencionada com maior frequência pelos estudantes (28) e pelos profissionais da tradução (19). Seguem-se a “Competência em pós-edição e monitorização de qualidade” e “Literacia tecnológica e competência no uso de ferramentas de IA”, o que manifesta a necessidade de combinar o uso adequado da IA com uma avaliação rigorosa dos seus resultados. Tal como salientou um dos profissionais de tradução, é essencial uma “Prática aprofundada e perceção das dinâmicas de colaboração humano e IA”.

Adicionalmente, tanto “Conhecimento específico do domínio e capacidade de localização de conteúdos” como “Aprendizagem contínua ao longo da vida” registam elevada incidência. A primeira destaca-se entre os estudantes, refletindo a importância atribuída ao domínio de áreas especializadas, enquanto a segunda é amplamente

reconhecida por ambos os grupos, revelando um consenso quanto à necessidade de aprendizagem contínua num contexto de rápida evolução tecnológica.

Competências essenciais	Frequência			
	Estudantes	Profissional da tradução	Outros	Total
Compreensão intercultural e sensibilidade cultural	28	19	7	54
Literacia tecnológica e competência no uso de ferramentas de IA (ex.: <i>prompting</i>)	24	19	3	46
Competência em pós-edição e monitorização de qualidade	26	20	5	51
Conhecimento específico do domínio e capacidade de localização de conteúdos	25	14	2	41
Perspetiva empresarial e gestão de projetos	8	10	4	22
Gestão do tempo	7	8	0	15
Aprendizagem contínua ao longo da vida	17	16	6	39
Outras competências (especifique, se faz favor)	0	1	0	1

Tabela 10. Competências essenciais na era da tradução impulsionada por IA.

Fonte: Elaboração da investigadora.

Relativamente à pergunta aberta sobre o papel dos tradutores humanos na era da IA (Q17), as respostas dos inquiridos podem ser sintetizadas em três aspetos principais: pós-edição, gestão e otimização do processo de tradução, e responsabilidade ética e profissional (Veja-se a Tabela 11).

A função mais frequentemente mencionada foi o papel essencial no processo da pós-edição, responsável pelo controlo de qualidade das saídas da IA e pelo aperfeiçoamento de aspetos que esta não domina, como a adaptação cultural, a criatividade, a expressividade emocional e o estilo literário.

Vários participantes sublinharam ainda a relevância do tradutor na gestão de projetos de tradução, em particular na integração de bases terminológicas, no desenho e aperfeiçoamento de fluxos de trabalho colaborativos e na formulação de prompts que orientem a IA para resultados adequados.

Por fim, enquanto garante último da ética e da responsabilidade profissional, o tradutor humano continua a desempenhar um papel essencial na verificação da precisão, adequação cultural e confidencialidade dos textos traduzidos.

Categoria	Respostas representativas
Controlo de qualidade, refinamento e especialização (pós-edição)	<ul style="list-style-type: none"> ● “Mediadores culturais, revisores, agentes de localização, especialistas linguísticos.” ● “[...] pois o humano terá sempre mais contexto do mundo real, o que se refletirá na tradução de questões culturais ou com mais nuances que possam surgir.” ● “[...] áreas sensíveis da tradução técnica, tais como a legal, medicina, farmacologia, etc.; e na tradução literária, em geral, e na de poesia, em particular, creio ainda ser imprescindível a ação humana.”
Gestão de processo e otimização de fluxos de trabalho	<ul style="list-style-type: none"> ● “Gestor de projeto, com sensibilidade cultural e conhecimento especializado [...]” ● “Baseado em ferramentas de geração de IA, dê prompts claros e treine a IA [...]” ● “O tradutor humano também assume um papel de mediação entre a tecnologia e o utilizador: treina sistemas de tradução, constrói bases terminológicas e garante a ética e a confidencialidade dos conteúdos. [...]” ● “project leader: framing, monitoring, decision-making, judging” ● “For Professional da traduções, [...], especially the prompt literacy required for human-machine collaborative translation.”
Garantias éticas, supervisão estratégica e responsabilidade final	<ul style="list-style-type: none"> ● “[...] controlo da qualidade de tradução e pela comunicação ativa com todas as partes (agentes) no projeto de tradução.” ● “[...] garante a ética e a confidencialidade dos conteúdos. ● “[...] 现在更突出的责任是递交最终结果并对其负责” Tradução pela investigadora: [...], mas atualmente a sua principal responsabilidade consiste em entregar o resultado final e assumir a sua responsabilidade.” ● “[...] and ensuring the quality, cultural appropriateness, and ethical integrity of translations. [.]”

Tabela 11. Papel dos Tradutores Humanos na Era da IA.

Fonte: Elaboração da investigadora.

Quanto às dificuldades dos inquiridos na utilização de IA, podem ser sintetizadas em quatro aspetos principais (Q18), incerteza do nível cognitivo, limitação ao nível das competências operacionais, desafios de avaliação e criatividade, e preocupações de ordem ética, securitária e profissional.

No nível cognitivo, alguns participantes manifestam dúvidas quanto aos limites das capacidades da IA, salientando a imaturidade de determinados corpora e a dificuldade da tecnologia em captar intenções comunicativas em línguas menos difundidas, como o par chinês-português. Alguns exemplos de respostas representativas são os seguintes:

Falta de criatividade; A IA apresenta limitações na compreensão;
IA não compreende totalmente que efeito eu quero;
Em comparação com os corpora destinados à tradução chinês-inglês e chinês-espanhol, os recursos relacionados com a tradução chinês-português são relativamente menos desenvolvidos e menos maduros;
A IA ainda não é suficientemente avançada, por isso, não consegue integrar-se de forma profunda nos fluxos de trabalho;

Relativamente às competências operacionais, foi referida a dificuldade em elaborar *prompts* eficazes e a instabilidade das respostas geradas pela IA, bem como restrições geográficas em certos modelos e atrasos de sistema. Como os seguintes:

Elaboração de prompts eficazes; Não saber escrever prompts com requisito exato
A IA por vezes é inconsistente nos resultados, mesmo após prompting rigoroso, pelo que precisa de lembretes e correções constantes
vpn para chatgpt; preço e limitação de uso; Delayed system

No domínio da avaliação e da criatividade, destacaram-se problemas de verificação da veracidade e da fiabilidade dos conteúdos gerados, limitações na compreensão cultural e receios de dependência excessiva da IA, com impacto negativo no pensamento crítico e na expressão criativa. Como os seguintes:

Certos termos e definições não parecem corretos e não apresenta fontes para se poder confirmar
Determinar se a fonte de informação é fidedigna e se as sugestões eram viáveis.
Algumas respostas são difíceis de examinar e não garantem a verdade
AI cannot have a deep understanding of contents with culture.
In AI-generated content, there is too much information that seems correct but is actually wrong.
Students abuse AI translation and can't work independently and creatively.

Por fim, os inquiridos expressaram preocupações éticas, seguranças e profissionais, nomeadamente quanto à privacidade dos dados, à falta de transparência e à dificuldade em verificar a veracidade dos conteúdos gerados. Manifestam receio de

que conteúdos falsos (ou seja, alucinações da IA), bem como receios relativos à substituição do tradutor humano no futuro. Como os seguintes:

<p>Questões éticas e de segurança de dados. Informações falsas; Informação errada; A credibilidade da IA Transparência da informação; despesa de subscrição; verificação das expressões menos naturais Sometimes, it's difficult to spot the hallucinations in AI outputs. I am worrying it will replace me in the future</p>

Quanto à questão sobre a integração precoce da tecnologia de IA no ensino da tradução (Q18), entre os 67 inquiridos, mais de metade (68,66%) considera necessária a integração precoce da IA na formação em tradução, as opiniões representativas se apresentam na Tabela 12. Cerca de um quarto (25,87%) discorda dessa opinião, sendo as respetivas opiniões apresentadas na Tabela 12. Três participantes (4,48%) manifestam posições de neutralidade, conforme ilustrado na Tabela 12.

