



UEPB

**UNIVERSIDADE ESTADUAL DA PARAÍBA
CAMPUS VII**

**CENTRO DE CIÊNCIAS EXATAS E SOCIAIS APLICADAS
CURSO DE BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO**

CHRIS RUAN DA SILVA GOMES

**DESENVOLVIMENTO DE CHATBOT E TREINAMENTO DE MODELOS DE
LINGUAGEM PARA A FUNÇÃO DE MESTRE DE RPG.**

**PATOS-PB
2024**

CHRIS RUAN DA SILVA GOMES

DESENVOLVIMENTO DE CHATBOT E TREINAMENTO DE MODELOS DE LINGUAGEM PARA A FUNÇÃO DE MESTRE DE RPG.

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

Área de concentração: Large language models (LLMs).

Orientador: Ricardo Santos de Oliveira.

**PATOS-PB
2024**

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

G633d Gomes, Chris Ruan da Silva.
Desenvolvimento de Chatbot e treinamento de modelos de linguagem para a função de mestre de RPG [manuscrito] / Chris Ruan da Silva Gomes. - 2024.
62 p. : il. colorido.

Digitado.

Trabalho de Conclusão de Curso (Graduação em Computação) - Universidade Estadual da Paraíba, Centro de Ciências Exatas e Sociais Aplicadas, 2024.

"Orientação : Prof. Dr. Ricardo Santos de Oliveira, Coordenação do Curso de Computação - CCEA. "

1. Modelos de linguagem. 2. Inteligência artificial. 3. Game master chatbot. 4. RPG. I. Título

21. ed. CDD 005.13

CHRIS RUAN DA SILVA GOMES

DESENVOLVIMENTO DE CHATBOT E TREINAMENTO DE MODELOS DE LINGUAGEM PARA A FUNÇÃO DE MESTRE DE RPG

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

Aprovado em 22/03/2024

BANCA EXAMINADORA

Ricarda Santos de Oliveira

Prof. Dr. Ricardo Santos de Oliveira
(Orientador)

Documento assinado digitalmente

gov.br

THIAGO ALVES LAURENTINO

Data: 27/03/2024 19:21:39-0300

Verifique em <https://validar.it.gov.br>

Prof. Thiago Alves Laurentino
(Examinador)

Demetrio Gomes Mestre

Prof. Dr. Demetrio Gomes Mestre
(Examinador)

AGRADECIMENTOS

Neste momento de conclusão, é impossível não expressar minha profunda gratidão às pessoas que estiveram ao meu lado durante toda essa jornada, tornando possível a realização deste trabalho de conclusão de curso.

Em primeiro lugar, gostaria de expressar minha gratidão a Deus. Sua presença constante em cada detalhe e seu amor inabalável foram a luz que iluminou meu caminho nos momentos de dificuldade. Sua orientação e a sua palavra foram fundamentais para que eu pudesse alcançar esta conquista tão significativa em minha vida.

Aos meus pais, Rubia e Cícero, devo todo o meu sucesso. Seu apoio incondicional e sacrifício foram o alicerce sobre o qual construí cada passo dessa trajetória acadêmica. Esta vitória é dedicada a vocês, que além de pais exemplares, são os responsáveis por minha formação e valores. Não posso deixar de mencionar meus irmãos, Yartagnam e Klermerson, cujo apoio e exemplo foram fontes de inspiração inestimáveis do início ao fim dessa jornada, vocês me ajudaram a enxergar que eu deveria querer mais e ir além.

Ao meu orientador, Ricardo, expresso minha mais sincera gratidão. Sua orientação dedicada, sua paciência e sua confiança em meu potencial foram fundamentais para o desenvolvimento deste trabalho. Obrigado por estar sempre disponível para esclarecer dúvidas, por seu comprometimento e por acreditar em mim, saiba que o senhor me ajudou a realizar este sonho.

Aos demais familiares e amigos que estiveram ao meu lado, meu profundo agradecimento. Vocês foram minha “âncora” nos momentos de dificuldade, oferecendo apoio, encorajamento e compreensão. Mesmo diante das dificuldades, sempre pude contar com vocês servindo como uma base sólida para me apoiar.

Este trabalho não seria possível sem o apoio e contribuição de cada destes. Que este momento de gratidão seja apenas o início de uma jornada repleta de realizações e sucesso para todos nós. Obrigado por fazerem parte desta conquista.

RESUMO

O RPG de mesa é conhecido por promover narrativas colaborativas e estimular a imaginação, mas encontrar participantes e um mestre competente pode ser difícil. Para resolver esse problema, foram treinados modelos de linguagem para Criação de Resumos de Aventuras e Geração de personagens fictícios, visando melhorar a experiência dos jogadores e aliviar a carga do mestre do jogo. A principal motivação para o treinamento dos modelos de linguagem foi para aprimorar o desempenho do Game Master Chatbot, uma ferramenta que desempenha o papel de mestre. O objetivo deste projeto é que o Game master Chatbot e os modelos de linguagem fossem projetados como ferramentas viáveis para as narrativas de RPG e condução do jogo, facilitando a organização das mesas, reduzindo o tempo de preparo e tornando a experiência mais atrativa. Nesse contexto, o treinamento de modelos de linguagem para desempenhar funções diferentes de um mestre de RPG mostrou-se promissor para suprir as necessidades de geração de informações direcionadas. O estudo concentra-se em Large Language Models (LLMs), que lidam com diversas tarefas e mantêm o contexto narrativo, atendendo às interações dos jogadores. Para alcançar esse objetivo, foram utilizadas técnicas avançadas de processamento de linguagem natural e aprendizado de máquina. A metodologia envolveu coleta de dados, treinamento dos modelos, desenvolvimento do Chatbot e avaliação das ferramentas. A coleta de dados automatizada e os modelos de linguagem treinados por fine-tuning utilizaram a plataforma de inteligência artificial da OpenAI. Os resultados foram avaliados por meio de entrevistas com avaliadores selecionados, indicando uma boa eficácia das ferramentas. A pesquisa e análise dessas ferramentas forneceram orientações para futuras melhorias e implementações.

Palavras-chave: Large Language Models. Fine-tuning. Processamento de linguagem natural. RPG de mesa.

ABSTRACT

Tabletop RPG is known for promoting collaborative narratives and stimulating imagination, but finding participants and a competent master can be challenging. To address this issue, language models were trained for Adventure Summary Creation and Fictional Character Generation, aiming to enhance players' experience and alleviate the burden on the game master. The primary motivation for training language models was to improve the performance of the Game Master Chatbot, a tool that acts as the master. The objective of this project is for the Game Master Chatbot and language models to be designed as viable tools for RPG narratives and game management, facilitating table organization, reducing preparation time, and enhancing the overall experience. In this context, training language models to perform different functions than an RPG master proved promising in meeting the needs for targeted information generation. The study focuses on Large Language Models (LLMs), which handle various tasks while maintaining narrative context and addressing player interactions. Advanced natural language processing and machine learning techniques were employed to achieve this goal. The methodology involved data collection, model training, Chatbot development, and tool evaluation. Automated data collection and fine-tuning of language models utilized the OpenAI artificial intelligence platform. Results were assessed through interviews with selected evaluators, indicating a good effectiveness of the tools. Research and analysis of these tools provided guidance for future improvements and implementations.

Keywords: Large Language Models. Fine-tuning. Natural Language Processing. Tabletop RPGs.

LISTA DE FIGURAS

Figura 1 – Exemplo de arquitetura Transformer.....	17
Figura 2 – Diagrama de Prompt engineering (Engenharia de Prompt).....	20
Figura 3 – Treinamento de Modelo de Linguagem através do Fine-Tuning.....	24
Figura 4 – Exemplo do uso do modelo treinado para Descrições de NPCs de RPG de Mesa, através do playground da plataforma da OpenIA.....	35
Figura 5 – Interface de chat do Game master Chatbot.....	37
Figura 6 – Interação com o chat do Game master Chatbot.....	38
Figura 7 – Pipeline do Projeto.....	40
Figura 8 – Facilidade de uso dos Modelos treinados via plataforma da OpenIA e do Game master Chatbot.....	45
Figura 9 – Usabilidade dos modelos de linguagem treinados para um mestre de RPG.....	45
Figura 10 – Capacidade de reter a atenção do usuário do Game master chatbot.....	46
Figura 11 – Coesão e consistência dos modelos de linguagem treinados.....	47
Figura 12 – Coesão e consistência da narração do Game master chatbot.....	48
Figura 13 – Adaptatividade do Game master Chatbot a diferentes e interações.	48
Figura 14 – Diversificação e atratividade das interações do Game master chatbot.....	49
Figura 15 – Nível de engajamento e envolvimento que as ferramentas provocaram aos avaliadores.....	50
Figura 16 – Nível de engajamento e envolvimento que as ferramentas provocaram aos avaliadores.....	51

LISTA DE TABELAS

Tabela 1 –	Objetivos e desenvolvimento das bases de dados.	30
Tabela 2 –	Bases de dados.	31
Tabela 3 –	Exemplos de instâncias e resultados das bases de dados.	32
Tabela 4 –	Exemplos de dados contidos nos arquivos JSONL de cada base de dados.	34
Tabela 5 –	Contexto utilizado para o Game Master Chatbot, separado em instruções.	39
Tabela 6 –	Questionário e a finalidade de cada pergunta.	42

LISTA ABREVIATURAS E SIGLAS

BD	Bancos de Dados
BERT	Bidirectional Encoder Representations from Transformers
CSV	Comma-Separated Values
CTOs	Chief Technology Officers
D&D	Dungeons & Dragons
GPT	Generative Pre-trained Transformer
GPT-4	Generative Pre-trained Transformer 4
GUI	Graphical User Interface
IA	Inteligência Artificial
JSONL	JSON Lines
LLMs	Large Language Models
ML	Machine Learning
NLP	Natural Language Processing
NPCs	Non-Player Characters
OS	Operating System
RPG	Natural Language Processing
T5	Text-To-Text Transfer Transformer
TTRPG	Tabletop Role-Playing Gam
UI	User Interface
VTTs	Virtual Tabletops

SUMÁRIO

1.	INTRODUÇÃO	11
1.1.	Objetivos	13
1.1.1.	<i>Objetivos específicos</i>	13
1.2.	Justificativa	14
1.3.	Estrutura do Documento	15
2.	REVISÃO BIBLIOGRÁFICA	16
2.1.	Large language models (LLMs)	16
2.1.1.	<i>Arquitetura e Treinamento de LLMs</i>	17
2.1.2.	<i>Transferência de Aprendizado</i>	17
2.1.3.	<i>Aplicações e Impacto dos LLMs</i>	18
2.2.	Prompt engineering (Engenharia de Prompt)	19
2.3.	Advanced Prompt Engineering (Engenharia de Prompt Avançada).....	21
2.3.1.	<i>Refinando a Geração com Maior Precisão</i>	21
2.3.2.	<i>Adaptando-se ao Contexto e Personalizando a Experiência</i>	21
2.3.3.	<i>Meta-Aprendizado e Transferência de Aprendizado</i>	22
2.3.4.	<i>Potencial Transformativo</i>	22
2.4.	Fine-Tuning	22
2.5.	RPG (Role-playing game)	24
2.6.	Trabalhos Relacionados	26
2.6.1.	<i>Towards Computational Support with Language Models for TTRPG Game Masters</i>	26
2.6.2.	<i>Chat Reincarnation: The Case of My Childhood Girl Friend Who Was Supposed to be Dead Becoming a Hero in Another World</i>	27
2.6.3.	<i>AI Dungeon</i>	28
2.7.	Considerações Finais	28
3.	METODOLOGIA	29
3.1.	Coleta de dados e desenvolvimento dos Bancos de Dados (BD)	29
3.2.	Fine-tuning dos Modelos de Linguagem	32
3.3.	Desenvolvimento de um Chatbot Mestre de RPG	35
3.4.	Avaliação das ferramentas desenvolvidas.....	41
4.	RESULTADOS E DISCUSSÕES	43

4.1	Visão geral dos resultados da pesquisa.	43
5.	CONCLUSÃO	53
	REFERÊNCIAS	56
	ANEXO A – Sessão de RPG com o Game Master Chatbot	62

1 INTRODUÇÃO

Os modelos de linguagem desempenham um papel essencial no avanço da Inteligência Artificial (IA) e têm sido amplamente estudados no campo do processamento de linguagem natural. Esses modelos são capazes de aprender e compreender estruturas linguísticas complexas, permitindo a geração de texto coerente e facilitando tarefas como tradução automática, resumo de texto e resposta a perguntas. Segundo Jurafsky e Martin, os modelos de linguagem são fundamentais para o processamento de linguagem natural, pois aprendem a prever a próxima palavra em uma sequência de palavras, com base em um contexto fornecido (2020).

