

Desenvolvimento de Ecossistema Web para Prática Ativa de Inglês: Refinamento Linguístico e Autodidatismo Assistidos por Inteligência Artificial

Romulo L. Bezerra¹ , Iago Medeiros¹ 

¹Universidade Federal do Pará (UFPA)

romulo.bezerra@tucurui.ufpa.br, iagomedeiros@ufpa.br

Abstract. *This paper describes the development and implementation of ChatEp, an open-source web ecosystem designed to foster self-directed learning in English language acquisition. Given the growing presence of Artificial Intelligence (AI) and the limitations of conventional tools that prioritize mechanical repetition, this proposal is grounded in Maker Culture and the Task-Based Language Teaching (TBLT) approach to provide an active experimentation environment. The platform utilizes state-of-the-art language models and efficient fine-tuning techniques (LoRA) to enable autonomous practice of listening, writing, speaking, and reading skills. The results establishes itself as an immediate calibration tool that allows students to independently manage their own learning paths.*

Resumo. *Este artigo descreve o desenvolvimento e a implementação do ChatEp, um ecossistema web open source projetado para fomentar o autodidatismo no aprendizado da língua inglesa. Diante da crescente presença da Inteligência Artificial (IA) e das limitações de ferramentas convencionais, que priorizam a repetição mecânica, esta proposta fundamenta-se na Cultura Maker e na abordagem Task-Based Language Teaching (TBLT) para oferecer um ambiente de experimentação ativa. A plataforma utiliza modelos de linguagem de última geração e técnicas de ajuste fino eficiente (LoRA) para viabilizar a prática autônoma das competências de listening, writing, speaking e reading. Os resultados consolidam-no como uma ferramenta de calibração imediata que permite ao estudante gerenciar sua própria trilha de aprendizagem de forma independente.*

1. Introdução

Em um mundo globalizado, o inglês se tornou o idioma mais influente e predominante, principalmente em meios internacionais e acadêmicos [Kalimullah and Tabassum 2025]. Mesmo com esta característica, observando o âmbito geral principalmente no Brasil, percebe-se que recentemente apenas uma ínfima fração da população brasileira é considerada fluente, de tal forma que o Brasil se enquadra no ranking mundial de proficiência em inglês como um país de “baixa proficiência” [Olajide-Owoyomi 2025].

Em paralelo a esse cenário, observa-se, nos últimos anos, uma rápida evolução das tecnologias baseadas em Inteligência Artificial (IA), impulsionadas pelo avanço do poder computacional, da disponibilidade de grandes volumes de dados e do desenvolvimento de arquiteturas modernas de aprendizado profundo [Sharma et al. 2022]. Essas tecnologias vêm sendo amplamente incorporadas em diferentes áreas, com destaque para o setor educacional com a criação de uma gama de ferramentas que auxiliam no ensino

e aprendizagem do inglês, sendo elas *chatbots*, corretores gramaticais, sistemas de reconhecimento de fala e transcrição de áudio e *feedbacks* personalizados com base em cada aluno [Kalimullah and Tabassum 2025]. Nesse contexto, surgem implementações como as *CALLs*, *Computer Assisted Language Learning*, que são aplicações que utilizam tecnologia computacional, ou inteligência artificial, para o auxílio do ensino-aprendizagem de línguas estrangeiras ou um segundo idioma.

Entretanto, apesar da ampla difusão dessas tecnologias e de seu considerável potencial pedagógico, estudos recentes apontam que várias das soluções disponíveis para o ensino da língua inglesa ainda apresentam limitações significativas [Mohd Sapuan et al. 2024]. Esse cenário é evidente mesmo em plataformas comerciais amplamente consolidadas no mercado, como o Duolingo, que prioriza o método de tradução e repetição espaçada, forçando apenas a memorização e repetição mecânica [Jawad et al. 2024], ou o ELSA Speak, cujo foco metodológico reside majoritariamente na acurácia fonética isolada. Ademais, tais sistemas proprietários operam por meio do modelo de negócio *freemium*, que consiste em oferecer um serviço parcialmente gratuito enquanto restringe as melhores funcionalidades, recursos avançados e tempo de acesso a planos de assinaturas pagos [Osipov et al. 2015].