Exemplos de respostas positivas
Sim. A IA facilita o trabalho dos tradutores [...]. Porém, nem todos os alunos são capazes de identificar as inadequações nas traduções de IA e avaliar a qualidade das traduções [...].
Sim. [...] Precisam aprender a trabalhar com as ferramentas [...]. Isso significa compreender o funcionamento dos sistemas de tradução automática, saber avaliar a sua qualidade, realizar pós-edição e utilizar bases terminológicas, memórias de tradução e outras ferramentas digitais de apoio [...].
[...] In this era of AI, translators should learn as soon as possible how to effectively manage, evaluate and correct the output of AI, turning the tool into an advantage, while strengthening their own critical thinking and cultural conversion capabilities [...].
Yes, with care and good distribution for relevant courses. AI translation tools are available and serve as supportive tools. Teachers can stop students' AI use. Thus they should be instructed from the beginning. However, they should be trained on translation theories and skills so that they know how to employ AI translation tools appropriately and effectively.
Exemplos de respostas negativas
Não. É algo fácil de aprender num nível mais avançado e é preciso ter conhecimentos base para as usar criticamente
No. Learners will become too lazy to think independently [...]. But if they do so, their ability can never reach the level of monitors of AI.
No. The core of prioritizing basic skills training in translation lies in language comprehension, logical thinking, and cultural sensitivity. Excessive reliance on technology in the early stages

<p>may undermine students' grasp of the essence of language, leading to a decline in translation quality [...].</p>
<p>Exemplos de respostas de neutralidade</p>
<p>Não é estritamente necessário, mas é importante fazer com que os estudantes se familiarizem com a ferramenta. Acho que a familiarização com a tecnologia é uma mais valia, mas deve ser feito sempre com alguma precaução [...].</p>
<p>我想教学不一定需要融合 ai 工具，但翻译、文学相关学生有必要在课堂上充分讨论学习和未来工作中 ai 工具的使用。</p> <p>学生需要知道使用 ai 工具可能造成的积极（如节省时间）和负面影响（如信息错误、路径依赖）。</p> <p>Tradução da investigadora: [...] o ensino não necessita necessariamente de integrar ferramentas de IA; contudo, é essencial que os estudantes das áreas da tradução e da literatura debatam amplamente, em aula, a utilização e o exercício dessas ferramentas no contexto dos seus estudos e do futuro profissional.</p> <p>Os estudantes devem compreender tanto os efeitos positivos (como a poupança de tempo) quanto os seus impactos negativos (como a possibilidade de erros de informação e de dependência excessiva).</p>

Tabela 12. Opinião sobre a integração precoce da IA no ensino da tradução.

Fonte: Elaboração da investigadora.

5. Discussão e conclusão

O presente trabalho utiliza um inquérito por questionário para investigar o nível de conhecimento, as experiências de utilização e as competências essenciais de literacia em IA dos estudantes e profissionais de tradução.

Os resultados mostram que os participantes de língua materna chinesa tendem a preferir o uso do ChatGPT, DeepSeek e Doubao, enquanto os participantes de língua portuguesa demonstram maior preferência pelo ChatGPT, Gemini e Perplexity. Na frequência de utilização, os profissionais utilizam a IA com maior frequência semanal (mais de 7 horas), ao passo que a maioria dos estudantes concentram o uso entre 0 e 3 horas.

Quanto ao conhecimento dos princípios básicos da IA, verificou-se que os profissionais demonstram uma melhor compreensão dos conceitos mais comuns, como ML, MTPE e LLM, enquanto a compreensão dos conceitos mais complexos, como RL e NLP, permanece limitada em ambos os grupos. Relativamente à aplicação da IA no processo de tradução, observa-se maior frequência nas fases de pré-tradução (como a pesquisa de contexto e de informação e a consulta e extração de terminologia) e de tradução (como a geração de rascunho inicial da tradução e o fornecimento de sugestões de tradução), sendo a fase de pós-tradução sobretudo dedicada ao controlo de qualidade.

Os inquiridos revelam consciência das limitações e dos riscos éticos da IA, com preocupação elevada relativamente à veracidade dos conteúdos gerados (“alucinação da IA”), seguida das limitações de compreensão decorrentes de modelos estatísticos e do impacto sobre as competências de tradução humanas, sobretudo entre os estudantes. As respostas abertas reforçam essa preocupação generalizada com a fiabilidade e a autenticidade dos conteúdos, em consonância com as conclusões de Xu et al. (2025) sobre a literacia em IA.

A maioria dos inquiridos (68,66%) manifesta uma atitude favorável sobre a integração precoce da IA na formação de tradução, justificando-a pela possibilidade de aumentar a eficiência de tradução, desenvolver o pensamento crítico, acompanhar as tendências do setor e enfrentar os desafios e riscos duais da IA. Alguns participantes,

contudo, expressam receio de que a introdução precoce da IA possa reduzir a autonomia dos tradutores humanos. Assim, considera-se necessário estruturar de forma adequada as unidades curriculares, de modo a consolidar as competências de tradução e de pós-edição, promovendo simultaneamente a capacidade crítica de avaliar os resultados gerados pela IA, como referiu um dos inquiridos, “com atenção e uma boa distribuição pelas disciplinas relevantes”.

Os resultados divergem parcialmente da hipótese inicial: os participantes revelam consciência ética e crítica face à GenAI, sendo que os profissionais demonstram maior domínio técnico e experiência e prática do que os estudantes, que ainda apresentam margem de progresso. Conclui-se que a inclusão da IA generativa (GenAI) nos programas de tradução é necessária para reduzir as desigualdades cognitivas e promover uma literacia crítica em IA.

O presente trabalho, ao analisar de forma multidimensional as perceções e práticas de diferentes grupos, oferece evidências empíricas que podem apoiar a aprendizagem dos fundamentos da IA e o reforço das competências associadas entre estudantes e profissionais de tradução. No entanto, devido às limitações do tamanho de amostra e à concentração linguística (chinês e português), recomenda-se que investigações futuras abranjam um maior número de línguas e contextos culturais, de modo a aprofundar a compreensão das diferenças na perceção e utilização da IA entre tradutores de diferentes origens linguísticas.

6. Referências

- Ahmadova, A. (2025). The Ethics of Translation: An Analytical Study of Accuracy, Cultural Sensitivity, and Technological Impact. *Global Spectrum of Research and Humanities*, 2(1), 4–11. <https://doi.org/10.69760/gsrh.01012025001>
- Algaraady, J., & Mahyoob, M. (2025). Exploring ChatGPT's potential for augmenting post-editing in machine translation across multiple domains: Challenges and opportunities. *Frontiers in Artificial Intelligence*, 8, 1526293. <https://doi.org/10.3389/frai.2025.1526293>
- Al-Kadery, S. A. K., & Almotiry, M. M. G. (2025). Artificial Intelligence and Ethical Practices: A Study in the Realm of Translation. *International Journal of Linguistics and Translation Studies*, 6(2), 1–15. <https://doi.org/10.36892/ijlts.v6i2.563>
- Artetxe, M., Labaka, G., & Agirre, E. (2018). *Unsupervised Statistical Machine Translation*. <https://doi.org/10.18653/v1/D18-1399>
- Artetxe, M., Labaka, G., & Agirre, E. (2019). *An Effective Approach to Unsupervised Machine Translation*. <https://doi.org/10.18653/v1/P19-1019>
- Bahdanau, D., Cho, K., & Bengio, Y. (2016). *Neural Machine Translation by Jointly Learning to Align and Translate* (No. arXiv:1409.0473). arXiv. <https://doi.org/10.48550/arXiv.1409.0473>
- Başer, Z., & Çetİner, C. (2023). Examining translation behaviour of Turkish student translators in scientific text translation with think-aloud protocols. *Meta*, 67(2), 274–296. <https://doi.org/10.7202/1096256ar>
- Belhassen, S., & Hamda, A. (2025). Translation Students' Reliance on and Trust in Artificial Intelligence for Successful Translation Projects: Opportunities, Challenges, and Implications. *Arab World English Journal For Translation and Literary Studies*, 9(2), 106–119. <https://doi.org/10.24093/awejtls/vol9no2.7>
- BLEU. (2025). In *Wikipedia*. <https://en.wikipedia.org/w/index.php?title=BLEU&oldid=1300846595>