Através de avanços notáveis na área, como a introdução do Transformer por Vaswani et al. (2017), os modelos de linguagem alcançaram resultados significativos na modelagem de dependências de longo alcance e no tratamento de estruturas complexas da linguagem. Esses modelos são treinados em grandes volumes de dados textuais, permitindo capturar padrões e informações linguísticas que podem ser aplicados em diferentes domínios.

Os modelos de linguagem desempenham um papel crucial em várias aplicações de IA, permitindo que as máquinas processem e gerem texto de maneira mais natural e fluente, aproximando-se da capacidade humana. De acordo com LeCun et al. (2015), esses modelos têm se mostrado extremamente eficazes para uma ampla gama de tarefas de processamento de linguagem natural, servindo como base para a construção de sistemas de IA em diversas aplicações.

Esses modelos são treinados em grandes volumes de dados textuais, capturando informações e estruturas linguísticas que podem ser aplicadas em diferentes domínios. Eles são a base para tarefas mais complexas, como tradução automática, sumarização de texto, geração de diálogos e assistentes virtuais.

É importante ressaltar que a pesquisa em modelos de linguagem continua avançando, impulsionada por estudos importantes realizados por pesquisadores renomados, como Brown et al. (2020). Esses estudos contribuem para o desenvolvimento de modelos mais sofisticados e eficazes, permitindo interações mais naturais e inteligentes entre humanos e máquinas.

À medida que os modelos de linguagem evoluem, espera-se que a sua importância na IA continue a crescer, possibilitando o desenvolvimento de sistemas

cada vez mais inteligentes e interativos. Combinados com outros avanços em áreas relacionadas, como visão computacional e aprendizado por reforço, esses modelos têm o potencial de revolucionar a maneira como interagimos com a tecnologia, tornando-a mais humana, adaptável e útil em diversas aplicações.

Uma das aplicações possíveis é o uso de LLMs em RPGs de Mesa, que se trata de um tipo de jogo de narrativa colaborativa que combina elementos de improvisação teatral, imaginação e estratégia. O RPG de Mesa surgiu na década de 1970, com o lançamento do jogo "Dungeons & Dragons" por Gary Gygax e Dave Arneson (Gygax & Arneson, 1974). Desde então, o RPG de Mesa tem sido uma forma popular de entretenimento, mobilizando tanto o mercado físico quanto o mercado digital, especialmente por meio das Virtual Tabletops (VTTs) (PRASS; WEBE, 2017).

O RPG de Mesa permite que os participantes assumam o papel de personagens fictícios e interajam em um mundo imaginário, criado pelo mestre do jogo. Como mencionado por Jon Peterson (2012), autor de "Playing at the World: A History of Simulating Wars, People, and Fantastic Adventures from Chess to Role-Playing Games", o RPG de Mesa é uma experiência única: "Os RPGs de mesa abrem a porta para a criação de histórias compartilhadas, não apenas assistidas".

Nos últimos anos, o RPG de Mesa tem experimentado um aumento significativo em sua popularidade, impulsionado, em parte, pelo avanço da tecnologia. Os Virtual Tabletops (VTTs) tornaram possível jogar RPGs de mesa online, reunindo jogadores de diferentes partes do mundo. Conforme mencionado por Scholtz (2020), "a pandemia de COVID-19 acelerou ainda mais essa tendência, com muitos jogadores migrando para plataformas online para continuar jogando com seus amigos".

No contexto digital, os RPGs de mesa também têm sido impulsionados pelo avanço da tecnologia. Os Virtual Tabletops (VTTs), como Roll20, Fantasy Grounds e Tabletop Simulator, têm experimentado um aumento significativo na popularidade. Por exemplo, a Roll20, uma dos principais VTTs, registrou um aumento de mais de 20% no número de usuários ativos em 2020 em comparação com o ano anterior, conforme relatado pela TechCrunch.

1.1 Objetivos

Este trabalho tem como objetivo treinar dois modelos de linguagem, um deles com a função de Gerador de Aventuras de RPG e o outro de Descrição de NPCs de RPG de Mesa e desenvolver um Chatbot para atuar como mestre em RPG de mesa. Utilizando técnicas avançadas de processamento de linguagem natural e aprendizado de máquina, o objetivo é capacitar o modelo para gerar informações para roteirização das sessões e executar narrativas de forma coerente. Isso inclui a criação de personagens, ambientação e interações inteligentes. A proposta é automatizar tarefas de criação e execução de narrativa, proporcionando uma experiência imersiva e personalizada para os jogadores. O modelo e o Chatbot serão avaliados para demonstrar sua eficácia na criação de uma experiência de jogo coesa e consistente.

1.1.1 *Objetivos específicos*

- Realizar um levantamento bibliográfico sobre os fundamentos teóricos e práticos do RPG de mesa, compreendendo os elementos-chave, regras e estrutura das sessões de jogo.
- Investigar técnicas avançadas de processamento de linguagem natural e aprendizado de máquina para o desenvolvimento de modelos de linguagem e geração de texto.
- Coletar e preparar um conjunto de dados adequado para o treinamento do modelo de linguagem, considerando narrativas de RPG de mesa, manuais de jogos e outros recursos relevantes.
- Implementar e treinar dois modelos de linguagem utilizando as técnicas selecionadas, o primeiro modelo de linguagem possui a função de Geração de Resumos de Aventuras de RPG e outro de Descrição de NPC de RPG de mesa.
- Desenvolver um Chatbot com um uso de engenharia de prompt que utiliza os dados gerados pelos modelos de linguagem para narrar uma sessão de jogo de RPG de Mesa.

- Avaliar o desempenho dos modelos de linguagem e do Chatbot por meio de testes e estudos sobre técnicas de melhoria, buscando o aperfeiçoamento das ferramentas geradas, usando como critérios a coerência narrativa, qualidade da interação com o jogador e capacidade de adaptação às diferentes situações de jogo.
- Realizar experimentos práticos envolvendo jogadores reais de RPG de mesa, solicitando seu feedback através de um questionário por grau de concordância e avaliação da experiência de jogo e de geração de informação ao interagir com o modelo de linguagem.
- Analisar e discutir os resultados obtidos, analisando pontos fortes e áreas de melhorias.

1.2 Justificativa

Em primeiro lugar, o RPG de mesa é uma forma de entretenimento que tem ganhado destaque e impacto significativo em diversas áreas (Peterson, 2012). O RPG de mesa oferece uma experiência única de criação de narrativas compartilhadas, promovendo interação social e estimulando a imaginação dos participantes.

No entanto, a função do mestre de RPG de mesa pode ser desafiadora, requerendo habilidades de criação de histórias, gerenciamento de personagens e interação com os jogadores. Nesse contexto, a proposta de treinar modelos de linguagem e desenvolver um Chatbot para desempenhar a função de mestre tem implicações significativas.

Ao desenvolver um modelo de linguagem e chatbot capaz de gerar narrativas coerentes, criar personagens não-jogadores dinâmicos e interagir com um jogador durante uma sessão de jogo, busca-se otimizar a experiência de jogo, aprofundando a imersão do jogador no mundo ficcional (Murray, 2018). A imersão é um conceito fundamental nos RPGs, e diz respeito ao grau em que o jogador se sente transportado para a realidade do jogo, como se estivesse realmente vivendo as aventuras do seu personagem.

A relevância do presente trabalho também pode ser justificada pela aplicação prática do RPG de mesa em diversas áreas além do entretenimento. Estudos acadêmicos destacam o potencial do RPG de mesa no desenvolvimento de

habilidades cognitivas, criatividade, pensamento crítico e resolução de problemas em estudantes do ensino médio (Vasques, 2008).

Além disso, o RPG de mesa tem sido utilizado como uma ferramenta terapêutica para jovens e adultos, mostrando benefícios no fortalecimento da interação social, na melhoria da autoestima e no aprimoramento das habilidades de comunicação do indivíduo com transtornos de ansiedade (Hawkes-Robinson, 2008).

Essas aplicações abrangentes do RPG de mesa vão além do entretenimento e alcançam o campo da educação, terapia ocupacional e treinamento corporativo. Isso demonstra que o RPG de mesa é uma forma versátil de interação social e desenvolvimento pessoal.

Portanto, realizar um trabalho acadêmico como o proposto contribuiria para o avanço do campo de processamento de linguagem natural e aprendizado de máquina, bem como para a ampliação das possibilidades do RPG de mesa.

1.3 Estrutura do Documento

O presente trabalho está estruturado em cinco capítulos principais, visando fornecer uma organização clara e lógica para o desenvolvimento do estudo e a compreensão do leitor. O Capítulo 1 compreende a introdução, objetivos, justificativa e estrutura do documento. No Capítulo 2, é realizada uma revisão bibliográfica sobre Large Language Models, Prompt Engineering, Advanced Prompt Engineering, Fine-Tuning, RPG de Mesa e Trabalhos Relacionados. O Capítulo 3 detalha a metodologia, dividida em Coleta de dados e desenvolvimento dos Bancos de Dados (BD), Fine-tuning dos Modelos de Linguagem, Desenvolvimento de um Chatbot Mestre de RPG e Avaliação das ferramentas desenvolvidas. O Capítulo 4 trata dos Resultados e Discussões, apresentando uma visão geral por meio de gráficos. E, por fim, no Capítulo 5, são apresentadas as conclusões deste trabalho, abordando as motivações e percepções sobre o desenvolvimento e resultados, além de discutir trabalhos futuros.

2 REVISÃO BIBLIOGRÁFICA

Neste capítulo, serão apresentados tópicos que abordarão as principais áreas de pesquisa relacionadas a este trabalho. Ele fornecerá uma visão geral dos temas relevantes, estabelecendo assim uma base de conhecimento sólida e contextualizada para uma compreensão aprimorada.