Dessa forma, diferente das abordagens tradicionais que fragmentam habilidades e punem o erro, o ChatEp integra o processamento de linguagem natural à abordagem *TBLT* para contextualizar o aprendizado e transformar desvios linguísticos em componentes construtivos da fluência. Rompendo barreiras comerciais, o sistema adota uma arquitetura *web open source* para democratizar o acesso a tecnologias atuais. Assim, propõe-se uma plataforma de *CALL* focada nas quatro competências da língua inglesa — *listening*, *speaking*, *writing* e *reading* — que oferece transcrição de áudio, exercícios cotidianos e *feedbacks* automáticos direcionados ao progresso individual. Essa proposta converge com a filosofia *Maker* ao transformar o ambiente digital em um espaço de experimentação, autonomia e metodologias ativas de ensino [Santos et al. 2025, Pereira et al. 2025].

2. Trabalhos relacionados

O uso de ferramentas digitais no ensino de línguas estrangeiras pode ser conferido no *Task-Based Language Teaching (TBLT)*, que se apresenta como uma das principais vertentes do ensino comunicativo, na qual tarefas baseadas em situações reais constituem o núcleo do processo de aprendizagem ativa. O *TBLT* fundamenta-se no uso de linguagem significativa por meio de tarefas comunicativas com objetivos claros, permite flexibilidade na complexidade das tarefas, e reforça a autonomia do estudante ao possibilitar sua adaptação a diferentes níveis de proficiência, contribuindo para a calibração constante do aprendizado em ambientes mediados por tecnologia [Li 2021]. Todavia, apesar do reconhecimento da eficácia do *TBLT* no aprimoramento da comunicação, constata-se que uma boa parcela das implementações tecnológicas voltadas ao ensino de línguas não integram completamente seus princípios, pois elas tendem a manter o foco principalmente em exercícios pouco contextualizados e estruturais.

Mobile-Assisted Language Learning (MALL), que é uma extensão do *CALL*, estende a possibilidade de ensino ao viabilizar o acesso flexível, contínuo e personalizado de atividades assistidas por tecnologia. Estudos recentes apontam que essas ferramentas contribuem no aumento da confiança dos estudantes em relação ao idioma, motivação e

no exercício do aprendizado autônomo [Ahmad et al. 2025]. Contudo, essas ferramentas ainda apresentam limitações referentes à profundidade do *feedback* e à interação comunicativa real com falantes nativos, uma vez que os *feedbacks* são baseados em padrões pré-definidos, minando, assim, a análise contextualizada do padrão linguístico do estudante.

Estudos como os de [Coşkun and Solmaz 2024] evidenciam que, embora *Mobile-Assisted Language Learning (MALL)* tenham bastante potencial, ainda possuem limitações evidentes em suas implementações pedagógicas. Entre os principais obstáculos pode-se destacar a predominância de abordagens centradas em exercícios mecânicos e repetitivos, que pouco contribuem para o desenvolvimento da agência e autonomia do estudante. Essas limitações destacam a necessidade de soluções que combinem sólidos princípios pedagógicos com recursos avançados de inteligência artificial, superando o modelo de ferramentas isoladas para oferecer práticas comunicativas contextualizadas, *feedback* detalhado e monitoramento do progresso em um ambiente unificado. A análise conjunta desses conceitos mostra que a evolução de *CALL* para *MALL* apenas mudou o canal de acesso (computador para celular), mantendo os sistemas rígidos e estáticos. A superação dessa limitação ocorre na união em que a Inteligência Artificial (IA) serve como o motor técnico de respostas e adaptação, enquanto o *TBLT* fornece a base pedagógica para guiar essas automações. Essa integração transforma as ferramentas digitais em ambientes de teste prático e aprendizado ativo.