- Bowker, L., & Buitrago-Ciro, J. (2019). *Machine translation and global research: Towards improved machine translation literacy in the scholarly community* (First edition). Emerald Publishing.
- Brotsi, V. (2025a). *Artificial Intelligence and Machine Translation: Post-editing of Machine*.
- Brotsi, V. (2025b). *Artificial Intelligence and Machine Translation: Post-editing of Machine* [Diploma Thesis]. Aristotle University of Thessaloniki.
- Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A., Agarwal, S., Herbert-Voss, A., Krueger, G., Henighan, T., Child, R., Ramesh, A., Ziegler, D. M., Wu, J., Winter, C., ... Amodei, D. (2020). *Language Models are Few-Shot Learners*.
- Burlot, F., & Yvon, F. (2019). *Using Monolingual Data in Neural Machine Translation: A Systematic Study* (No. arXiv:1903.11437). arXiv. <https://doi.org/10.48550/arXiv.1903.11437>
- Castaldo, A., Castilho, S., Moorkens, J., & Monti, J. (2025). *Extending CREAMT: Leveraging Large Language Models for Literary Translation Post-Editing* (No. arXiv:2504.03045). arXiv. <https://doi.org/10.48550/arXiv.2504.03045>
- Chen, B., Zhang, Z., Langrené, N., & Zhu, S. (2025). Unleashing the potential of prompt engineering for large language models. *Patterns*, 6(6), 101260. <https://doi.org/10.1016/j.patter.2025.101260>
- Chen, R., & Guo, B. (2024). Human-machine Collaborative Translation Based on Artificial Intelligence Technology. *Scientific and Social Research*, 6(12), 225–240. <https://doi.org/10.26689/ssr.v6i12.9144>
- Cheng, Y., Xu, W., He, Z., He, W., Wu, H., Sun, M., & Liu, Y. (2016). *Semi-Supervised Learning for Neural Machine Translation* (No. arXiv:1606.04596). arXiv. <https://doi.org/10.48550/arXiv.1606.04596>
- Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2019). *BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding* (No. arXiv:1810.04805). arXiv. <https://doi.org/10.48550/arXiv.1810.04805>

- Doddington, G. (2002). Automatic evaluation of machine translation quality using n-gram co-occurrence statistics. *Proceedings of the Second International Conference on Human Language Technology Research* -, 138. <https://doi.org/10.3115/1289189.1289273>
- Domhan, T., & Hieber, F. (2017). Using Target-side Monolingual Data for Neural Machine Translation through Multi-task Learning. *Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing*, 1500–1505. <https://doi.org/10.18653/v1/D17-1158>
- Ertel, W. (2025). *Introduction to Artificial Intelligence*. Springer Fachmedien Wiesbaden. <https://doi.org/10.1007/978-3-658-43102-0>
- Freitag, M., Foster, G., Grangier, D., Ratnakar, V., Tan, Q., & Macherey, W. (2021). Experts, Errors, and Context: A Large-Scale Study of Human Evaluation for Machine Translation. *Transactions of the Association for Computational Linguistics*, 9, 1460–1474. https://doi.org/10.1162/tacl_a_00437
- Gokul, A. (2023). *LLMs and AI: Understanding Its Reach and Impact*. Computer Science and Mathematics. <https://doi.org/10.20944/preprints202305.0195.v1>
- Gulcehre, C., Firat, O., Xu, K., Cho, K., Barrault, L., Lin, H.-C., Bougares, F., Schwenk, H., & Bengio, Y. (2015). *On Using Monolingual Corpora in Neural Machine Translation* (No. arXiv:1503.03535). arXiv. <https://doi.org/10.48550/arXiv.1503.03535>
- Gulcehre, C., Firat, O., Xu, K., Cho, K., & Bengio, Y. (2017). On integrating a language model into neural machine translation. *Computer Speech & Language*, 45, 137–148. <https://doi.org/10.1016/j.csl.2017.01.014>
- Hadi, M. U., Tashi, Q. A., Qureshi, R., Shah, A., Muneer, A., Irfan, M., Zafar, A., Shaikh, M. B., Akhtar, N., Hassan, S. Z., Shoman, M., Wu, J., Mirjalili, S., & Shah, M. (2024). *Large Language Models: A Comprehensive Survey of its Applications, Challenges, Limitations, and Future Prospects*. Preprints. <https://doi.org/10.36227/techrxiv.23589741.v7>

- Hao, X., & Zhang, S. (2025). *Investigating the Integration of LLMs into Trainee Translators' Practice and Learning: A Questionnaire-based Study on Translator-AI Interaction*.
- He, M. (2025). AI-Driven Paradigm Shift in Translation Education and Career Trajectories: Navigating Human-Machine Synergy in the Digital Era. *Education as Change*, 29. <https://doi.org/10.25159/1947-9417/19128>
- Heath, A. (2025, August 7). *GPT-5 is being released to all ChatGPT users*. The Verge. <https://www.theverge.com/openai/748017/gpt-5-chatgpt-openai-release>
- Janiesch, C., Zschech, P., & Heinrich, K. (2021a). Machine learning and deep learning. *Electronic Markets*, 31(3), 685–695. <https://doi.org/10.1007/s12525-021-00475-2>
- Janiesch, C., Zschech, P., & Heinrich, K. (2021b). Machine learning and deep learning. *Electronic Markets*, 31(3), 685–695. <https://doi.org/10.1007/s12525-021-00475-2>
- Jean, S., Cho, K., Memisevic, R., & Bengio, Y. (2015). *On Using Very Large Target Vocabulary for Neural Machine Translation* (No. arXiv:1412.2007). arXiv. <https://doi.org/10.48550/arXiv.1412.2007>
- Kanglang, L. (2021). Artificial Intelligence (AI) and Translation Teaching: A Critical Perspective on the Transformation of Education. *INTERNATIONAL JOURNAL OF EDUCATIONAL SCIENCES*, 33(1–3). <https://doi.org/10.31901/24566322.2021/33.1-3.1159>
- Kanglang, L., & Afzaal, M. (2021). Artificial Intelligence (AI) and Translation Teaching: A Critical Perspective on the Transformation of Education. *INTERNATIONAL JOURNAL OF EDUCATIONAL SCIENCES*, 33(1–3). <https://doi.org/10.31901/24566322.2021/33.1-3.1159>
- Khalilov, M., Fonollosa, J. A. R., Zamora-Martínez, F., Castro-Bleda, M. J., & España-Boquera, S. (2008). Neural Network Language Models for Translation with Limited Data. *2008 20th IEEE International Conference on Tools with Artificial Intelligence*, 445–451. <https://doi.org/10.1109/ictai.2008.35>
- Khowaja, S. A., Khuwaja, P., Dev, K., Wang, W., & Nkenyereye, L. (2024). ChatGPT Needs SPADE (Sustainability, PrivAcy, Digital divide, and Ethics) Evaluation: A

- Review. *Cognitive Computation*, 16(5), 2528–2550.
<https://doi.org/10.1007/s12559-024-10285-1>
- Khurana, D., Koli, A., Khatter, K., & Singh, S. (2023). Natural language processing: State of the art, current trends and challenges. *Multimedia Tools and Applications*, 82(3), 3713–3744. <https://doi.org/10.1007/s11042-022-13428-4>
- Kimera, R., Kim, Y.-S., & Choi, H. (2024a). *Advancing AI with Integrity: Ethical Challenges and Solutions in Neural Machine Translation*.
<https://doi.org/10.22724/LMR.2024.22.1.171>
- Kimera, R., Kim, Y.-S., & Choi, H. (2024b). *Advancing AI with Integrity: Ethical Challenges and Solutions in Neural Machine Translation*.
<https://doi.org/10.22724/LMR.2024.22.1.171>
- Kirov, V., & Malamin, B. (2022). Are Translators Afraid of Artificial Intelligence? *Societies*, 12(2), 70. <https://doi.org/10.3390/soc12020070>
- Krüger, R. (2024). Outline of an Artificial Intelligence Literacy Framework for Translation, Interpreting and Specialised Communication. *Lublin Studies in Modern Languages and Literature*, 48(3), 11–23.
<https://doi.org/10.17951/lsmll.2024.48.3.11-23>
- Kwok, H. L., Shi, Y., Xu, H., Li, D., & Liu, K. (2025). GenAI as a translation assistant? A corpus-based study on lexical and syntactic complexity of GPT-post-edited learner translation. *System*, 130, 103618.
<https://doi.org/10.1016/j.system.2025.103618>
- Li, Y. (2025). An ethical examination of artificial intelligence. *International Theory and Practice in Humanities and Social Sciences*.
- Liu, Y., Ott, M., Goyal, N., Du, J., Joshi, M., Chen, D., Levy, O., Lewis, M., Zettlemoyer, L., & Stoyanov, V. (2019). *RoBERTa: A Robustly Optimized BERT Pretraining Approach* (No. arXiv:1907.11692). arXiv.
<https://doi.org/10.48550/arXiv.1907.11692>
- Liu, Z., Riley, P., Deutsch, D., Lui, A., Niu, M., Shah, A., & Freitag, M. (2024). *Beyond Human-Only: Evaluating Human-Machine Collaboration for Collecting High-*