O primeiro tópico irá explorar em detalhes os modelos de linguagem por aprendizado profundo, também conhecidos como Language Models (LMs). Serão apresentados conceitos fundamentais, arquiteturas populares e suas diversas aplicações.

Em seguida, será discutida a técnica do Prompt Engineering, que consiste na elaboração adequada de instruções ou prompts para orientar o modelo de linguagem durante o processo de treinamento. No tópico seguinte serão exploradas estratégias avançadas e eficazes para a criação de prompts que serão abordadas.

O quarto tópico abordará o Fine-Tuning, uma etapa crucial do treinamento de modelos de linguagem pré-treinados. Serão discutidos os conceitos e metodologias relacionados ao Fine-Tuning, destacando sua importância para adaptar o modelo de linguagem aos requisitos específicos de seu treinamento.

Por fim, um tópico que fornecerá uma visão geral do RPG de Mesa e da função do Mestre. Será explorado o conceito do RPG de Mesa, o papel central desempenhado pelo Mestre na narrativa e interação com os jogadores.

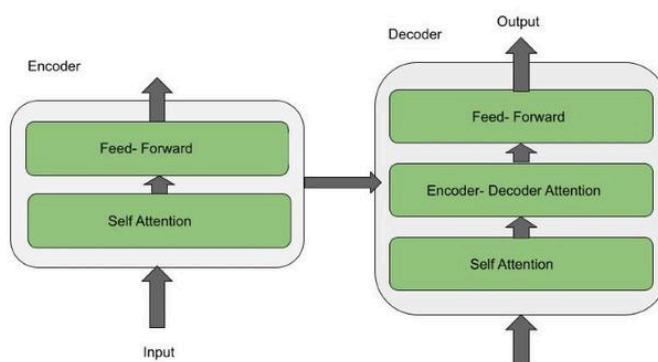
2.1 Large language models (LLMs)

Os avanços em aprendizado de máquina e a disponibilidade de grandes conjuntos de dados permitiram o desenvolvimento de modelos de linguagem cada vez mais poderosos. Os LLMs são uma classe de modelos que usam técnicas de aprendizado profundo, em particular a arquitetura de redes neurais conhecida como Transformer, para aprender padrões linguísticos complexos e gerar texto de alta qualidade. Esses modelos são treinados em grandes quantidades de dados textuais, como livros, artigos, sites e até mesmo todo o conteúdo da internet. A partir desse treinamento massivo, os LLMs são capazes de produzir saídas que se assemelham ao estilo e à estrutura do texto original.

2.1.1 Arquitetura e Treinamento de LLMs

Os LLMs são construídos com base na arquitetura Transformer, introduzida por Vaswani et al. (2017). Essa arquitetura é composta por várias camadas de autoatendimento (self-attention) e camadas totalmente conectadas, permitindo que o modelo capture dependências de longo alcance entre as palavras em um texto. Durante o treinamento, os LLMs utilizam a tarefa de previsão da próxima palavra para aprender a probabilidade condicional de uma sequência de palavras. Algoritmos como o BERT (Devlin et al., 2019), o GPT (Radford et al., 2018) e o T5 (Raffel et al., 2019) são exemplos populares de LLMs que se destacam em várias tarefas de NLP.

Figura 1 – Exemplo de arquitetura Transformer.



Disponível em: <<https://acervolima.com/introducao-aos-transformers/>>

2.1.2 Transferência de Aprendizado

A transferência de aprendizado em Large Language Models (LLMs) permite aproveitar o conhecimento adquirido durante o treinamento em tarefas específicas (Devlin et al., 2019). Os LLMs pré-treinados podem ser ajustados para tarefas específicas, resultando em economia de tempo, recursos computacionais e dados de treinamento.

Essa abordagem é vantajosa devido ao pré-treinamento em um corpus extenso, que proporciona aos modelos uma compreensão profunda da linguagem

natural, incluindo informações sobre sintaxe, semântica e conhecimento factual (Devlin et al., 2019).

Ao aplicar a transferência de aprendizado, os LLMs podem ser adaptados para diversas tarefas, como classificação de sentimentos ou identificação de entidades nomeadas. Durante o fine-tuning, o modelo é treinado em um conjunto de dados anotado para aprender a relação entre as entradas e as saídas desejadas da tarefa específica (Devlin et al., 2019).

Estudos demonstraram a eficácia da transferência de aprendizado em LLMs, evidenciando que modelos pré-treinados em grandes corpora de texto podem ser ajustados para uma ampla gama de tarefas, obtendo resultados competitivos ou até superiores aos métodos tradicionais (Radford et al., 2018).

No entanto, a transferência de aprendizado em LLMs apresenta desafios. A escolha adequada do conjunto de dados para o fine-tuning é essencial para capturar as nuances da tarefa específica (Devlin et al., 2019).

Além disso, questões relacionadas à transferência de viés devem ser consideradas, uma vez que os LLMs podem absorver preconceitos presentes nos dados de treinamento e amplificá-los durante a geração de texto ou a execução de tarefas.

2.1.3 Aplicações e Impacto dos LLMs

Os LLMs têm uma ampla gama de aplicações no processamento de linguagem natural. Eles são utilizados para tarefas como tradução automática, geração de texto, resumo automático, resposta a perguntas, correção gramatical e muito mais. Além disso, os LLMs também encontram aplicação em outras áreas, como suporte ao cliente automatizado, criação de chatbots e assistentes virtuais. Esses modelos têm o potencial de melhorar a eficiência e a qualidade das interações humanas com a tecnologia, impulsionando a automação e a personalização.

O impacto dos LLMs em diversas aplicações de processamento de linguagem natural é discutido por Radford et al. (2018). Esses modelos melhoram a qualidade da tradução automática, sistemas de pergunta-resposta, resumos automáticos e outros. "Large Language Models têm demonstrado impacto significativo em várias aplicações de processamento de linguagem natural." (Radford et al., 2018)

2.2 Prompt engineering (Engenharia de Prompt)

A engenharia de prompts é um novo campo na inteligência artificial que se concentra no design de prompts que podem ser usados para orientar grandes modelos de linguagem (LLMs) a gerar resultados desejados. Prompts são pequenos trechos de texto que fornecem instruções ou orientações ao LLM. Eles podem ser usados para controlar o conteúdo, estilo e formato da saída do LLM.

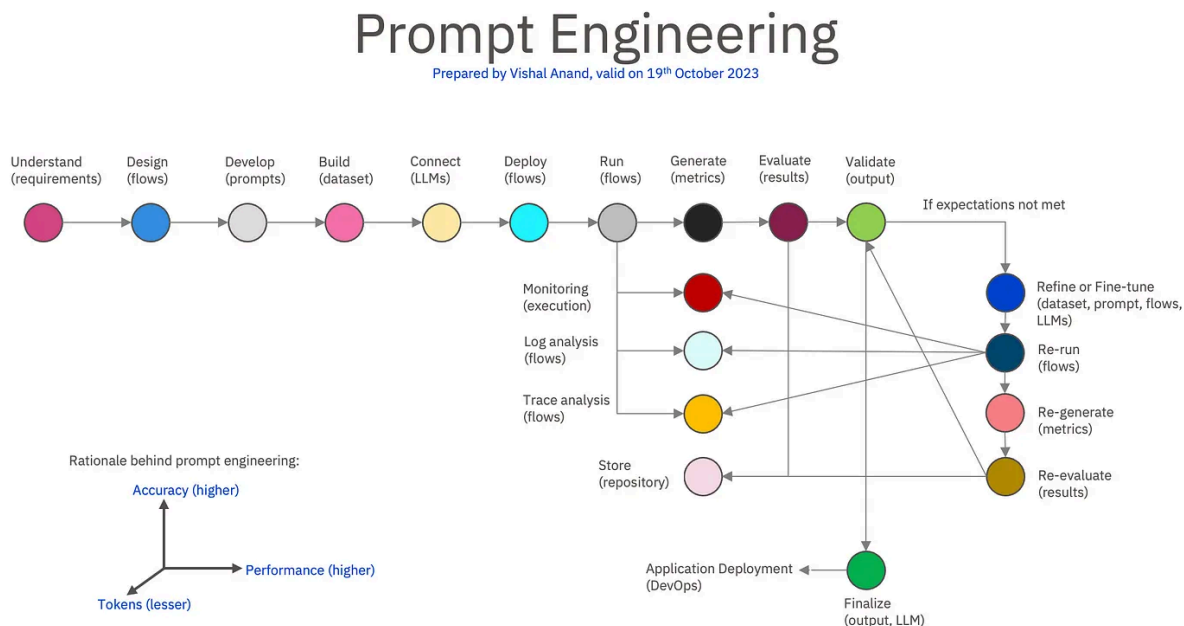
A engenharia de prompts tem o potencial de revolucionar a forma com a qual se interage com a IA. Ao criar prompts cuidadosamente, pode-se tornar os LLMs mais úteis e versáteis. Por exemplo, é possível usar prompts para ensinar LLMs a escrever diferentes tipos de formatos de texto criativo, como poemas, código, roteiros, peças musicais, e-mails, cartas, etc. Também possibilita o uso de prompts para melhorar a precisão e confiabilidade dos LLMs em tarefas como tradução de idiomas, análise de sentimentos e resposta a perguntas.

A engenharia de prompts funciona aproveitando o fato de que os LLMs são treinados em conjuntos massivos de dados de texto e código. Esses conjuntos de dados contêm exemplos de como os seres humanos usam a linguagem para alcançar diferentes objetivos. Ao fornecer um prompt que seja similar a um exemplo no conjunto de dados, é possível ajudar o LLM a gerar uma saída semelhante.

Por exemplo, se for necessário ensinar um LLM a escrever um poema, há a possibilidade de fornecer um prompt que inclua algumas linhas de um poema, juntamente com algumas instruções sobre o estilo e conteúdo do poema. O LLM, então, usaria o prompt para gerar um novo poema que seja similar ao poema exemplo.

A engenharia de prompts tem sido amplamente aplicada com resultados impressionantes em diversas tarefas. Por exemplo, (LeewayHertz, 2022) demonstrou que a utilização de prompts mostrou-se eficaz na melhoria da precisão de LLMs em tarefas de tradução de idiomas. Além disso, em uma abordagem inovadora (Zapier, 2022), prompts foram empregados para capacitar LLMs a responder perguntas de forma abrangente e informativa. Essas contribuições destacam a importância e o potencial da engenharia de prompts na otimização do desempenho de modelos de linguagem.

Figura 2 – Diagrama de Prompt engineering (Engenharia de Prompt).



Fonte: Vishal Anand (2023)

Na Figura 2, está uma representação do Core Diagram, o diagrama é uma representação sintética que visa oferecer uma visão abrangente da engenharia de prompts, dirigida a um público diversificado, incluindo CTOs, Engenheiros de Prompt, Desenvolvedores de Aplicativos, entre outros. Esse diagrama destaca a personalização de prompts para atender às exigências específicas dos aplicativos, enfatizando sua flexibilidade e adaptabilidade. Importante ressaltar que não se trata de uma representação de tarefas sequenciais ou paralelas, nem visa ilustrar conceitos como shift-left ou shift-right, mas sim destaca a capacidade de flexibilidade na execução para alcançar resultados desejados.