Conforme evidenciado por [Kalra and Sharma 2025], apesar de modelos baseados na arquitetura *Transformer* alcançarem alto desempenho em tarefas de Processamento de Linguagem Natural (PLN), seu alto custo computacional faz com que o *fine-tuning* convencional seja um desafio para uso em situações com recursos limitados. Na prática, essa exigência de *hardware* impede o uso de IA em plataformas comuns de *CALL* e *MALL*, pois computadores e celulares mais simples não conseguem rodar modelos pesados. Nesse contexto, métodos de Ajuste Fino Eficiente em Parâmetros (*PEFT*), em particular a Adaptação de Baixa Classificação (*LoRA*), provam ser opções eficientes ao reduzir consideravelmente a quantidade de parâmetros treináveis, decompondo matrizes de peso em componentes de baixa dimensão, preservando um desempenho semelhante ao ajuste completo e reduzindo o tempo e a necessidade de recursos computacionais.

Portanto, tendo isso vista, esta investigação caracteriza-se firmemente como uma pesquisa aplicada com desenvolvimento tecnológico, conduzida sob uma abordagem empírico-experimental. A metodologia foi operacionalizada por meio de um protocolo experimental rigoroso dividido em três fases sequenciais: (I) o treinamento e ajuste fino (*fine-tuning*) de modelos de linguagem via *LoRA* em ambiente computacional controlado para eficiência de parâmetros; (II) a integração de uma arquitetura cliente-servidor e de uma arquitetura de microsserviços para assegurar a escalabilidade do sistema; e (III) a validação preliminar da usabilidade técnica e pedagógica do ecossistema proposto.

3. Introdução a plataforma ChatEp

ChatEp é uma plataforma web que foi idealizada como um ecossistema de suporte ao autodidatismo, voltado a estudantes-*makers* que buscam desenvolver de forma ativa as competências do idioma e que predominantemente não possuem um parceiro ou professor para treino ou não têm condições de fazer turismo linguístico. A plataforma busca oferecer ambientes de experimentação linguística baseados na abordagem pedagógica *TBLT* e

mecanismos de *feedback* para calibração imediata por meio de modelos de IA.




Figura 1. Fluxo geral da plataforma ChatEip



Figura 2. Representação dos módulos das 4 competências agrupados

A plataforma foi desenvolvida como uma aplicação web em arquitetura cliente-servidor, composta por *frontend*, *backend*, banco de dados e um microserviço, a arquitetura e fluxo de uso do usuário pode ser visto na Figura 1. No *frontend*, utilizou-se o *Next.js* baseado em *React*, aliado a *CSS* para construir uma interface intuitiva, responsável pela interação com o usuário e envio de requisições *HTTP* assíncronas via *APIs REST* baseadas em *JSON*. Já o *backend*, implementado com *Nest.js*, baseado em *Node.js*, gerencia a lógica da aplicação, autenticação, validação e persistência dos dados, atuando como um orquestrador central que recebe os dados do cliente e os redireciona para os *endpoints* específicos do microserviço de IA. Complementarmente, há um microserviço em *Python* com *FastAPI*, dedicado ao processamento de linguagem e áudio via modelos de IA, comunicando-se com o *backend* por meio de requisições *HTTP* seguindo o padrão *Proxy*, o que garante modularidade, baixo acoplamento e organização ao sistema.

O microserviço, no que lhe concerne, é empregado diferentes modelos de inteligência artificial organizados em uma *pipeline* sequencial de processamento, dentre eles o *Flan-T5 Large*, desenvolvido pela *Google*, que foi utilizado na tarefa de análise e correção de texto, o *Whisper*, criado pela *OpenAI*, que foi empregado na tarefa de transformar fala do estudante (*speech-to-text*) gerando a entrada textualizada que alimenta a etapa subsequente da *pipeline*, e o *TinyLlama-1.1B-Chat*, concebido pela comunidade *open-source* do projeto *TinyLlama*, usado na atividade de criação de um modelo conversacional que atua como um tutor na plataforma. Todos os modelos foram adaptados por meio de *fine-tuning*, utilizando *LoRA* (*Low-Rank Adaptation*), permitindo, assim, o treinamento de versões especializadas dos modelos para realizar as diferentes tarefas específicas da aplicação, mas com um menor custo computacional em seus treinamentos.