- Quality Translation Data* (No. arXiv:2410.11056). arXiv.
<https://doi.org/10.48550/arXiv.2410.11056>
- Long, D., & Magerko, B. (2020). What is AI Literacy? Competencies and Design Considerations. *Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems*, 1–16. <https://doi.org/10.1145/3313831.3376727>
- Matos, M. (2024, October 8). *Prémios Nobel da Física e da Química unidos pela Inteligência Artificial | Faculdade de Ciências da Universidade de Lisboa [CIÊNCIAS]*. <https://ciencias.ulisboa.pt/pt/noticia/08-10-2024/premios-nobel-da-fisica-e-da-quimica-unidos-pela-inteligencia-artificial>
- Mohamed, Y. A., Khanan, A., Bashir, M., Mohamed, A. H. H. M., Adiel, M. A. E., & Elsadig, M. A. (2024). The Impact of Artificial Intelligence on Language Translation: A Review. *IEEE Access*, *12*, 25553–25579. <https://doi.org/10.1109/access.2024.3366802>
- Mohd Saad, M. L. I. H., Nik Hashim, N. A. K. J., & Mohmad Rouyan, N. (2025). Navigating the Convergence of Human Expertise and Artificial Intelligence in the Translation Field. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.5065151>
- Ng, D. T. K., Leung, J. K. L., Chu, S. K. W., & Qiao, M. S. (2021). Conceptualizing AI literacy: An exploratory review. *Computers and Education: Artificial Intelligence*, *2*, 100041. <https://doi.org/10.1016/j.caeai.2021.100041>
- Nguyen, T. N. N., Tran, T. T., Nguyen, N. H. A., Lam, H. P., Nguyen, H. M. S., & Tran, N. A. T. (2025). The Benefits and Challenges of AI Translation Tools in Translation Education at the Tertiary Level: A Systematic Review. *International Journal of TESOL & Education*, *5*(2), 132–148. <https://doi.org/10.54855/ijte.25527>
- Omar, L. I., & Salih, A. A. (2024). Systematic Review of English/Arabic Machine Translation Postediting: Implications for AI Application in Translation Research and Pedagogy. *Informatics*, *11*(2), 23. <https://doi.org/10.3390/informatics11020023>

- OpenAI. (n.d.). *Prompting—OpenAI API*. Retrieved September 18, 2025, from <https://platform.openai.com>
- Otter, D. W., Medina, J. R., & Kalita, J. K. (2021). A Survey of the Usages of Deep Learning for Natural Language Processing. *IEEE Transactions on Neural Networks and Learning Systems*, 32(2), 604–624. <https://doi.org/10.1109/TNNLS.2020.2979670>
- Papineni, K., Roukos, S., Ward, T., & Zhu, W.-J. (2001). BLEU: A method for automatic evaluation of machine translation. *Proceedings of the 40th Annual Meeting on Association for Computational Linguistics - ACL '02*, 311. <https://doi.org/10.3115/1073083.1073135>
- Prompt Engineering Guide*. (2024). <https://www.promptingguide.ai/zh/introduction/elements>
- Qing, L. (2022). On the Strategies of Machine Translation Post-Editing Based on Cloud Platform. *Advances in Engineering Technology Research*, 3(1), 11. <https://doi.org/10.56028/aetr.3.1.11>
- Radford, A., Narasimhan, K., Salimans, T., & Sutskever, I. (2018). *Improving Language Understanding by Generative Pre-Training*.
- Radford, A., Wu, J., Child, R., Luan, D., Amodei, D., & Sutskever, I. (2019). *Language Models are Unsupervised Multitask Learners*.
- Raunak, V., Sharaf, A., Wang, Y., Awadallah, H. H., & Menezes, A. (2023). *Leveraging GPT-4 for Automatic Translation Post-Editing* (No. arXiv:2305.14878). arXiv. <https://doi.org/10.48550/arXiv.2305.14878>
- Rudolph, J., Tan, S., & Tan, S. (2023). ChatGPT: Bullshit spewer or the end of traditional assessments in higher education? *Journal of Applied Learning & Teaching*, 6(1). <https://doi.org/10.37074/jalt.2023.6.1.9>
- Sanh, V., Debut, L., Chaumond, J., & Wolf, T. (2020). *DistilBERT, a distilled version of BERT: Smaller, faster, cheaper and lighter* (No. arXiv:1910.01108). arXiv. <https://doi.org/10.48550/arXiv.1910.01108>

- Sennrich, R., Haddow, B., & Birch, A. (2016). *Improving Neural Machine Translation Models with Monolingual Data* (No. arXiv:1511.06709). arXiv. <https://doi.org/10.48550/arXiv.1511.06709>
- Sharma, S., Diwakar, M., Singh, P., Singh, V., Kadry, S., & Kim, J. (2023). Machine Translation Systems Based on Classical-Statistical-Deep-Learning Approaches. *Electronics, 12*(7), 1716. <https://doi.org/10.3390/electronics12071716>
- Tan, Z., Wang, S., Yang, Z., Chen, G., Huang, X., Sun, M., & Liu, Y. (2020). Neural machine translation: A review of methods, resources, and tools. *AI Open, 1*, 5–21. <https://doi.org/10.1016/j.aiopen.2020.11.001>
- Taye, M. M. (2023a). Understanding of Machine Learning with Deep Learning: Architectures, Workflow, Applications and Future Directions. *Computers, 12*(5), 91. <https://doi.org/10.3390/computers12050091>
- Taye, M. M. (2023b). Understanding of Machine Learning with Deep Learning: Architectures, Workflow, Applications and Future Directions. *Computers, 12*(5), 91. <https://doi.org/10.3390/computers12050091>
- Teixeira, J. de F. (1990). *O QUE É INTELIGÊNCIA ARTIFICIAL*.
- Tian, S., Jia, L., & Zhang, Z. (2023). Investigating students' attitudes towards translation technology: The status quo and structural relations with translation mindsets and future work self. *Frontiers in Psychology, 14*, 1122612. <https://doi.org/10.3389/fpsyg.2023.1122612>
- Tian, X. (2024). Personalized translator training in the era of digital intelligence: Opportunities, challenges, and prospects. *Heliyon, 10*(20), e39354. <https://doi.org/10.1016/j.heliyon.2024.e39354>
- Touretzky, D., Gardner-McCune, C., Martin, F., & Seehorn, D. (2019). Envisioning AI for K-12: What Should Every Child Know about AI? *Proceedings of the AAAI Conference on Artificial Intelligence, 33*(01), 9795–9799. <https://doi.org/10.1609/aaai.v33i01.33019795>
- Wang, A., Singh, A., Michael, J., Hill, F., Levy, O., & Bowman, S. R. (2019). *GLUE: A Multi-Task Benchmark and Analysis Platform for Natural Language*