Reconhece-se a natureza iterativa do processo, podendo necessitar de refinamentos ao longo do tempo para otimizar sua eficácia. Além disso, o diagrama enfatiza que a abordagem prática delineada é baseada nas capacidades de IA, oferecendo uma aplicação concreta dentro deste ecossistema. Em suma, o Core Diagram oferece uma perspectiva valiosa e prática da engenharia de prompts, sublinhando sua importância e potencial no contexto da inteligência artificial.

2.3 Advanced Prompt Engineering (Engenharia de Prompt Avançada)

A engenharia de prompt, um campo emergente na inteligência artificial, abre um leque de possibilidades para direcionar modelos de linguagem a gerar resultados específicos. Através da criação de prompts mais cuidadosamente elaborados, é possível moldar o conteúdo, estilo e formato da produção textual, expandindo as capacidades da IA e abrindo caminho para novas aplicações.

Nesta abordagem mais profunda, serão exploradas técnicas avançadas de engenharia de prompt, indo além dos conceitos básicos e desvendando as ferramentas que permitem um controle mais preciso e sofisticado sobre a geração de texto.

2.3.1 Refinando a Geração com Maior Precisão

- Prompting Hierárquico: Uma estrutura multicamadas para o prompt, refinando progressivamente a geração e permitindo maior controle sobre diferentes aspectos do texto final (Lo et al., Findings 2023).
- Prompting com Controle de Fluxo: A capacidade de direcionar o fluxo da narrativa, definindo pontos de virada, introduzindo novos elementos e controlando o ritmo da história (Beurer-Kellner et al., 2023).
- Prompting com Injeção de Conhecimento: Integração de conhecimento específico no prompt, como termos técnicos, vocabulário especializado ou informações sobre um determinado tema (Zhang et al., 2023).

2.3.2 Adaptando-se ao Contexto e Personalizando a Experiência

- Prompting com Personalização de Estilo: A geração de textos com estilos específicos, desde formal e informativo até humorístico e criativo (Liu, G. et al., 2021).
- Prompting com Adaptação ao Contexto: A inclusão de informações contextuais relevantes no prompt para gerar textos mais coerentes e relevantes à conversa em curso (Devlin et al., 2019).

2.3.3 Meta-Aprendizado e Transferência de Aprendizado

- Prompting com Meta-Aprendizado: Treinamento de um modelo para aprender como gerar prompts eficazes para diferentes tarefas (Ha et al., 2023)
- Prompting com Transferência de Aprendizado: Utilização de prompts treinados em uma tarefa para melhorar o desempenho em outra (Su et al., 2022)

2.3.4 Potencial Transformativo

A engenharia de prompt avançada possibilita um cenário onde a LLM se torna ainda mais versátil e poderosa. As aplicações abrangem:

- Geração de Conteúdo Multimodal: Criação de textos, imagens, músicas e outros tipos de conteúdo com prompts, abrindo caminho para experiências interativas e imersivas (Guinness et al., 2022).
- Diálogo Aberto e Realista: Desenvolvimento de sistemas de conversação que podem manter diálogos abertos e realistas com humanos (Lu, H. et al., 2023).
- Auxílio na Escrita Criativa: Geração de ideias, sugestões de roteiros e desenvolvimento de personagens para autores (Chen & Ding, Findings 2023).

A engenharia de prompt avançada é uma ferramenta poderosa que redefine a maneira como interagimos com o modelo de linguagem. Através de técnicas personalizadas, é possível moldar a geração de texto com maior precisão e versatilidade. O uso de tais técnicas amplia as possibilidades de geração de novos resultados, impulsionando a criatividade e abrindo caminho para inovações em diversas áreas.

2.4 Fine-Tuning

O desenvolvimento e aprimoramento de modelos de aprendizado de máquina têm desempenhado um papel significativo em diversas áreas, como processamento de linguagem natural, visão computacional e reconhecimento de padrões. Tradicionalmente, treinar esses modelos do zero requer um grande conjunto de dados e poder computacional considerável. No entanto, com o advento do pré-treinamento de modelos em larga escala, como o BERT (Devlin et al., 2018) e o

GPT (Radford et al., 2018), tornou-se possível aproveitar o conhecimento prévio desses modelos por meio do fine-tuning.

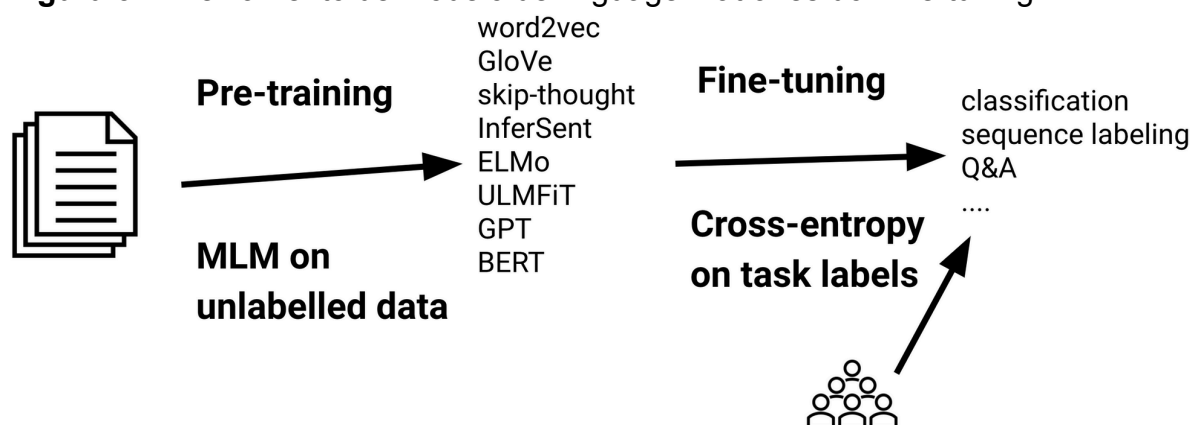
O fine-tuning é uma técnica que envolve ajustar um modelo pré-treinado em uma tarefa específica. Esse processo ocorre em duas etapas principais: pré-treinamento e fine-tuning. No pré-treinamento, um modelo é treinado em grandes quantidades de dados não rotulados, aprendendo representações gerais de alto nível. Em seguida, durante o fine-tuning, o modelo pré-treinado é adaptado a uma tarefa específica com um conjunto menor de dados rotulados.

Durante o fine-tuning, as camadas finais do modelo pré-treinado são substituídas ou modificadas para se adequarem à nova tarefa. Em seguida, os pesos dessas camadas são atualizados usando um algoritmo de otimização, como o gradiente descendente estocástico (Bottou, 2010; Ruder, 2016). A taxa de aprendizado, o tamanho do lote e outros hiperparâmetros também são ajustados durante esse processo para melhorar o desempenho do modelo na nova tarefa (Kingma & Ba, 2014).

Para implementar o fine-tuning, é necessário ter acesso a um modelo pré-treinado, que pode ser obtido a partir de arquiteturas amplamente utilizadas, como o BERT, GPT, ResNet (He et al., 2016), entre outros. Em seguida, o conjunto de dados rotulados específico da tarefa é utilizado para adaptar o modelo pré-treinado. É importante destacar que o tamanho do conjunto de dados para fine-tuning geralmente é menor do que o utilizado no pré-treinamento.

Ainda durante o fine-tuning, é possível congelar algumas camadas iniciais do modelo pré-treinado para manter as representações aprendidas previamente e evitar uma adaptação excessiva aos dados de treinamento da nova tarefa. Essa estratégia, conhecida como transferência de aprendizado, permite que o modelo aproveite o conhecimento prévio para melhorar sua performance em uma nova tarefa (Pan & Yang, 2010).

Figura 3 – Treinamento de modelo de linguagem através do Fine-tuning.



Fonte: Sebastian Ruder (2019)

O fine-tuning tem sido amplamente utilizado em diversos domínios, com resultados promissores. Em processamento de linguagem natural, por exemplo, o BERT tem sido ajustado através do uso do fine-tuning para tarefas como classificação de sentimento, reconhecimento de entidades nomeadas e resposta a perguntas (Devlin et al., 2018). Na visão computacional, modelos pré-treinados como o ResNet têm sido adaptados para classificação de imagens, detecção de objetos e segmentação semântica (He et al., 2016). Os resultados alcançados por meio do fine-tuning demonstram a eficácia dessa abordagem em diferentes contextos.

O fine-tuning de modelos pré-treinados tem se mostrado uma estratégia efetiva para aproveitar o conhecimento prévio em tarefas específicas de aprendizado de máquina. Essa técnica oferece uma maneira eficiente de utilizar modelos pré-treinados em larga escala, como o BERT e o GPT, e adaptá-los para aplicações diversas (Devlin et al., 2018; Radford et al., 2018). Com a combinação do pré-treinamento e do fine-tuning, é possível obter resultados impressionantes em diversas tarefas, com menor necessidade de dados rotulados e tempo computacional. O fine-tuning continua sendo um campo de pesquisa ativo, com novos avanços e aplicações em constante desenvolvimento.

2.5 RPG (Role-playing game)

Desde sua criação na década de 1970, o RPG de Mesa tem se mostrado uma forma única e envolvente de entretenimento interativo. Também conhecido como

"jogo de mesa" ou "jogo de role-playing", o RPG de Mesa permite que os participantes assumam o papel de personagens fictícios e embarque em aventuras emocionantes. O jogo é baseado na colaboração e na imaginação compartilhada, proporcionando aos jogadores a oportunidade de explorar mundos fictícios, interagir com outros personagens e tomar decisões que afetam o desenrolar da história.

O RPG de Mesa teve suas origens no jogo de tabuleiro "Dungeons & Dragons" (D&D), criado por Gary Gygax e Dave Arneson em 1974 (Gygax & Arneson, 1974). D&D foi o primeiro jogo a introduzir a ideia de um mestre do jogo (também chamado de "mestre" ou "game master") que assume o papel de narrador e controla o cenário, personagens não jogadores e eventos do jogo. Desde então, uma ampla variedade de sistemas de RPG de Mesa foi desenvolvida, abrangendo diferentes gêneros, ambientações e regras.

O RPG de Mesa possui características distintas que o diferenciam de outros tipos de jogos. Uma das principais características é a ênfase na narrativa e na interpretação de papéis. Os jogadores criam personagens com características e habilidades únicas, e são encorajados a tomar decisões com base na personalidade e objetivos desses personagens. Além disso, o RPG de Mesa utiliza dados de múltiplas faces (como dados de seis lados, o famoso "D6") para determinar os resultados das ações dos jogadores, introduzindo elementos de aleatoriedade e estratégia.

Estudos têm sugerido que o RPG de Mesa pode ter um impacto positivo no desenvolvimento pessoal e social dos jogadores. Ao interpretar personagens e enfrentar desafios no jogo, os participantes podem desenvolver habilidades de comunicação, colaboração, resolução de problemas e pensamento crítico (Bowman, 2010). Além disso, o RPG de Mesa pode proporcionar um ambiente seguro para explorar questões emocionais e sociais, permitindo que os jogadores experimentem diferentes perspectivas e desenvolvam empatia (Randi & Carvalho, 2013).