Para o treinamento dos modelos, utilizou-se a biblioteca *Transformers* para o carregamento e gerenciamento dos modelos e tokenizadores, atuando em conjunto com a biblioteca *Datasets* para organizar as bases de dados. Os conjuntos *grammar_samples1.json*, desenvolvido pelo autor com cerca de 730 instâncias sob o mapeamento de chaves *instruction* e *output*, e o *dataset* público *Mistake-To-Meaning* foram incorporados para o treinamento do modelo de correção gramatical *Flan-T5 Large*, fornecendo um volume robusto de pares estruturados de erro e correção linguística. Também de autoria própria, o *conversation.json* conta com cerca de 2.010 instâncias baseadas em turnos de diálogo contínuo e foi empregado no alinhamento do tutor artificial baseado no modelo *TinyLlama-1.1B-Chat*, mapeado sob o padrão de chaves *input* e *output*. Em paralelo, para otimizar

o modelo de reconhecimento de fala *Whisper* aplicou-se a base de dados *L2-Arctic*, garantindo maior robustez na transcrição dos fonemas dos estudantes. Além do mais, fez-se uso da biblioteca *PEFT* para aplicar o *LoRA* e a execução dos treinamentos foi suportada por meio da biblioteca *PyTorch* e otimizada com o uso da *Accelerate* e, para reduzir ao máximo o consumo de memória, *bitsandbytes*.

Para o banco de dados foi escolhido o *MongoDB* por permitir construir bancos de dados não relacional, *NoSQL*, que armazena documentos *BJSON*, que é uma extensão do *JSON* que possibilita o suporte a tipos de dados adicionais, de forma que a modelagem de informações seja simplificada, uma vez que elas podem mudar ao longo do tempo. De acordo com essa estrutura, a plataforma distribui suas funções em seções focadas nas quatro habilidades essenciais para o aprendizado da língua inglesa: compreensão auditiva (*Listening*), fala (*Speaking*), leitura (*Reading*) e escrita (*Writing*), criando um ambiente integrado para a calibração contínua das competências do estudante conforme visto na Figura 2. Em conformidade com os preceitos da comunidade *open-source* e visando a reprodutibilidade científica, todo o código-fonte do ecossistema ChatEp foi disponibilizado no *GitHub* e na plataforma *Hugging Face*.

A plataforma proposta alinha-se à Cultura *Maker* ao transcender o modelo de sistemas educacionais fechados por meio de uma arquitetura aberta e extensível. A fácil reorganização do sistema é viabilizada pelo recurso de Injeção de *System Prompt*, permitindo que usuários avançados customizem a lógica, o rigor e a personalidade do tutor de IA sem modificar o código-fonte. Esse ecossistema estimula a autonomia por meio da Exportação de Dados Brutos(*JSON/CSV*), capacitando os usuários a extraírem todo o seu histórico de exercícios para análises estatísticas e acompanhamento pessoal de desempenho, capacitando os usuários a consolidarem novos *datasets* abertos para o refinamento coletivo dos modelos.

3.1. Módulos de Compreensão Auditiva (*Listening*), Escrita (*Writing*), Fala (*Speaking*) e Leitura (*Reading*)

As Figuras 3 e 4 apresentam o módulo de *listening*, desenvolvido para aprimorar a compreensão auditiva de forma autodidata por meio de vídeos com falantes nativos ou fluentes. O estudante registra sua interpretação em um campo textual e, após o envio, recebe um *feedback* com base na comparação entre sua resposta e o texto original, resultando em um *score* de 0 a 100. Além disso, a correção é enriquecida com destaques visuais: verde para correspondências corretas, amarelo para omissões e vermelho para erros. Cabe ressaltar que o *score* não atua como um mecanismo punitivo, mas sim como uma métrica de calibração que indica o nível de aproximação entre a entrega do estudante e a resposta ideal. Essa estrutura permite um ciclo de iteração contínua, em que o estudante tem autonomia para repetir o exercício quantas vezes desejar, ajustando sua compreensão e progredindo em seu próprio ritmo.