- Understanding* (No. arXiv:1804.07461). arXiv.
<https://doi.org/10.48550/arXiv.1804.07461>
- Xu, K., Tang, W., Tian, Z., Luan, Q., & Shi, L. (2025). Investigating the Effect of AI Literacy on the Quality of Technical Translation. *Linguistics*, 150–164.
<https://doi.org/10.35534/lin.0702015>
- Yong, Z.-X., Menghini, C., & Bach, S. H. (2024). *Low-Resource Languages Jailbreak GPT-4* (No. arXiv:2310.02446). arXiv.
<https://doi.org/10.48550/arXiv.2310.02446>
- Zhang, J. (2023). *Exploring undergraduate translation students' perceptions towards machine translation: A qualitative questionnaire survey*. 1–10.
- Zhang, J., & Doherty, S. (2025). Investigating novice translation students' AI literacy in translation education. *The Interpreter and Translator Trainer*, 1–20.
<https://doi.org/10.1080/1750399X.2025.2541478>
- Zhang, J., Zhao, X., & Doherty, S. (2025). *Prompt engineering in translation: How do student translators leverage GenAI tools for translation tasks*. 420–431.
- Zhang, Q., Nie, H., Fan, J., & Liu, H. (2025). Exploring the Dynamics of Artificial Intelligence Literacy on English as a Foreign Language Learners' Willingness to Communicate: The Critical Mediating Roles of Artificial Intelligence Learning Self-Efficacy and Classroom Anxiety. *Behavioral Sciences*, 15(4), 523.
<https://doi.org/10.3390/bs15040523>
- Zhang, W., Li, A. W., & Wu, C. (2025). University students' perceptions of using generative AI in translation practices. *Instructional Science*, 53(4), 633–655.
<https://doi.org/10.1007/s11251-025-09705-y>
- Zhao, W. X., Zhou, K., Li, J., Tang, T., Wang, X., Hou, Y., Min, Y., Zhang, B., Zhang, J., Dong, Z., Du, Y., Yang, C., Chen, Y., Chen, Z., Jiang, J., Ren, R., Li, Y., Tang, X., Liu, Z., ... Wen, J.-R. (2023). *A Survey of Large Language Models* (Version 16). arXiv. <https://doi.org/10.48550/ARXIV.2303.18223>

Zhou, L., Zhang, J., & Zong, C. (2019). Synchronous Bidirectional Neural Machine Translation. *Transactions of the Association for Computational Linguistics*, 7, 91–105. https://doi.org/10.1162/tacl_a_00256

Os dados originais do inquérito poderão ser disponibilizados a investigadores mediante pedido.

Apêndice A - Questionário em Português

Título: Inteligência Artificial Para Tradutores: Proposta de

Conteúdo Essencial

Olá! Sou mestrado em Tradução em Universidade Nova de Lisboa — Faculdade de Ciências Sociais e Humanas (UNL-FCSH). Muito obrigada pela participação nesta investigação.

Objetivo:

Este inquérito pretende recolher e conhecer as perceções de estudantes e profissionais de tradução relativamente à inteligência artificial (IA), às suas experiências de utilização, às competências essenciais de literacia em IA e às respetivas necessidades de aprendizagem. Para facilitar o preenchimento, o questionário está disponível em três línguas: Português, Inglês e Chinês. Os participantes podem responder na língua com a qual se sintam mais familiarizadas.

O questionário está organizado em três secções: a primeira secção recolhe o perfil dos participantes; a segunda incide sobre o uso e a compreensão de ferramentas de tradução baseadas em IA; a terceira centra-se na avaliação integrada da utilização de ferramentas de tradução baseada em IA, da perceção dos participantes relativamente a essas ferramentas e da literacia em IA.

Armazenamento de dados

Os resultados deste inquérito serão utilizados exclusivamente para fins académicos. Todos os dados recolhidos serão armazenados de forma segura numa unidade externa encriptada e protegida por palavra-passe, pertencente à investigadora. Esta unidade nunca será ligada à Internet nem a quaisquer outras redes de comunicação. Portanto, pode preencher o questionário com total confiança.

Confidencialidade e direitos dos participantes

A participação neste inquérito é inteiramente voluntária. A confidencialidade será assegurada em todas as fases do processo. A preservação do anonimato estará garantida e os direitos dos participantes à privacidade e à desistência do inquérito serão plenamente respeitados. No entanto, não será possível retirar as respostas depois do envio, por serem anónimas, também não poderão ser associadas a participantes individuais.

Contactos

Não existem respostas certas ou erradas, e o preenchimento deste questionário demorará aproximadamente 12 a 15 minutos. Caso tenha alguma questão relacionada com o inquérito ou pretenda obter informações adicionais sobre os resultados, poderá

contactar a investigadora através do endereço do e-mail a2022106454@campus.fcsh.unl.pt, ou contactar o Encarregado de Proteção de Dados da Universidade NOVA de Lisboa através do endereço dpo@unl.pt.

Se concordar em participar, por favor clique em

“Li e compreendi as informações acima fornecidas e concordo, voluntariamente, em participar neste inquérito.”

Secção I: Informações demográficas

(1) Género

- Feminino
- Masculino

(2) Idade

- Menos de 18 anos
- 18-24 anos
- 25-34 anos
- 35-44 anos
- 45-54 anos
- 55 anos ou mais

(3) É atualmente

- Estudante de licenciatura
- Estudante de mestrado
- Estudante de doutoramento
- Profissional da tradução
- Outro (especifique, se faz favor)

(4) Qual é o curso que frequenta?

- Tradução
- Línguas
- Educação
- Outro (especifique, se faz favor)

(5) Indique a (s) sua (s) língua (s) materna (s)? (Assinale todas as opções que se aplicam)

- Português
- Espanhol
- Inglês
- Francês
- Chinês
- Italiano

- Outra (especifique, se faz favor)

(6) Indique a (s) sua (s) segunda (s) língua (s) estrangeira (s) ou língua (s) de trabalho? (Assinale todas as opções que se aplicam)

- Português

- Espanhol

- Inglês

- Francês

- Chinês

- Italiano

- Outra (especifique, se faz favor)

Secção II: Uso e familiaridade com ferramentas de tradução baseadas em IA

(7) Utiliza ferramentas de IA (por exemplo, DeepL, ChatGPT, Claude, DeepSeek, Perplexity) para tradução no seu estudo ou trabalho diário?

Sim

Não

Navegação: Agradecemos a sua participação. A sua resposta foi registada.

(8) Quais das seguintes ferramentas ou tecnologias de IA já utilizou no seu trabalho de tradução? (Assinale todas as opções que se aplicam)

A. Ferramentas gerais de tradução automática (NMT) (Google Translator, DeepL, Microsoft Translator, Bing Translate)

B. Ferramentas de tradução assistida por computador (CAT) com funcionalidade de IA integradas (ex.: SDL Trados Studio, funcionalidades de tradução por IA do memoQ, YiCAT)

C. Modelos de linguagem de grande escala (LLM) (ex.: ChatGPT, Gemini, Claude, DeepSeek, Doubao)

D. Outras (especifique, se faz favor)

(9) Quais são os modelos de linguagem de grande escala (LLM) que utiliza com mais frequência? (Assinale todas as opções que se aplicam)

A. ChatGPT

B. Gemini

C. Grok 3

D. Microsoft Copilot

E. LLaMA

F. Claude

G. Perplexity

H. Mistral Large

I. Deepseek

J. AliTongyi Qianwen

- K. Zhipu Qingyan
- L. DouBao
- M. Tengxun Yuanbao
- N. Kimi
- O. Ernie Bot
- P. Falcon Arabic
- Q. Outro (especifique, se faz favor)

(10) Em média, quantas horas por semana utiliza ferramentas de inteligência artificial (por exemplo, ChatGPT, DeepL, Grammarly) para fins de estudo ou trabalho?

(Pergunta de escolha única)

- A. Menos de 1 hora ($L \leq 1$ h)
- B. 1–3 horas ($1h < L \leq 3$ h)
- C. 3–7 horas ($3h < L \leq 7$ h)
- D. 7–10 horas ($7h < L \leq 10$ h)
- E. 10–15 horas ($10\text{ h} < L \leq 15$ h)
- F. Mais de 15 hours ($L > 15$ h)

(Q. Zhang et al., 2025, p. 6)

Princípios fundamentais da IA:

(11) Qual é o seu nível de compreensão dos seguintes conceitos?

(Para cada item, assinale: Não conhece/Conhecimento limitado/Conhecimento médio/Conhecimento avançado/Conhecimento profundo)

Instruções:

- Não conhece: Não conhece o conceito ou não faz ideia do que significa.
- Conhecimento limitado: Reconhece o nome ou apenas uma noção muito vaga, mas não o consegue explicar.
- Conhecimento médio: Conhecimento básico e superficial, mas sem profundidade nem detalhe.
- Conhecimento avançado: compreende bem o conceito e consegue explicá-lo ou discuti-lo.
- Conhecimento profundo: tem uma compreensão profunda e completa, possivelmente com conhecimento relevante ou experiência prática.