O RPG de Mesa tem sido utilizado como uma ferramenta educacional em várias áreas do conhecimento, incluindo história, literatura, matemática e desenvolvimento de habilidades linguísticas (Randi & Carvalho, 2013). Ao incorporar elementos educacionais em aventuras e enredos, os educadores podem engajar os alunos de forma lúdica e estimulante. Além disso, o RPG de Mesa tem sido explorado como uma terapia complementar, ajudando indivíduos a lidar com

problemas emocionais, desenvolver habilidades sociais e promover a resiliência (Hawkes-Robinson, 2008).

Os LLMs têm o potencial de ser uma ferramenta valiosa para RPGs de mesa. Eles podem ser usados para gerar diálogos realistas e envolventes para personagens não-jogadores, criar mundos detalhados e imersivos e ajudar os jogadores a resolver problemas complexos. Além disso, os LLMs podem ser usados para criar aventuras e histórias personalizadas, adaptadas aos interesses individuais de cada jogador.

2.6 Trabalhos Relacionados

Nesta seção, serão apresentados trabalhos que possuem relação e similaridade com o trabalho proposto neste documento. Durante a pesquisa realizada, foram analisadas aplicações similares cujo objetivo era compreender de maneira mais ampla a aplicação de LLMs em RPGs de mesa e de como uma LLM poderia ser utilizada para assumir o papel de um mestre.

2.6.1 Towards Computational Support with Language Models for TTRPG Game Masters.

No ano de 2023, Jack Kelly, Michael Mateas e Noah Wardrip-Fruin abordaram o potencial dos modelos de linguagem para fornecer suporte computacional aos Mestres de Jogo em jogos de RPG de mesa (Kelly et al., 2023). Eles exploraram a utilização de grandes modelos de linguagem (LLMs) para oferecer sugestões de diálogo para personagens não jogadores e destacar informações relevantes do módulo de jogo, a fim de auxiliar nas necessidades de improvisação durante a partida. Baseando-se no Shoelace, um assistente computacional para a estrutura de role-playing GUMSHOE One-2-One, eles estenderam o Shoelace usando GPT-3 para fornecer sugestões de diálogo para personagens não-jogadores, bem como para destacar informações relevantes do módulo do jogo.

O artigo inicia discutindo os desafios de ser um mestre de jogo, como a necessidade de ser criativo, acompanhar um mundo de jogo complexo e responder a ações inesperadas dos jogadores. Jack Kelly, Michael Mateas e Noah Wardrip-Fruin argumentam que os LLMs podem ser utilizados para enfrentar alguns desses

desafios. Por exemplo, os LLMs podem gerar diálogos para personagens não jogadores, fornecer resumos do mundo do jogo e sugerir soluções criativas para os problemas dos jogadores.

O artigo apresenta, então, um sistema protótipo que utiliza o GPT-3 para fornecer suporte computacional aos mestres de jogo. O sistema é avaliado em um estudo com usuários, e os resultados sugerem que ele é capaz de gerar texto criativo e envolvente.

O artigo conclui discutindo as limitações do sistema atual e o potencial para trabalhos futuros. Os autores sugerem que trabalhos futuros podem se concentrar em aprimorar a precisão do sistema, torná-lo mais amigável aos usuários e expandi-lo para oferecer suporte a outros tipos de jogos de interpretação de papéis de mesa.

2.6.2 Chat Reincarnation: The Case of My Childhood Girl Friend Who Was Supposed to be Dead Becoming a Hero in Another World

Em 2023, Takayuki Fukatsu (Fukatsu, 2023) descreveu um RPG Isekai baseado em chat que utiliza o GPT-4 como mestre de jogo. O jogador insere suas ações, e o GPT-4 gera texto descrevendo os resultados dessas ações. O artigo discute os desafios de usar LLMs para RPGs de mesa, como a necessidade de uma engenharia de prompt cuidadosa e a dificuldade de gerar texto que seja simultaneamente criativo e consistente com o mundo do jogo.

O artigo começa discutindo o gênero Isekai de animes e mangás, que apresenta personagens transportados para outro mundo. Fukatsu argumenta que LLMs podem ser usados para criar RPGs Isekai que sejam mais imersivos e envolventes do que os RPGs de mesa tradicionais.

Após isso é então apresentado um sistema protótipo que utiliza o GPT-4 para criar um RPG Isekai baseado em chat. O sistema é avaliado em um estudo com usuários, e os resultados sugerem que ele é capaz de gerar texto que seja ao mesmo tempo criativo e envolvente.

O artigo conclui discutindo as limitações do sistema atual e o potencial para trabalhos futuros. Fukatsu sugere que trabalhos futuros possam se concentrar em melhorar a precisão do sistema, torná-lo mais amigável ao usuário e expandi-lo para suportar outros tipos de jogos de interpretação de papéis de mesa.

2.6.3 AI Dungeon

Em 2019, Nick Walton e Josh Wardle (Walton e Wardle, 2019) criaram o AI Dungeon, um jogo de aventura baseado em texto que utiliza inteligência artificial para gerar conteúdo. Os jogadores podem criar suas próprias aventuras ou jogar aventuras pré-criadas. O jogo é alimentado pelo GPT-3, um grande modelo de linguagem desenvolvido pela OpenAI.

O AI Dungeon tem sido elogiado por sua criatividade e sua capacidade de gerar textos realistas e envolventes. No entanto, o jogo também tem sido criticado por sua capacidade de gerar conteúdo prejudicial ou ofensivo. Em 2021, a Latitude, a empresa proprietária do AI Dungeon, implementou uma série de mudanças no jogo na tentativa de abordar essas preocupações. A empresa está empenhada em encontrar um equilíbrio entre a liberdade criativa do jogo e a necessidade de garantir que o conteúdo gerado seja apropriado e seguro para todos os jogadores.

Apesar desses desafios, o AI Dungeon continua sendo um jogo popular com milhões de usuários. O jogo tem sido elogiado por seu potencial de ser usado para fins educacionais e terapêuticos.

2.7 Considerações Finais

Neste capítulo foram abordadas as áreas que possuem uma conexão com a abordagem central deste trabalho, além de ter sido fornecida a base teórica indispensável para a compreensão aprofundada do próximo capítulo. Neste último, será desenvolvido de forma detalhada e exposta a metodologia empregada no desenvolvimento do modelo proposto para este trabalho. Ao longo da revisão bibliográfica, foram discutidos de maneira abrangente os principais temas relacionados às LLMs (Language Models), incluindo seu funcionamento e relevância, a importância da Prompt Engineering e algumas de suas técnicas avançadas, o processo de Fine-tuning e sua aplicabilidade, bem como o contexto do RPG e a contribuição que as LLMs podem fazer para este campo.

Por fim, foi apresentado resumos de alguns trabalhos que possuem conexão com a proposta deste trabalho, onde cada um dos trabalhos citados faz o uso direto de LLMs com a finalidade de auxiliar ou executar jogos de RPG de mesa com a própria LLM.

3 METODOLOGIA

Neste capítulo, será apresentada a metodologia adotada para a realização do trabalho. Esta seção abrange todas as etapas necessárias, desde o desenvolvimento do banco de dados até o processo de limpeza dos dados e o procedimento de fine-tuning do modelo de linguagem. Além disso, será abordado o processo de fine-tuning do modelo de linguagem, com o objetivo de adaptá-lo para a função de auxiliar um Mestre de RPG, assim como a criação de Chatbot criado a partir de um modelo de linguagem que desempenha a função de um mestre de RPG. Por fim, descreveremos as estratégias de avaliação do modelo e a análise dos resultados obtidos.

3.1 Coleta de dados e desenvolvimento dos Bancos de Dados (BD)

A coleta de dados e o desenvolvimento de bases de dados são etapas fundamentais para o treinamento do modelo de linguagem voltado para a função de Mestre de RPG. Nesta etapa, foram coletados dados relevantes para a construção das bases de dados, incluindo descrições de personagens e resumos de narrativas de sessões de jogo de RPG, e dados para o chatbot, como as regras do sistema Candela Obscura (Jaffe & Lockey, 2023). Fontes confiáveis, como sites de referência, como o RPG Geek (RPG Geek, 2024) e o D&D Beyond (Wizards of the Coast, 2020), foram exploradas para validar as informações contidas nas bases de dados.

Durante a fase inicial de importação de bibliotecas, o código estabelece o ambiente de execução ao importar as bibliotecas fundamentais para o script. Estas incluem a biblioteca 'os', para funcionalidades relacionadas ao sistema operacional, 'openai', para interação com a API OpenAI, 'pandas', para manipulação de dados em formato tabular, e 'time', para controle do intervalo de espera entre as solicitações à API. Em seguida, na etapa de configuração da chave da API OpenAI, é definida uma chave de acesso para autenticar as solicitações enviadas à plataforma, assegurando que apenas usuários autorizados possam utilizar seus serviços.

Posteriormente, para a base de dados que tem como objetivo criar resumos de narrações de RPG, foi feita a definição das listas de temas, ambientes, níveis de

dificuldade e problemáticas. Já para a base de dados que tem como objetivo criar a descrição de Personagens Não-Jogadores, é realizada a definição das listas de idades, gêneros e traços de personalidade. São criadas estruturas de dados contendo estes valores nas diferentes bases de dados, os quais são utilizados para gerar os prompts de solicitação. Essas listas formam a base para a criação de combinações que serão empregadas na solicitação à API para a geração de resumos de aventuras de RPG de mesa e descrições de NPCs de RPG de Mesa.

Como abordado anteriormente, para este trabalho, foram desenvolvidas duas bases de dados adequadas para o Fine-Tuning desses modelos de linguagem utilizando a API da OpenAI. Foram empregadas duas abordagens distintas para a geração de dados:

Tabela 1: Objetivos e desenvolvimento das bases de dados.

Objetivo da Base de dados	Descrição	Prompt utilizado
Resumos de Aventuras de RPG de Mesa	Preparar aventuras de RPG de mesa resumidas e com diferentes temas, ambientes, níveis de dificuldade e problemáticas. Esses resumos tem como objetivo gerar uma variedade de contextos narrativos e desafios.	"Crie um resumo de uma aventura de RPG de mesa com tema {tema}, ambientada em um ambiente {ambiente}, com nível de dificuldade {dificuldade}. A grande problemática é {problematica}. Escreva o resumo em até 300 palavras com muitos detalhes."
Descrições de NPCs de RPG de Mesa	Criar descrições detalhadas de Personagens Não-Jogadores (NPCs) para uma ambientação de RPG de mesa, considerando diferentes idades, gêneros e traços de personalidade.	"Crie uma descrição detalhada de um NPC de {idade} anos de idade, {gênero}, conhecido por sua {traço} em um mundo fantasioso. Escreva a descrição em até 100 palavras com muitos detalhes:"

Fonte: Próprio autor com base nos dados de desenvolvimento.

Durante a etapa do Loop de Geração de Resumos, o código opera iterando sobre todas as combinações possíveis de temas, ambientes, níveis de dificuldade e problemáticas, bem como de idades, gêneros e traços de personalidade para a outra base de dados. Para cada combinação, um prompt específico é gerado e enviado para a API OpenAI, solicitando a geração de um resumo ou uma descrição de um NPC, dependendo do código em questão. No caso da geração de resumos, o objetivo é criar resumos de até 300 palavras para aventuras de RPG de mesa, enquanto na geração de descrições de NPCs, o objetivo é criar descrições detalhadas de NPCs com até 100 palavras, ambientados em um mundo medieval.