A Figura 5 exibe a aba de exercícios para *Writing*, onde o sistema apresenta

⁰Repositórios: <https://github.com/RomuloLB28/ChatEP-front>,
<https://github.com/RomuloLB28/ChatEP-back>, <https://github.com/RomuloLB28/chatep-microservice>

⁰Modelos: <https://huggingface.co/RomuloLB28/chatep-whisper-finetuned>,
<https://huggingface.co/RomuloLB28/finetuned-chatep-tutor>, <https://huggingface.co/RomuloLB28/chatep-conversador>



Figura 3. Módulo de *Listening* - Tela inicial

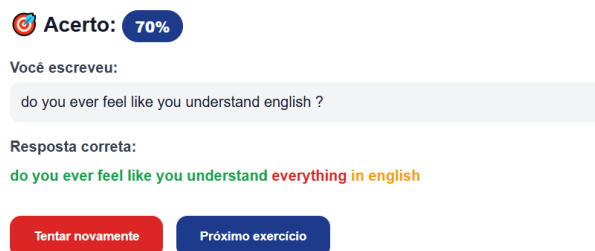


Figura 4. Módulo de *Listening* - Tela pós-avaliação

situações contextualizadas que servem como desafios de prototipagem textual. Fundamentada na abordagem *TBLT*, a plataforma permite que o estudante-maker explore diferentes cenários comunicativos, construindo frases em inglês que atendam às necessidades do contexto. Ao final, a resposta é analisada para fornecer um retorno automático, que permite que o estudante identifique lacunas e refine sua escrita de forma independente, respeitando seu próprio ritmo de descoberta e aprofundamento. Figura 6 exibe a aba de correção de texto, desenvolvida com o objetivo de prover ao estudante-maker uma ferramenta de calibração para o refino autônomo de sua escrita, permitindo o gerenciamento de sua evolução gramatical, elemento fundamental para a fluência no idioma. Para isso, o módulo utiliza um modelo de linguagem previamente ajustado por meio de *fine-tuning*, baseado no *Flan-T5 Large*, no qual o estudante insere seu texto na plataforma, sendo processado pelo modelo para identificar e corrigir inadequações gramaticais e estruturais, visando atuar como parâmetro de refinamento gramatical e não apenas apontar erros, retornando tanto o texto original quanto a versão corrigida para comparação e compreensão dos ajustes necessários.

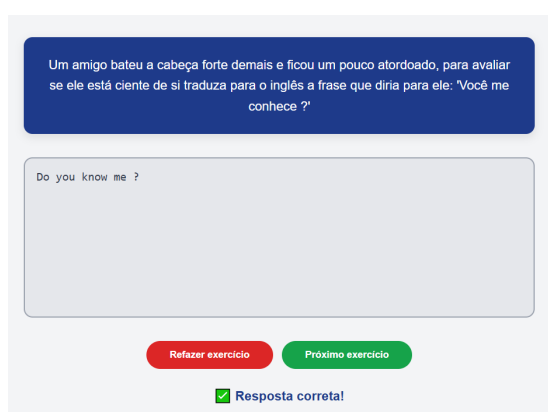


Figura 5. Aba de exercícios de *writing* pós correção

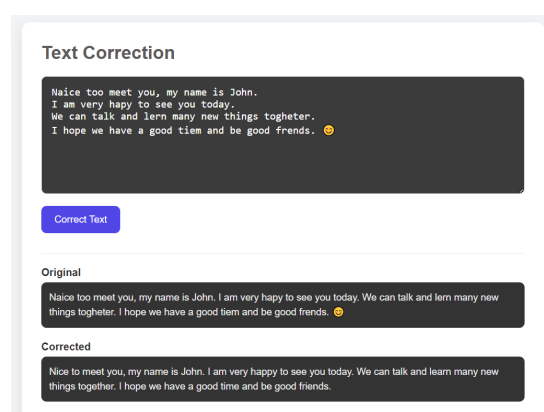


Figura 6. Aba de correção textual pós correção

Figura 7 simula interações conversacionais para a prática da pronúncia e produção oral da língua inglesa, na qual o sistema apresenta uma frase ou pergunta e solicita que o estudante grave sua resposta oral com base no conteúdo exibido; após a gravação, o áudio é enviado ao *backend* e convertido em texto por meio de um modelo de reconhecimento