-Aprendizagem automática (ML – Machine Learning)

Não conhece/Conhecimento limitado/Conhecimento médio/Conhecimento avançado/Conhecimento profundo

-Aprendizagem profunda (DL – Deep Learning)

Não conhece/Conhecimento limitado/Conhecimento médio/Conhecimento avançado/Conhecimento profundo

-Aprendizagem por esforço (RL – Reinforcement Learning)

Não conhece/Conhecimento limitado/Conhecimento médio/Conhecimento avançado/Conhecimento profundo

-Processamento de linguagem natural (NLP – Natural Language Processing)

Não conhece/Conhecimento limitado/Conhecimento médio/Conhecimento avançado/Conhecimento profundo

-Corpus

Não conhece/Conhecimento limitado/Conhecimento médio/Conhecimento avançado/Conhecimento profundo

-Tradução automática e pós-edição (MTPE – Machine Translation and Post-editing)

Não conhece/Conhecimento limitado/Conhecimento médio/Conhecimento avançado/Conhecimento profundo

- Modelos de linguagem de grande escala (LLM – Large Language Models)

Não conhece/Conhecimento limitado/Conhecimento médio/Conhecimento avançado/Conhecimento profundo

-Big Data

Não conhece/Conhecimento limitado/Conhecimento médio/Conhecimento avançado/Conhecimento profundo

- Algoritmos (Algorithm)

Não conhece/Conhecimento limitado/Conhecimento médio/Conhecimento avançado/Conhecimento profundo

Secção III: Prática de tradução com IA: avaliação da aplicação, percepções e literacia em IA

Esta secção tem como objetivo compreender a utilização de ferramentas de IA na prática de tradução, o grau de consciência que estudantes e profissionais de tradução têm relativamente às limitações e questões éticas associadas à IA, bem como as competências essenciais de literacia em IA (todas as perguntas são de resposta múltipla).

(12) Quais são os objetivos da utilização de tecnologia de IA na sua prática de tradução? (Assinale todas as opções aplicáveis)

- A. Consulta e extração de terminologia
- B. Pesquisa de contexto e de informação
- C. Análise e compreensão do texto de partida
- D. Definição prévia de estilo e requisito de tradução
- E. Geração de rascunho inicial da tradução
- F. Procura de referências para expressões específicas ou estruturas fráscas
- G. Fornecimento de sugestões de tradução
- H. Detecção de erros linguísticos (por exemplo, ortografia e gramática)
- I. Verificação da precisão e consistência terminológica
- J. Melhoria da qualidade, fluência e legibilidade do texto
- K. Outros (especifique, se faz favor): _____

(13) Na sua opinião, quais são as principais limitações da IA generativa? (Assinale todas as opções aplicáveis)

- A. Compreensão limitada (dependência de correspondência de padrões, probabilidade estatística e qualidade dos dados)
- B. Interpretação fraca de lidar com sensibilidades culturais (ex.: expressões idiomáticas, metáforas, humor, ironia, conceitos culturais específicos)
- C. Baixa criatividade e adaptação estilística
- D. Conhecimento desatualizado e dificuldade em integrar informação especializada
- E. Desempenho limitado em línguas de baixos recursos
- F. Falta de transparência, responsabilização e rastreabilidade das fontes
- G. Preconceitos potenciais presentes no texto gerado
- H. Risco de violação de direitos de autor e de propriedade intelectual
- I. Potencial para gerar desinformação ou conteúdos manipulados (ex.: *deepseeks*)
- J. Impacto negativo no desenvolvimento das competências de tradução humanas
- H. Outras limitações (especifique, se faz favor): _____

(14) Na sua opinião, quais são os potenciais problemas éticos associados às ferramentas de IA?

- A. Nenhuma questão ética
- B. Preconceitos
- C. Falta de privacidade e proteção de dados
- D. Falta de transparência e explicabilidade (conhecido como “black box”)
- E. Traduções incorretas ou enganosas, desonestidade académica, manipulação maliciosa
- F. Alucinações e informação incorreta
- G. Geração de conteúdos prejudiciais ou tendenciosos
- H. Violação de direitos de autor ou propriedade intelectual
- I. Contaminação de dados de treino com conteúdos artificiais
- J. Outros problemas éticos (especifique, se faz favor): _____

- (15) Na utilização de IA generativa em tarefas de tradução, quais das seguintes práticas considera necessárias? (escolha múltipla)
- A. Obter autorização explícita e definir o âmbito de utilização da IA
 - B. Avaliar a segurança e a sensibilidade do conteúdo a traduzir, para determinar se é adequado recorrer à IA
 - C. Informar previamente sobre o papel e o grau de intervenção da IA no processo de tradução
 - D. Indicar claramente a contribuição da IA (ex.: em notas de rodapé ou secções explicativas)
 - E. Desde que o resultado traduzido seja rigoroso e de qualidade aceitável, não é necessário declarar explicitamente o uso de ferramentas de IA
 - F. Outras práticas (especifique, se faz favor): _____

- (16) Em sua opinião, na era da tradução impulsionada por IA, quais são as competências mais importantes para que os tradutores trabalhem eficazmente com a IA e mantenham a sua competitividade?
- A. Compreensão intercultural e sensibilidade cultural
 - B. Literacia tecnológica e competência no uso de ferramentas de IA (ex.: *prompting*)
 - C. Competência em pós-edição e monitorização de qualidade
 - D. Conhecimento específico do domínio e capacidade de localização de conteúdos
 - E. Perspetiva empresarial e gestão de projetos
 - F. Gestão do tempo
 - G. Aprendizagem contínua ao longo da vida
 - H. Outras competências (especifique, se faz favor): _____

As seguintes duas perguntas são de resposta aberta, têm como objetivo conhecer o papel dos tradutores humanos, as dificuldades enfrentadas por estudantes ou profissionais da tradução no uso de ferramentas de IA e as perspetivas relativas à integração precoce da tecnologia de IA no ensino da tradução.

- (17) Na sua opinião, qual é o papel dos tradutores humanos na era da tradução impulsionada por IA? _____

- (18) Que dificuldade ou dúvidas já enfrentou ao utilizar ferramentas de IA? Considera que é necessário integrar a tecnologia de IA no ensino da tradução numa fase precoce? Por que razão? _____
- Agradecemos a sua participação. A sua resposta foi registada com sucesso.

Apêndice B - Questionário em inglês

Title: Artificial Intelligence for Translators: Proposal of Core

Content

Hello! I am a master's student in Translation Studies at Nova University of Lisbon, School of Social Sciences and Humanities (UNL-FCSH). Thank you for participating in this survey!

Aim

This survey aims to gather and examine translation students' and practitioners' perceptions of artificial intelligence (AI), their experiences of its use, the essential AI literacies required, and their learning needs. To facilitate participation, the questionnaire is available in three languages: Portuguese, English, and Chinese. Respondents may complete it in the language with which they are most familiar.

The questionnaire is structured into three sections: the first section gathers participants' profiles; the second section focuses on the use and understanding of AI-driven translation tools; and the third section focuses on an integrated assessment of the utilization of AI-driven translation tools, participants' perceptions of these tools, and AI literacy.

Data storage

The findings of this survey will be used exclusively for academic purposes. All data collected will be securely stored on an encrypted, password-protected external drive belong to the researcher, which will never be connected to the internet or to any other communication networks. You may therefore complete the questionnaire with full confidence.

Confidentiality and your rights

Participation in this survey is entirely voluntary. Confidentiality will be safeguarded at all times. Anonymity will be preserved, and participants' rights to privacy and withdrawal will be fully respected. However, once the responses have been submitted, it will not be possible to withdraw them, as they cannot be linked to the identity of the participant.

Contacts

There are no right or wrong answers, and completing this questionnaire will take approximately 12-15 minutes. If you have any questions regarding the survey, or if you would like further information about the results, please contact the researcher at

a2022106454@campus.fcsh.unl.pt, or contact the Data Protection Responsible of Nova University of Lisbon at dpo@unl.pt.

If you agree to participate, please click
“I have read and understood the information provided above and I voluntarily agree to take part in this survey”.

Section I: Demographic Information

1. Individual’s demographic characteristics

(1) Gender

- Female
- Male

(2) Age

- Under 18
- 18-24
- 25-34
- 35-44
- 45-54
- 55 or Above

(3) You are

- BA student
- MA student
- PhD student
- Professional translator
- Other (please specify)

(4) What course do you study?