Após cada solicitação à API, ambos os códigos incluem um intervalo de espera de 20 segundos, antes de prosseguir, com o intuito de evitar ultrapassar as taxas de solicitação estabelecidas pela API.

Os dados apresentados referem-se à quantidade de entradas geradas para duas bases de dados distintas voltadas para jogos de RPG de mesa. No caso dos resumos de aventuras de RPG, as entradas são geradas para cada combinação possível de temas, ambientes, níveis de dificuldade e problemáticas. Por outro lado, as descrições de NPCs (Personagens Não Jogáveis) consistem em entradas geradas para cada combinação de idade, gênero e traço de personalidade dos personagens.

Tabela 2: Bases de dados.

Base de Dados	Número de Entradas
Resumos de Aventuras de RPG	360
Descrições de NPCs de RPG de Mesa	140

Fonte: Próprio autor com base nos dados de desenvolvimento.

Após a conclusão das etapas de geração de resumos e descrições de NPCs, os dados resultantes são armazenados em DataFrames do pandas. Cada linha desses DataFrames corresponde a um único resumo ou descrição gerada, e na linha seguinte são registrados detalhes como tema, ambiente, nível de dificuldade, problemática (para os resumos) e idade, gênero, traço (para as descrições de NPCs).

Essa associação de dados permite uma organização estruturada e categorizada dos resultados, facilitando análises posteriores e garantindo a rastreabilidade das informações geradas. É importante ressaltar que durante o processo de geração, o texto de entrada é tokenizado automaticamente pela infraestrutura da OpenAI antes de ser processado pelo modelo de linguagem. Em seguida, os DataFrames são exportados para arquivos CSV utilizando o método `to_csv` do pandas. No caso do código relacionado à geração de resumos de aventuras de RPG de mesa, o arquivo de saída é denominado "out_openai_adventure.csv", enquanto para o código de geração de descrições de NPCs, o arquivo de saída é denominado "out_openai_npc.csv".

Tabela 3: Exemplos de instâncias e resultados das bases de dados.

Base de dados	Detalhes da Instância	Prompt gerado	Resultado
out_openai_adventure.csv	Fantasia Épica, Urbano, Normal, Acontecimento	"Crie um resumo de uma aventura de RPG de mesa com tema Fantasia Épica, ambientada em um ambiente Urbano, com o nível de dificuldade Normal. A grande problemática é um Acontecimento. Escreva o resumo em até 300 palavras com muitos detalhes:"	O cenário desta aventura de RPG de mesa é uma cidade grande e urbanizada, com suas ruas repletas de magia e de mistérios. A grande problemática da aventura é um Acontecimento misterioso que começou a assolar a cidade, ameaçando transformá-la em um caos sem precedentes. Nossos heróis serão representados por personagens jogáveis que deverão descobrir a origem do caos. Para isso, eles deverão cruzar o ambiente urbano à procura de pistas: investigar bairros, interagir com estranhos e perigosos semideuses, visitar calabouços misteriosos e procurar ajuda entre guildas de aventureiros e guildas de magos. Durante esta aventura, os aventureiros serão confrontados por vilões diversos. Desde gárgulas e demônios guardiões dos calabouços, até perigosos bandidos armados e mestres secretos do crime. Uma vez descoberta a fonte da magia sombria, os aventureiros deverão enfrentar o mal em sua forma mais pura e, finalmente, refundar a cidade em paz. A menos que a própria cidade seja absorvida pelas trevas antes mesmo que nosso grupo tenha tempo de se aperceber do mal que assolava o local.
out_openai_npc.csv	18, mulher, medrosa	"Crie uma descrição detalhada de um NPC de 18 anos de idade, mulher, conhecida por ser medrosa em um mundo fantasioso. Escreva a descrição em até 100 palavras com muitos detalhes:"	Hanna é uma jovem de 18 anos, mulher de tez atlética e pele clara. Ela tem cabelos escuros, amarrados em um rabo de cavalo, e olhos azuis-acinzentados que vão mudando conforme a luz muda. Ela é muito medrosa de natureza, sendo frequentemente dominada por seu medo de desconhecidos e novidades. Ela adora prospectar o mundo ao seu redor, mas sempre em um contexto seguro. Ela é muito atenta a detalhes e observa tudo com uma atenção meticulosa, prestando atenção no menor ruído ou movimento. Ela tem um círculo grande de amigos, mas evita ficar em locais muito cheios. Seu estilo de vestimenta varia entre rendas delicadas, tons naturais e pequenas jóias brilhantes. Ela evita movimentos e sons intensos, prefere sempre se manter em recintos abertos. Ela é gentil, doce e amigável, sempre pronta para ajudar aqueles que precisam.

Fonte: Próprio autor com base nos dados de desenvolvimento.

Após a coleta dos dados, foi conduzido um processo de limpeza para assegurar a qualidade dos dados que foram utilizados no treinamento do modelo de linguagem durante o Fine Tuning. Essa etapa consistiu na remoção e correção de erros gramaticais, normalização de termos e eliminação de dados duplicados como descrições redundantes ou que não faziam sentido para o contexto dos dados.

3.2 Fine-tuning dos Modelos de Linguagem

O processo de fine-tuning se mostrou essencial ao personalizar os modelos de linguagem para as tarefas específicas de geração de resumos de Aventuras de RPG de Mesa e descrições de NPCs de RPG de Mesa. Ao longo desta etapa crucial, detalharemos minuciosamente como o fine-tuning foi realizado utilizando a API da OpenAI, explicando seu funcionamento e sua importância. Os dados preparados anteriormente, voltados exclusivamente para essas finalidades, foram utilizados durante esse processo.

Inicialmente, o código carrega os arquivos CSV out_openai_adventure.csv e out_openai_npc.csv, contendo os dados preparados para a geração de resumos de

aventuras de RPG de mesa e descrições de NPCs de RPG de mesa, respectivamente. De acordo com a OpenAI (2023), em seu guia sobre fine-tuning, esses dados são essenciais, pois representam exemplos de entrada (prompts) e as respostas esperadas, que são fundamentais para treinar o modelo GPT-3 a gerar resumos precisos e descrições autênticas. Esses exemplos são detalhados no Tabela 3, que apresenta instâncias e resultados das bases de dados, fornecendo uma visão clara do processo de treinamento.

Utilizando a biblioteca pandas, as colunas relevantes dos DataFrames são selecionadas e renomeadas para 'prompt' e 'completion', refletindo o prompt de entrada e a resposta esperada, respectivamente. Este passo serve para garantir que os dados estejam formatados corretamente para o próximo estágio do processo.

Em seguida, os dados preparados são armazenados em novos arquivos CSV, `prepared_data_adventure.csv` e `prepared_data_NPC.csv`, respectivamente, para as aventuras de RPG de mesa e descrições de NPCs de RPG de mesa. Isso garante que os dados estejam prontos para serem processados no próximo estágio.

Após a preparação dos dados nos arquivos CSV, o próximo passo foi converter esses dados para o formato JSONL, essencial para o processo de fine-tuning do modelo GPT-3. Essa conversão é realizada utilizando o comando `'openai fine_tunes.prepare_data'`, executado através de subprocessos. Durante a execução deste comando, os dados são verificados e processados para garantir que estejam formatados corretamente. O JSONL (JSON Lines) é um formato de arquivo que armazena cada objeto JSON em uma linha separada, sendo exigido para treinar o modelo GPT-3. Ele organiza os exemplos de entrada e saída de forma estruturada, o que facilita o processo de treinamento do modelo. Os arquivos JSONL resultantes, `'prepared_data_adventure_prepared.jsonl'` e `'prepared_data_prepared_NPC.jsonl'`, contém exemplos de entrada e saída no formato adequado, permitindo que o modelo aprenda a gerar resumos de aventuras de RPG de mesa e descrições de NPCs com base nesses dados preparados. Essa organização é crucial para garantir que o modelo possa interpretar corretamente os dados durante o processo de treinamento.

Por fim, o fine-tuning do modelo GPT-3 é iniciado utilizando a API da OpenAI. O comando `openai api fine_tunes.create` é executado, fornecendo como entrada os arquivos JSONL preparados anteriormente e selecionando o modelo GPT-3 adequado, ao qual para estes modelos, o modelo escolhido foi o `text-davinci-003`.

Além disso, um sufixo é atribuído ao nome do modelo ajustado, refletindo seu propósito específico, neste caso, "RPGAdventure" para resumos de aventuras de RPG de mesa e "NPCFantasy" para descrições de NPCs de RPG de mesa).

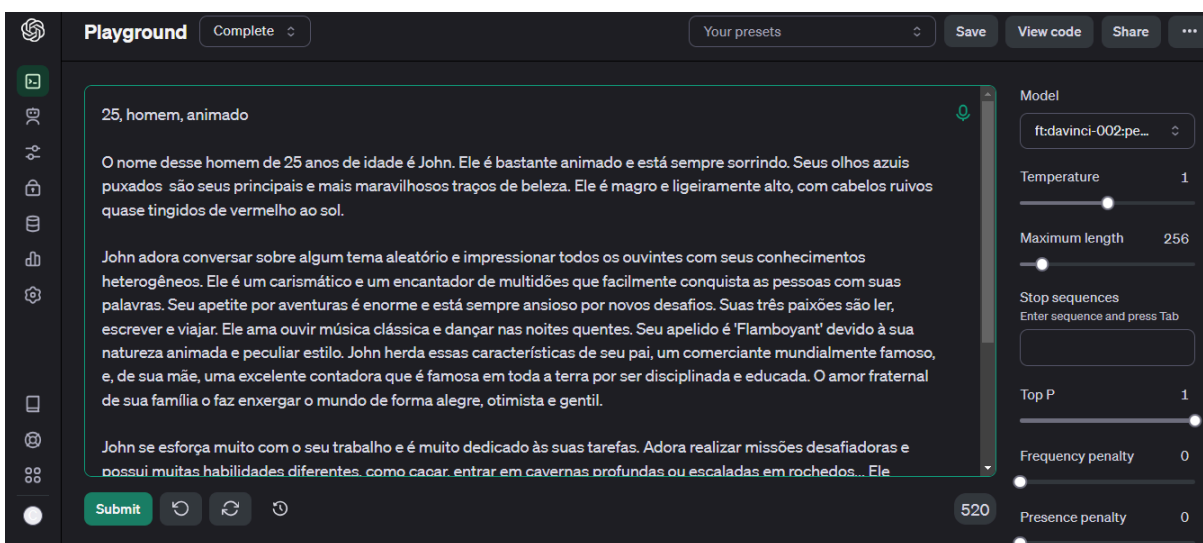
Tabela 4: Exemplos de dados contidos nos arquivos JSONL de cada base de dados.