de fala baseado no *Whisper*, previamente ajustado por *fine-tuning*. O texto resultante é comparado com a frase de referência, servindo como parâmetro de calibração para análise do nível de correspondência da fala, a partir do qual o sistema gera uma métrica de similaridade percentual que atua como indicador de ajuste técnico, permitindo ao estudante identificar pontos de melhoria e realizar novas iterações de forma autônoma até refinar sua produção oral em seu próprio ritmo. A Figura 8 exibe a aba de tutoria que permite a interação do estudante com um agente conversacional baseado no modelo *TinyLlama-1.1B-Chat*, no qual o estudante insere mensagens textuais que são enviadas ao *backend* para processamento, e o modelo gera respostas conforme o contexto, simulando uma interação natural e contínua com comportamento previamente ajustado para ser mais amigável e compreensivo, atuando como suporte ao autodidatismo. Após a geração, a resposta é exibida na interface e convertida em áudio por meio de *Text-to-Speech*, permitindo integrar a prática de *listening* e *speaking* de forma síncrona, possibilitando o refinamento das competências no próprio ritmo, de maneira semelhante a interações reais do cotidiano.

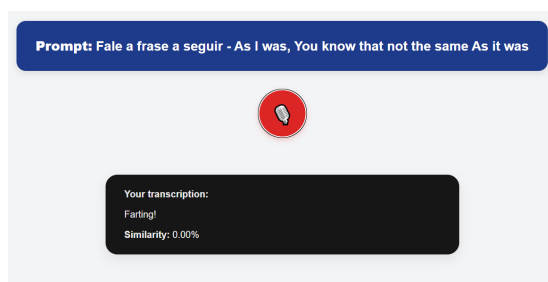


Figura 7. Aba de exercícios de speaking pós correção

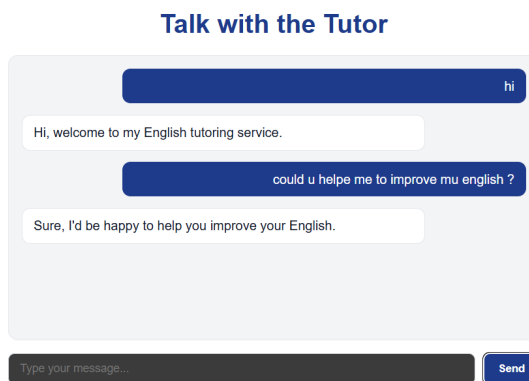


Figura 8. Aba de tutoria

A Figura 9 mostra o módulo de *reading* que oferece textos curtos com níveis variados de complexidade, do vocabulário básico ao acadêmico, permitindo ao estudante escolher desafios compatíveis com seu estágio, incluindo, nos níveis avançados, estruturas como *phrasal verbs*, *wh-words*, *conjunctions*, *modal verbs* e tempos verbais mais complexos, promovendo progressão gradual da proficiência. Após a leitura, são apresentadas questões de múltipla escolha e, ao final, o sistema fornece *feedback* visual ao destacar a alternativa correta em verde e a incorreta em vermelho.

4. Avaliação

Para a avaliação dos modelos utilizados na plataforma, foram empregadas três métricas específicas, selecionadas de acordo com a natureza de cada tarefa desempenhada, conforme apresentado na Tabela 1. Os testes automatizados e a coleta de desempenho foram executados em um ambiente controlado, composto por um notebook Samsung Book equipado com processador Intel Core i3-1115G4, 12 GB de memória RAM, SSD de 1 TB, placa de vídeo integrada Intel UHD Graphics, com Windows 10. Para o modelo baseado no *Flan-T5 Large*, utilizado em tarefas de correção textual, adotou-se a métrica *Bilingual Evaluation Understudy (BLEU)*, a qual se baseia na comparação entre a saída gerada pelo modelo e uma ou mais referências consideradas corretas, sendo, neste trabalho, utilizada apenas uma referência por critérios de exatidão, calculando a sobreposição de n-gramas

Figura 9. Tela de exercícios de re-reading pós correção

entre os textos e atribuindo uma pontuação que varia entre 0 a 100%. Em contrapartida, para o modelo de reconhecimento de fala baseado no *Whisper*, foi empregada a métrica *Word Error Rate (WER)*, comum em transcrição automática, a qual mede a taxa de erro entre o texto transcrito pelo modelo e a transcrição de referência, apresentando o resultado em forma de porcentagem (0 a 100%). Para o modelo conversacional *TinyLlama-1.1B-Chat*, foi utilizada a métrica *BERTScore*, que considera a similaridade semântica entre os textos de referência e aqueles produzidos pelo modelo, permitindo avaliar respostas que, embora não sejam idênticas lexicalmente, apresentam equivalência semântica, tornando-se, assim, mais adequada para sistemas conversacionais, nos quais diferentes formas de resposta podem ser consideradas corretas desde que mantenham a coerência com o contexto da interação com o estudante. BLEU e BERTScore possuem maior qualidade quanto maior for sua porcentagem, enquanto WER apresenta comportamento contrário.