- Translation
- Language
- Education
- Others (Please Spacy)

(5) Please specify your native language (s)?

- Portuguese
- Spanish
- English
- French
- Chinese
- Italian
- Other (please specify)

(6) Please specify your second language (s) or working language (s)?

- Portuguese
- Spanish
- English
- French
- Chinese
- Italian
- Other (please specify)

Section II: Use and familiarity with AI-driven translation tools

(7) Do you use AI tools (e.g., DeepL, ChatGPT, Claude, DeepSeek, Perplexity) for translation in your daily studies or professional work?

- Yes
- No

Navigation: Thank you very much for your participation! Your response has been recorded.

(8) Which of the following AI tools or technologies have you used in your translation work? (Select all that apply)

- A. General machine translation tools (NMT) (e.g., Google Translator, DeepL, Microsoft Translator, Bing Translate)
- B. Computer-assisted translation (CAT) tools with integrated AI functionalities (e.g., SDL Trados Studio, AI translation features in memoQ, YiCAT)
- C. Large language models (LLM) (e.g., ChatGPT, Gemini, Claude, DeepSeek, Doubao)
- D. Others (please specify)

(9) Which large language models (LLM) do you use most frequently? (Select all that apply)

- A. ChatGPT
- B. Gemini
- C. Grok 3
- D. Microsoft Copilot
- E. LLaMA
- F. Claude
- G. Perplexity
- H. Mistral Large
- I. Deepseek
- J. AliTongyi Qianwen
- K. Zhipu Qingyan
- L. DouBao

- M. Tengxun Yuanbao
- N. Kimi
- O. Ernie Bot
- P. Falcon Arabic
- Q. Other (please specify)

(10) On average, how many hours per week do you use AI tools (e.g., ChatGPT, DeepL, Grammarly) for study or work purposes?

- Less than 1 hour ($L \leq 1$ h)
- 1–3 hours ($1\text{h} < L \leq 3$ h)
- 3–7 hours ($3\text{h} < L \leq 7$ h)
- 7–10 hours ($7\text{h} < L \leq 10$ h)
- 10–15 hours ($10\text{ h} < L \leq 15$ h)
- More than 15 hours ($L > 15$ h)

(Q. Zhang et al., 2025, p. 6)

Core principles of AI

(11) How would you rate your understanding of the following related concepts? (For each item, please select: Not familiar/Slightly familiar/Moderately familiar/Quite familiar/Very familiar)

Instructions:

- Not familiar: Does not know the concept or has no idea what it means.
- Slightly familiar: Is familiar with the term or has only a very vague notion, but cannot explain it.
- Moderately familiar: Has a basic and superficial understanding, but lacks depth and detail.
- Quite familiar: Has a good understanding of the concept and is able to explain or discuss it.
- Very familiar: Has a deep and complete understanding, possibly with relevant knowledge or practical experience.

- Machine Learning

Not familiar/Slightly familiar/Moderately familiar/Quite familiar/Very familiar)

- Deep Learning

Not familiar/Slightly familiar/Moderately familiar/Quite familiar/Very familiar)

- Reinforcement Learning

Not familiar/Slightly familiar/Moderately familiar/Quite familiar/Very familiar)

- Natural Language Processing (NLP)

Not familiar/Slightly familiar/Moderately familiar/Quite familiar/Very familiar)

- Corpus

Not familiar/Slightly familiar/Moderately familiar/Quite familiar/Very familiar)

- Machine Translation and Post-editing

Not familiar/Slightly familiar/Moderately familiar/Quite familiar/Very familiar)

- Large Language Models (LLM)

Not familiar/Slightly familiar/Moderately familiar/Quite familiar/Very familiar)

- Big Data

Not familiar/Slightly familiar/Moderately familiar/Quite familiar/Very familiar)

- Algorithm

Not familiar/Slightly familiar/Moderately familiar/Quite familiar/Very familiar)

Section III: AI Translation Practice: An Assessment of usage, perceptions, and AI Literacy

(12) What are the purposes of using AI technologies in your translation practice?

(Select all that apply)

A. Terminology lookup and extraction

B. Background and information research

C. Analysis and understanding of the source text

D. Predefinition of translation style and requirements

E. Generation of an initial translation draft

F. Retrieval of references for specific expressions or syntactic structures

G. Proposing translation suggestions

H. Linguistic error detection (e.g., spelling and grammatical errors)

I. Verification of terminological accuracy and consistency

J. Improvement of translation quality, fluency, and readability

K. Other (please specify): _____

(13) From your perspective, what are the major limitations of Generative Artificial Intelligence? (Select all that apply)

A. Limited understanding (reliance on pattern matching, statistical probability, and data quality)

- B. Weak handling of cultural sensitivity (e.g., idioms, metaphors, humor, irony, culture-specific concepts)
- C. Limited creativity and stylistic adaptability
- D. Outdated knowledge and difficulty integrating specialised or up-to-date information
- E. Reduced performance in low-resource languages
- F. Lack of transparency, accountability and traceability of sources
- G. Potential biases present in AI-generated text
- H. Risk of copyright and intellectual property infringement
- I. Potential to generate misinformation or manipulated content (e.g., deepfakes)
- J. Negative impact on the development of human translation competencies
- H. Other limitations: _____

(14) In your opinion, what are the potential ethical issues associated with AI tools?
(Select all that apply)

- A. No ethical issues perceived
- B. Biases
- C. Lack of privacy and data protection
- D. Lack of transparency and explainability (known as “black box”)
- E. Incorrect or misleading translations, academic dishonesty, malicious manipulation
- F. Hallucinations and inaccurate information
- G. Generation of harmful or biased content
- H. Violation of copyright or intellectual property rights
- I. Training data contamination with artificial content
- J. Other ethical issues (please specify): _____

(15) When using Generative Artificial Intelligence for translation tasks, which of the following practices do you consider necessary? (Select all that apply)

- A. Obtaining explicit authorization and defining the scope of AI use
- B. Assessing the security and sensitivity of the translation content to determine whether it is appropriate for AI processing
- C. Informing in advance the role and extent of AI involvement in the translation workflow
- D. Clearly indicating AI contributions (e.g., in footnotes or explanatory notes)
- E. If the translation output is accurate and of acceptable quality, there is no need to explicitly disclose the use of AI tools
- F. Other practices (please specify): _____

(16) In your opinion, which skills are most essential for translators to work effectively with AI and maintain competitiveness in the AI-driven translation era? (Select all that apply)

- A. Intercultural understanding and cultural sensitivity
- B. Technological literacy and competence in AI tools (e.g., prompting)
- C. Competence in post-editing and quality monitoring

- D. Domain-specific knowledge and content localisation ability
- E. Business insight and project management
- F. Time management
- G. Lifelong learning
- H. Other competencies (please specify): _____

The following two open-ended questions aim to understand the value of human translators, the key challenges that translation students and professionals encounter when using AI tools, and gather insights on the early integration of AI into translation education.

(17) In your view, in the era of AI-driven translation, what is the role of human translators? _____

(18) What kinds of challenges or uncertainties have you encountered when using AI tools? Do you believe that AI technology should be incorporated into translation training at an early stage? Why?

Thank you very much for your participation! Your response has been successfully recorded.