Arquivo JSONL	Exemplo de dado
prepared_data_adventure.jsonl	<pre>{ "prompt": "Fantasia Épica, Urbano, Normal, Acontecimento", "completion": "\n\nO cenário desta aventura de RPG de mesa é uma cidade grande e urbanizada, com suas ruas repletas de magia e de mistérios. A grande problemática da aventura é um Acontecimento misterioso que começou a assolar a cidade, ameaçando transformá-la em um caos sem precedentes.\n\nNossos heróis serão representados por personagens jogáveis que deverão descobrir a origem do caos. Para isso, eles deverão cruzar o ambiente urbano à procura de pistas: investigar bairros, interagir com estranhos e perigosos semideuses, visitar calabouços misteriosos e procurar ajuda entre guildas de aventureiros e guildas de magos.\n\nDurante esta aventura, os aventureiros serão confrontados por vilões diversos. Desde gárgulas e demônios guardiões dos calabouços, até perigosos bandidos armados e mestres secretos do crime.\n\nUma vez descoberta a fonte da magia sombria, os aventureiros deverão enfrentar o mal em sua forma mais pura e, finalmente, refundar a cidade em paz. A menos que a própria cidade seja absorvida pelas trevas antes mesmo que nosso grupo tenha tempo de se aperceber do mal que assolava o local." }</pre>
prepared_data_NPC.jsonl	<pre>{ "prompt": "18, mulher, medroso", "completion": "\n\nHanna é uma jovem de 18 anos, mulher de tez atlética e pele clara. Ela tem cabelos escuros, amarrados em um rabo de cavalo, e olhos azuis-acinzentados que vão mudando conforme a luz muda. Ela é muito medrosa de natureza, sendo frequentemente dominada por seu medo de desconhecidos e novidades. Ela adora prospectar o mundo ao seu redor, mas sempre em um contexto seguro. Ela é muito atenta a detalhes e observa tudo com uma atenção meticulosa, prestando atenção no menor ruído ou movimento. Ela tem um círculo grande de amigos, mas evita ficar em locais muito cheios. Seu estilo de vestimenta varia entre rendas delicadas, tons naturais e pequenas jóias brilhantes. Ela evita movimentos e sons intensos, prefere sempre se manter em recintos abertos. Ela é gentil, doce e amigável, sempre pronta para ajudar aqueles que precisam." }</pre>

Fonte: Próprio autor com base nos dados de desenvolvimento.

Após a conclusão bem-sucedida deste processo, foram obtidos dois modelos GPT-3 ajustados, prontos para gerar resumos de aventuras de RPG de mesa e descrições de NPCs de RPG de mesa com base nos prompts fornecidos, atendendo às necessidades específicas deste contexto.

Figura 4 – Exemplo do uso do modelo treinado para Descrições de NPCs de RPG de Mesa, através do playground da plataforma da OpenAI.



Fonte: Plataforma da OpenAI retirado pelo autor.

É importante destacar que esses modelos ajustados são fundamentais para enriquecer a experiência dos jogadores de RPG, fornecendo narrativas e personagens autênticos para enriquecer o jogo, além de funcionarem como uma ferramenta para o mestre de RPG utilizar durante a narração. Este processo de fine-tuning é crucial para personalizar modelos de linguagem, tornando-os mais adequados para tarefas específicas.

3.3 Desenvolvimento de um Chatbot Mestre de RPG

A criação de um Chatbot Mestre de RPG foi uma etapa necessária para proporcionar uma experiência imersiva ao jogador durante um jogo de RPG mediada por um modelo de linguagem. O chatbot projetado tem como propósito desempenhar a função de um mestre de RPG durante a narração do jogo, interagindo com o jogador ao propor desafios e problemáticas e reagindo às suas decisões dentro do jogo. Esta abordagem buscou proporcionar uma experiência de jogo mais dinâmica e envolvente, permitindo ao jogador mergulhar no mundo fictício e tomar decisões que moldam o desenrolar da narrativa.

Além disso, a construção do Chatbot Mestre de RPG também foi baseada no uso dos fine-tunings criados para a geração de Resumos de Aventuras de RPG de

Mesa e para Descrições de NPCs de RPG de Mesa, assim como dados coletados sobre o sistema de RPG Candela Obscura (Jaffe & Lockey, 2023). Esses recursos foram utilizados para a roteirização do contexto das narrações e criação de regras, ao qual serve como base para as interações entre o jogador e o assistente virtual durante o jogo. Dessa forma, a construção do Game Master Chatbot se apoia não apenas na tecnologia de chatbot, mas também em técnicas de processamento de linguagem natural e em conceitos de narrativa de RPG.

A princípio, foram realizadas as importações das bibliotecas necessárias para o desenvolvimento do chatbot, incluindo o OpenAI para interagir com o modelo de linguagem GPT-3.5. Além disso, foram configuradas as credenciais de acesso à API do OpenAI a partir de variáveis de ambiente.

Logo após, foram definidas duas funções principais: ``get_completion`` e ``get_completion_from_messages``. A primeira função recebe um prompt (mensagem do usuário) e retorna a conclusão gerada pelo modelo de linguagem. Já a segunda função recebe uma lista de mensagens trocadas entre o usuário e o assistente, e retorna a conclusão gerada pelo modelo. Essas funções são essenciais para a interação entre o jogador e o Chatbot Mestre de RPG, permitindo que o assistente virtual gere respostas contextualizadas com base nas interações anteriores.

A interação do Chatbot com o jogador é gerenciada por uma função chamada ``collect_messages``. Esta função tem a responsabilidade de coletar as mensagens do usuário, interagir com o modelo de linguagem para gerar uma resposta e atualizar a interface do chat. Durante esse processo, as mensagens do usuário são adicionadas a uma lista chamada ``context``, que armazena o histórico das interações entre o jogador e o assistente ao longo do jogo. Quando uma nova interação ocorre, o contexto atual, representado pela lista ``context``, é passado como entrada para o modelo de linguagem nas funções ``get_completion`` ou ``get_completion_from_messages``. Dessa forma, o modelo considera o histórico de conversas para gerar uma resposta contextualizada, levando em conta as interações anteriores do jogador.

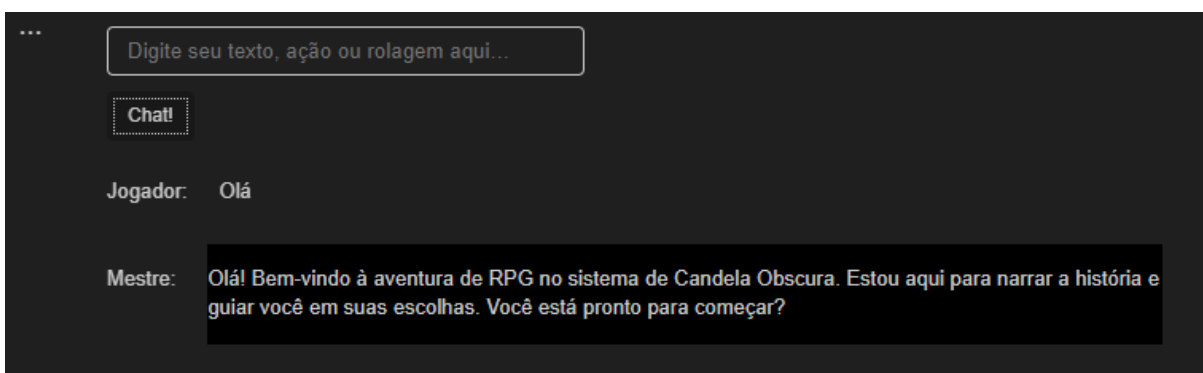
O código define um limite de 10000 caracteres para o tamanho da lista ``context``. Isso garante que o chatbot não fique sobrecarregado com informações desnecessárias e que a performance da conversa não seja prejudicada. Além disso, é importante destacar que a biblioteca OpenAI ChatCompletion é uma ferramenta poderosa para gerar respostas contextuais. No entanto, é fundamental fornecer a ela

um contexto preciso e relevante para que as respostas sejam satisfatórias e adequadas ao longo do jogo.

Ao final da implementação, foi preciso realizar a importação da biblioteca Panel, que oferece recursos para criar interfaces gráficas interativas em Python. Em seguida, a extensão do Panel foi realizada para garantir que todos os recursos necessários estejam disponíveis para a construção da interface do chatbot.

A configuração da interface Gráfica chat foi criada utilizando dois widgets principais: TextInput e Button. O TextInput permite que o usuário insira mensagens ou comandos, enquanto o Button inicia a interação com o chatbot quando clicado. Esses elementos são essenciais para facilitar a comunicação entre o jogador e o assistente virtual.

Figura 5 – Interface de chat do Game master Chatbot.

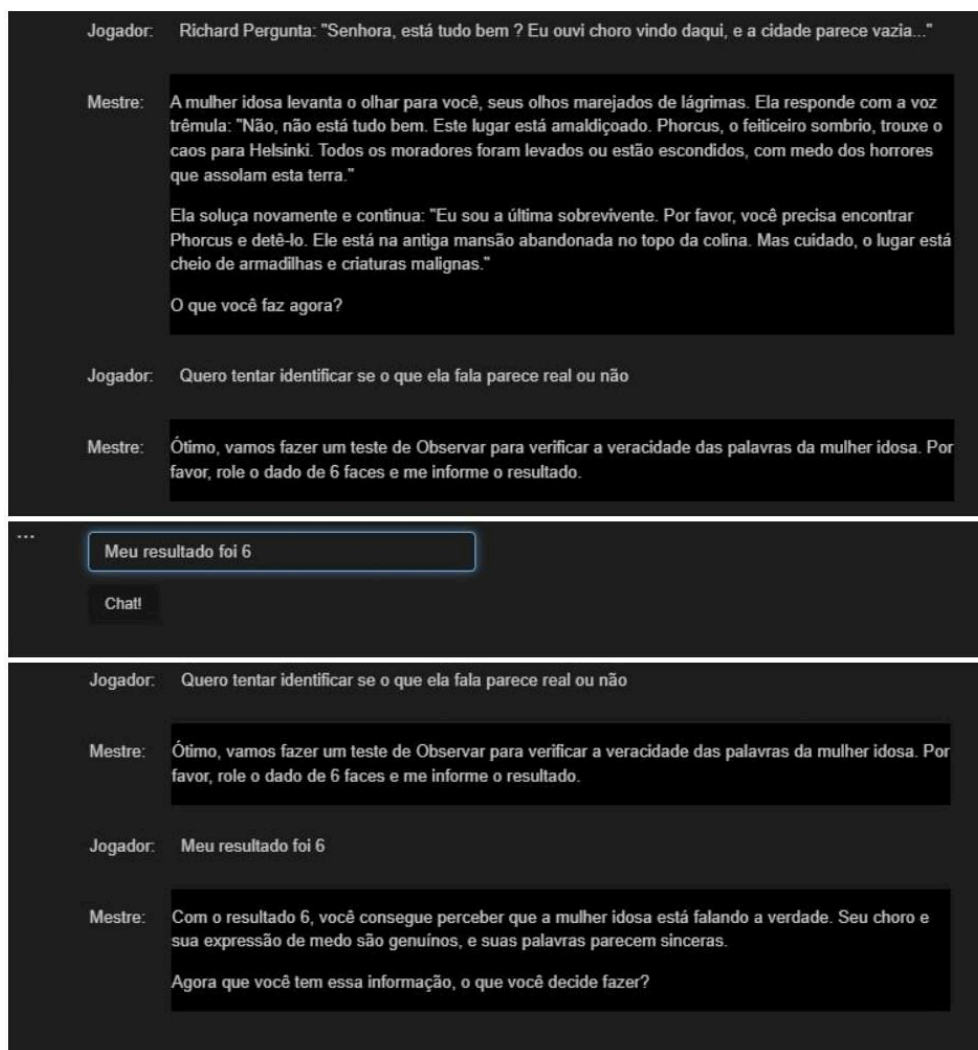


Fonte: Interface do Game master Chatbot retirado pelo autor.