Tabela 1. Interpretação das métricas BLEU, WER e BERTScore

Métrica	Faixa	Interpretação
BLEU (%)	0 – 9	Qualidade muito baixa
BLEU (%)	10 – 29	Qualidade baixa
BLEU (%)	30 – 49	Qualidade aceitável
BLEU (%)	50 – 69	Boa qualidade
BLEU (%)	70 – 100	Excelente correspondência
WER (%)	0 – 9	Excelente reconhecimento
WER (%)	10 – 19	Bom reconhecimento
WER (%)	20 – 39	Reconhecimento moderado
WER (%)	40 – 59	Baixa precisão
WER (%)	60+	Reconhecimento inadequado
BERTScore	0.00 – 0.59	Baixa similaridade semântica
BERTScore	0.60 – 0.74	Similaridade moderada
BERTScore	0.75 – 0.84	Boa similaridade
BERTScore	0.85 – 0.94	Alta similaridade semântica
BERTScore	0.95 – 1.00	Similaridade quase perfeita

A Tabela 2 mostra a pontuação obtida ao utilizar as métricas nos modelos após o uso de *fine-tuning* para a especialização dos mesmos nas tarefas da plataforma. Complementarmente, a Tabela 2 também apresenta uma avaliação comparativa entre o desempenho dos modelos base (puros) e as versões ajustadas com *LoRA*. Os resultados evidenciam uma evolução significativa em todas as tarefas: o modelo de correção de texto elevou a

métrica BLEU de 27.16% para 40.62%, enquadrando-se em uma qualidade considerada “aceitável”. O avanço mais expressivo ocorreu no modelo de reconhecimento de fala, cuja taxa de erro (WER) reduziu drasticamente de 116.67% na *baseline* para apenas 9.05%, o que reflete um “excelente reconhecimento”. Por fim, o agente conversacional obteve uma evolução na métrica BERTScore de 0.8576 para 0.8659, consolidando uma “boa similaridade” semântica. Dessa forma, a análise comparativa confirma a eficiência técnica do ajuste fino em parâmetros para adaptar grandes modelos de linguagem ao contexto educacional da plataforma, garantindo precisão nas tarefas de correção, transcrição e conversação.

Tabela 2. Avaliação e comparação de desempenho dos modelos puros (Baseline) vs. ecossistema ChatEp pós LoRA

Modelo	Tarefa	Métrica	Baseline (Puro)	ChatEp pós LoRA (Atual)
Flan-T5 Large	Correção de texto	BLEU ↑	27.16%	40.62%
Whisper	Reconhecimento de fala	WER ↓	116.67%	9.05%
TinyLlama-1.1B-Chat	Agente conversacional	BERTScore ↑	0.8576	0.8659

Além da validação quantitativa, um estudo piloto avaliou a usabilidade da plataforma com 5 usuários de níveis variados de proficiência (A2, B1 e C1 *CEFR*), após práticas de *listening*, *speaking*, *writing* e *reading*. Os *feedbacks* indicaram alta estabilidade técnica e respostas sem interrupções, mas apontaram que a latência ocasional (*delay*) das respostas, decorrente do tempo de inferência dos modelos e das limitações da hospedagem em nuvem, afetou a fluidez do estudo. No aspecto pedagógico, os usuários elogiaram os *feedbacks* automáticos e a abordagem *TBLT*. Como melhorias futuras, sugeriram a otimização desse tempo de resposta e a inclusão de testes e atividades por níveis de proficiência.