Apêndice C - Questionário em Chinês

标题：译者应掌握的人工智能知识：核心内容提案

您好！我是新里斯大学翻译学硕士学生。感谢您参加本次调查。

目标：

本次调查旨在收集并了解翻译专业学生和从业者对人工智能（AI）的认知、使用体验、所需关键 AI 素养及其学习需求。为方便受访者填写，本问卷提供了葡语，英语和中文 3 种语言版本。参与者可根据个人情况选择最熟悉的语言进行填写。

问卷由三部分组成：第一部分收集参与者的基本信息；第二部分聚焦于 AI 驱动型翻译工具的使用情况与了解程度；第三部分主要聚焦在 AI 工具的应用、认知及 AI 素养综合评估。

数据储存

本研究成果仅用于学术研究目的。所有收集数据将安全存储于研究人员加密且受密码保护的外部磁盘上，且该磁盘永远不连接互联网以及其他通信网络。请放心填写。

保密性和参与者权利

参与本次调查完全基于自愿。保密性将全程受保护，匿名性将予以充分保障。受访者的隐私权及退出权，均得到充分尊重。然而所有回复均以匿名形式提交，一经提交即无法撤回，且无法追溯至具体受访者。

联系方式

本问卷没有标准答案，完成时间约为 12 至 15 分钟。若您对调查有任何疑问，或希望进一步了解研究结果，请通过电子邮件 a2022106454@campus.fcsh.unl.pt 与研究本人联系，或联系新里斯本大学数据保护专员 dpo@unl.pt。

若您同意参与，请点击下方按钮确认开始问卷：

“本人已阅读并理解上述信息，并自愿参与本次调查”。

第 I 部分：人口统计学调查

1. 基本信息

(1) 性别

- 女性
- 男性

(2) 年龄

- 18 岁以下

- 18-24 岁
- 25-34 岁
- 35-44 岁
- 45-54 岁
- 55 岁及以上

(3) 您的身份是

- 本科生
- 硕士生
- 博士生
- 翻译从业者
- 其他（请说明）

(4) 您所学的专业是

- 翻译学
- 语言学
- 教育学
- 其他（请说明）

(5) 您的母语是？（可多选）

- 葡萄牙语
- 西班牙语
- 英语
- 法语
- 中文
- 意大利语
- 其他（请说明）

(6) 您的第二外语或工作语言是？（可多选）

- 葡萄牙语
- 西班牙语
- 英语
- 法语
- 中文
- 意大利语
- 其他（请说明）

第 II 部分：AI 驱动翻译工具的使用和了解情况

(7) 您在学习或日常工作中，是否使用人工智能工具辅助翻译（例如 DeepL, ChatGPT, Claude, DeepSeek, Perplexity）吗？

是
否

导航窗格：非常感谢您的参与！您的回复已记录！

(8) 请勾选以下您使用过的人工智能（AI）工具或技术？（可多选）

- A. 通用机器翻译工具 (NMT)（例如：Google 翻译、DeepL、微软翻译, 必应翻译)
- B. 集成 AI 功能的计算机辅助翻译 (CAT) 工具（如：SDL Trados Studio、memoQ 中的 AI 翻译功能, YiCAT 平台）
- C. 大语言模型 (LLM)（如：ChatGPT、Gemini、Claude、DeepSeek、Doubao）
- D. 其他（请说明）

(9) 您最常使用哪些大型语言模型 (LLM)（可多选）？

- A. ChatGPT
- B. Gemini
- C. Grok 3
- D. Microsoft Copilot
- E. LLaMA
- F. Claude
- G. Perplexity
- H. Mistral Large
- I. Deepseek
- J. AliTongyi Qianwen 通义千问
- K. Zhipu Qingyan 质谱清言
- L. DouBao 豆包
- M. Tengxun Yuanbao 腾讯元宝
- N. Kimi
- O. Ernie Bot 百度文心一言
- P. Falcon Arabic
- Q. 其他（请说明）

(10) 您平均每周使用人工智能工具（如 DeepL、ChatGPT、Deepseek、Perplexity 等）进行学习或工作的时间是多少小时？（单选题）

- A. 少于 1 小时 ($L \leq 1$ 小时)
- B. 1–3 小时 ($1 \text{ 小时} < L \leq 3 \text{ 小时}$)
- C. 3–7 小时 ($3\text{h} < L \leq 7 \text{ h}$)
- D. 7–10 小时 ($7\text{h} < L \leq 10 \text{ h}$)
- E. 10–15 小时 ($10 \text{ h} < L \leq 15 \text{ h}$)
- F. 超过 15 小时 ($L > 15 \text{ h}$)

(11) 您对以下概念的了解程度如何？（每项请选择：完全不了解 / 了解较少 / 了解一般 / 了解较多 / 完全了解

说明：

“完全不了解”表示您从未听说过该概念，或听到过，但对其含义毫无头绪。

“了解较少”表示您听说过，有非常模糊的印象，但无法解释其具体内容。

“了解一般”表示您对该概念有基本的、表面的认识，但缺乏深度和细节。
“比较较多”表示您对该概念有良好的理解。能够解释并能与他人讨论。
“完全了解”表示您对该概念有深入、全面的理解。可能具备相关的专业知识或实践经验。

- 机器学习

完全不了解/了解较少/了解一般/了解较多/完全了解

- 深度学习

完全不了解/了解较少/了解一般/了解较多/完全了解

- 强化学习

完全不了解/了解较少/了解一般/了解较多/完全了解

- 自然语言处理（NLP）

完全不了解/了解较少/了解一般/了解较多/完全了解

- 语料库

完全不了解/了解较少/了解一般/了解较多/完全了解

- 译后编辑

完全不了解/了解较少/了解一般/了解较多/完全了解

- 大语言模型（LLM）

完全不了解/了解较少/了解一般/了解较多/完全了解

- 大数据

完全不了解/了解较少/了解一般/了解较多/完全了解

- 算法

完全不了解/了解较少/了解一般/了解较多/完全了解

第 III 部分：AI 翻译实践：应用、认知与素养综合评估

导语：本部分旨在了解 AI 工具在翻译实践中的使用情况，翻译学生和从业人员对 AI 局限及伦理问题的认知情况以及必备的 AI 素养（可多选）。

(12) 您在翻译实践中，运用 AI 技术主要用于哪些目的？（可多选）

- A. 术语查询与提取
- B. 背景和信息研究
- C. 原文分析与理解
- D. 制定翻译风格/要求
- E. 生成译文初稿
- F. 寻求特定表达或句型参考
- G. 提供翻译建议
- H. 进行语言错误检测（拼写、语法检查等）
- I. 专业术语准确性与一致性检查
- J. 提升译文质量、流畅度和可读性
- K. 其他（请说明）：_____

(13) 您认为 生成式人工智能 主要存在哪些局限？（可多选）

- A. 理解深度不足（依赖**模式匹配**、**统计概率**和**数据质量**）
- B. 文化敏感点的处理能力弱，如谚语，隐喻，幽默，反讽，文化特定概念
- C. 创造力和风格适应能力较低
- D. 知识过时，难以整合专业知识或最新知识
- E. 低资源语言表现有限
- F. 来源缺乏透明度，责任感，可追溯性
- G. 译文中可能存在的潜在偏见
- H. 侵犯版权或知识产权的风险
- I. 可能产生虚假信息或深度伪造
- J. 影响人类翻译能力
- H. 其他局限: _____

(14) 您认为，AI 工具可能存在哪些伦理问题？（可多选）

- A. 无伦理问题
- B. 偏见
- C. 缺乏隐私和数据保护
- D. 缺乏透明度和可解释性（“黑匣子”）
- E. 错译或误译、学术不诚实、恶意操纵
- F. 幻觉和错误信息
- G. 生成有害或偏颇内容
- H. 版权或知识产权侵犯
- I. 人工智能训练数据被污染的可能性
- J. 其他伦理问题（请具体说明）: _____

(15) 在使用生成式人工智能进行翻译工作时，您认为以下哪些做法是必要的？（可多选）

- A. 获取明确授权与确认 AI 工具使用范围
- B. 翻译内容安全性与敏感性评估，确认是否适合交由 AI 处理
- C. 提前告知 AI 在翻译流程中扮演的角色及作用范围
- D. 明确标注 AI 的贡献（如脚注，说明栏）
- E. 只要翻译结果准确，质量合格，无需特别说明 AI 工具使用情况
- F. 其他做法: _____

(16) 您认为，在人工智能驱动的翻译新时代，翻译人员要与 AI 有效协作并保持竞争力，**最需要具备**以下哪些重要技能？（可多选）

- A. 跨文化理解与文化敏感性
- B. 技术素养与 AI 工具应用能力（如提示工程 **prompting**）
- C. 译后编辑与质量监控能力
- D. 领域专业知识与内容本地化能力
- E. 商业洞察与项目管理能力
- F. 时间管理能力

G. 终身学习能力

H. 其他技能（请具体说明）： _____

以下是两个开放式问题，旨在了解人类译员的角色，翻译学习者或从业者使用 AI 工具的困惑，以及尽早将 AI 技术融入翻译教学的想法。

(17) 在您看来，在 AI 辅助翻译时代，人类译员角色主要体现在哪些方面？

(18) 您在使用 AI 工具过程中遇到过的困惑有哪些？你认为是否有必要尽早将 AI 技术融入翻译教学？为什么？ _____

非常感谢您的参与！您的回复已成功记录！