5. Conclusão

O presente trabalho apresentou o desenvolvimento da plataforma ChatEp, uma aplicação *web* voltada no apoio do aprendizado a língua inglesa de forma autodidata, com foco nas quatro competências fundamentais: *listening*, *speaking*, *writing* e *reading*. A proposta integrou abordagens pedagógicas, como a *TBLT*, junto a tecnologias modernas de desenvolvimento *web* e inteligência artificial, de forma que resultou em um ambiente interativo que permite o estudante exercitar o idioma de forma autônoma e contextualizada. A avaliação dos modelos, conduzida por meio das métricas *BLEU*, *WER* e *BERTScore*, expôs resultados positivos, com desempenho apropriado para o propósito da aplicação.

Como trabalhos futuros, propõe-se a otimização do tempo de resposta dos microserviços na nuvem e a expansão dos testes para um estudo de caso longitudinal com turmas completas de estudantes, permitindo mensurar o ganho de proficiência a longo prazo. Além disso, a integração de novos recursos sugeridos pelos participantes, tais como: testes de nivelamento iniciais, atividades separadas por proficiência e análises detalhadas de pronúncia; contribuirá para tornar a plataforma ainda mais eficaz e personalizada no processo de ensino-aprendizagem da língua inglesa.

6. Agradecimentos

Este trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e do Programa Institucional de Bolsas de Iniciação Científica e de Desenvolvimento Tecnológico e Inovação da UFPA, edital 07/2025.

Referências

- Ahmad, Y., Hussain, S., Mumtaz, U., and Riaz, S. (2025). Investigating the influence of duolingo, elsa speak, and hello english mobile applications on students' attitudes and speaking skills. *Review Journal of Social Psychology & Social Works*, 3(1).
- Coşkun, Z. and Solmaz, O. (2024). Exploring high school students' acceptance and use of mobile applications for english language learning. *Dil Eğitimi ve Araştırmaları Dergisi*, 10(2):636–661.
- Jawad, I. A., Mohammed, A. A. S., Sulaiman, S. K., Sofir, B., and Mohsen, A. H. (2024). Innovative integration of the teaching-learning process in situational english practice. In *2024 International Conference on Emerging Research in Computational Science (ICERCS)*, pages 1–6.
- Kalimullah, M. and Tabassum, F. (2025). Technology-supported english language learning: Effectiveness and limitations. *International Journal of Social Impact*, 10(1):281–286.
- Kalra, M. and Sharma, V. (2025). Impact of low rank adaptation with parameter efficient fine-tuning techniques on transformer models. In *2025 6th International Conference for Emerging Technology (INCET)*, pages 1–6.
- Li, S. (2021). Task-based language teaching based on computer-assisted language learning. In *2021 2nd International Conference on Education, Knowledge and Information Management (ICEKIM)*, pages 863–866.
- Mohd Sapuan, W., Hassan, H., Rostam, N. L. S., and Azmimurad, A. (2024). The impacts of language learning apps on students' perceptions of language proficiency. *International Journal of Research and Innovation in Social Science*, VIII:3447–3455.
- Olajide-Owoyomi, F. (2025). English proficiency barriers in brazil: Communication challenges among international students and professionals. *Journal of International Students*, 15(12):177–192.
- Osipov, I. V., Prasikova, A. Y., and Volinsky, A. A. (2015). Monetization as a motivator for the freemium educational platform growth. *arXiv preprint arXiv:1501.04157*.
- Pereira, A., Pinheiro, P., and Costa, D. (2025). Explorando o interesse e necessidades em educação online de robótica e tecnologia. In *Anais do I Workshop de Inovação, Desenvolvimento, Educação e Inclusão com Ações Maker*, pages 147–156, Porto Alegre, RS, Brasil. SBC.
- Santos, S., Soares, H., Sousa, A., Barbosa, F., and Santos, J. (2025). Abordagem maker na contemporaneidade: Perspectivas e possibilidades nos processos de ensino e aprendizagem. In *Anais do I Workshop de Inovação, Desenvolvimento, Educação e Inclusão com Ações Maker*, pages 127–136, Porto Alegre, RS, Brasil. SBC.
- Sharma, A. K., Pareta, A., Meena, J., and Sharma, R. (2022). A long term impact of artificial intelligence and robotics on higher education. In *2022 International Conference on Advances in Computing, Communication and Applied Informatics (ACCAI)*, pages 1–4.