Esta função `collect_messages` desempenha um importante papel na interação com o usuário e na geração de respostas do chatbot. Quando o botão de envio é clicado, a função `collect_messages` é acionada. Ela captura o texto digitado pelo usuário no TextInput, adiciona à lista de contexto e utiliza a função `get_completion_from_messages` para gerar uma resposta com base no contexto atual. A resposta gerada é então adicionada à lista de contexto e exibida na interface do chat.

Após cada interação entre o jogador e o assistente virtual, a interface gráfica é atualizada para exibir as mensagens trocadas. Isso garante uma experiência interativa e dinâmica para o usuário, pois ele pode acompanhar a conversa de forma contínua.

Figura 6 – Interação com o chat do Game master Chatbot.



Fonte: Interface do Game master Chatbot retirado pelo autor.

O contexto em que o chatbot foi preparado para se comportar durante a interação, foi construído e mantido na lista chamada context que foi anteriormente gerada. Com o uso de engenharia de prompt avançada essa lista também é responsável por armazenar as mensagens previamente estabelecidas, onde é descrito qual a maneira que o assistente deve agir e se comportar durante o jogo. Dessa forma, o chatbot pode gerar respostas contextualizadas com base nas interações previamente estabelecidas, proporcionando uma experiência mais personalizada e imersiva para o jogador.

Além da construção da interface e da lógica de interação, o chatbot é instruído a seguir uma sequência específica de passos durante a conversa. Isso inclui cumprimentar o jogador, apresentar as regras do jogo, oferecer opções de

personagens e garantir que o jogador esteja pronto para iniciar a aventura. Essas instruções garantem que a interação com o chatbot seja clara, coesa e orientada ao objetivo do jogo de RPG.

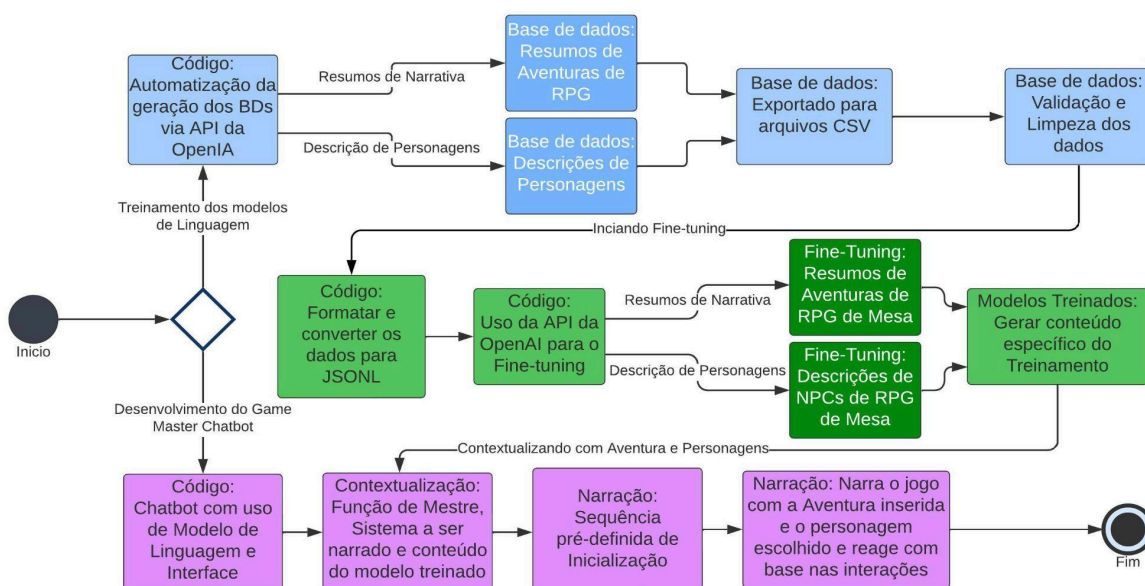
Tabela 5: Contexto utilizado para o Game Master Chatbot, separado em instruções.

Objetivo da Instrução	Texto Utilizado
Descrição do papel do Mestre de RPG	Você deve agir como um Mestre de RPG de mesa, você irá narrar uma aventura de RPG para o seu Usuário, na maior parte do tempo você deve apenas narrar a cena e esperar a atitude do usuário sobre como ele vai agir naquela situação, se em algum momento a ação dele for algo complexo, você deve solicitar a ele um teste de Ação, preciso que seja breve e direto em cada resposta sua. Você deverá provocar e confrontar o jogador durante o jogo, colocando ele em situações complexas, exigindo testes para só então definir quais os resultados de suas ações.
Descrição do sistema de Candela Obscura: Funcionamento das rolagens de dados	Você precisa saber como funciona o sistema de candela Obscura, onde para determinar o sucesso em alguma ação mais complexa o jogador deve rolar os dados de 6 faces que correspondem a aquela habilidade, em um resultado 1 o jogador terá uma falha crítica e deverá arcar com as consequências, nos resultados 2 ou 3 ele falhará e precisará arcar com as consequências, em um resultado 4 ou 5 ele terá um sucesso misto onde ele conseguirá o que quer realizar mas com uma consequência menor, e com o resultado 6 ele obtém um sucesso perfeito e sem consequências.
Descrição do sistema de Candela Obscura: Funcionamento dos tipos de ações.	Existem 9 tipos de ações, cada uma delas está disponível a seguir com uma breve descrição de algumas opções de seu funcionamento: Mover: Movimento físico para alcançar objetivos, como escalar, correr e saltar. Ataque: Aplicação da força física, como golpear, quebrar e abrir portas. Controle: Destreza e coordenação para tarefas como atirar, dirigir e manusear armas. Influenciar: Carisma e presença para persuadir, comandar e convencer outros. Observar: Percepção de detalhes e intenções, como identificar mentiras e comportamentos suspeitos. Esconder: Habilidade de furtividade e engano para passar despercebido e ocultar informações. Foco: Capacidade mental para analisar detalhes, lembrar informações e interpretar textos complexos. Sentir: Conexão com a magia para perceber e utilizar seus efeitos. Investigar: Consciência situacional e habilidade de reconhecer detalhes importantes no ambiente, útil para buscar pistas, seguir rastros, identificar saídas e encontrar pessoas em multidões. Quando um personagem tem 0 pontos numa habilidade, ele deve rolar dois dados de 6 faces e ficar com o pior resultado, quando ele tem 1 ponto ele rola 1 dado, quando ele tem 2 pontos ele rola 2 dados e fica com o melhor resultado, quando ele tem 3 pontos ele rola 3 dados e fica com o melhor resultado.
Descrição do sistema de Candela Obscura: Marcas dos personagens	Além das ações, cada personagem possui 3 "pontos de vida" em três categorias diferentes, estas são chamadas de marcas, sendo elas as seguintes: Corpo: Representa danos físicos – lacerações causadas por uma faca dentada, mordidas de uma criatura, ossos quebrados por uma queda. Mental: Representa tensão mental – exaustão por uma conversa intensa, ansiedade pelo medo de ser pego, estresse por um ataque de feras aterrorizantes. Corrupção: Representa a corrupção mágica – o toque arrepiante de um fantasma, o veneno de um monstro, a energia prejudicial irradiada de um artefato. Você deve atribuir o dano que o personagem recebeu de 0 a 3 após ele ser submético a alguma destas situações, tendo em vista que danos menores são mais comuns e danos maiores são muito incomuns e só ocorrem em situações extremas. Após ter os 3 pontos de alguma marca reduzida a zero, o personagem fica inconsciente, nesse momento você deve definir se ele ficará com um "cicatriz" ou se ele morre, essas cicatrizes podem ser do mais diverso tipo, seja perder um membro para Corpo, desenvolver um trauma para mental ou uma anomalia mágica e sobrenatural ocorre com o indivíduo para Corrupção. Você deve atribuir o dano que o personagem recebeu de 0 a 3 após ele ser submético a alguma destas situações, tendo em vista que danos menores são mais comuns e danos maiores são muito incomuns e demandam de situações extremas.
Instrução para Mestre do Sistema Candela Obscura: Quando solicitar e como funciona os testes de ação.	Constantemente em momentos que o jogador tiver que fazer alguma jogada que se encaixe na descrição de algum dos tipos de ação, você deve solicitar que ele faça um teste, neste teste ele deve rolar o dado e você deve pedir o resultado da rolagem para ele, após isso você deve julgar o resultado com base nas informações de resultado que lhe informei anteriormente, é de grande importância que você sempre solicite esses testes.
Instruções: Inicialização do jogador. (Obs: Os personagens aqui disponíveis foram feitos com o uso do modelo treinado com sufixo NPCFantasy)	Agora sim, primeiramente você deve cumprimentar o jogador e depois o informa que irá narrar uma aventura de RPG no sistema de Candela Obscura. Você espera a resposta, depois faz a pergunta a seguir. Apenas após ele cumprimenta-lo de volta, você deve perguntar se ele possui alguma dúvida sobre as regras. Você espera a resposta, depois faz a pergunta a seguir . Apenas após ele tirar as dúvidas você deve apresentar a opção de 2 personagens para o jogador escolher entre um deles: Richard (Mover 1, controle 2, Ataque 2, observar 1, Investigar 2, Foco 1): Richard é um homem de 60 anos, loiro e calvo com um pesado bigode. Seu corpo forte e musculoso reflete sua grande experiência como explorador consagrado durante toda sua vida. Heide (Mover 1, controle 2, Ataque 2, observar 1, Investigar 2, Foco 1): Heide é uma moça de 25 anos de idade, alta, magra, de cabelos esverdeados compridos, olhos escuros fascinantes e ovalados, pele clara com tons marmorizados. Você espera a resposta, depois faz a pergunta a seguir. Apenas após ele escolher o personagem você deve perguntar se ele já está pronto para começar a aventura. Você espera a resposta, depois faz a pergunta a seguir Apenas após ele confirmar que está pronto, o pergunte se existe algo que ele quer que seja abordado no jogo, e se existe algum tema sensível que ele não deseja que seja abordado, o informe que se ele estiver desconfortável com o jogo ele deve dizer "Alpaca dourada" e você irá parar a história.
Narrativa inicial da aventura	A narrativa que será narrada está disponível a seguir, nela você deve descrever para o jogador somente o que ele saberia naquele momento inicial, permitindo que ele descubra o restante à medida que o jogo avança. Certifique-se de manter uma boa qualidade gramatical em suas descrições. Narrativa (Atenção: Não diga o que vai acontecer ao jogador de início coloque ele apenas no início dessa narrativa): Os aventureiros se envolvem em uma ambientação um tanto sombria da qual não conseguem escapar. Eles chegam a um vilarejo distante. Imediatamente sentem o terror embriagado pela atmosfera infestada de assombrações e pesadelos. Os horrores que rondam o lugar parecem incluir deuses e divindades aberrantes, além de espíritos mortos aflitos por vingança. O propósito dos aventureiros é endereçar ao vilão que está por trás de todo o caos. Seu nome é Phorcus e ele é um feiticeiro sombrio que está trazendo à tona seres malignos e lendas antigas. Uma vez destronado, Helsinki e os vilarejos vizinhos serão encorajados a retornarem à normalidade e os espíritos irritados poderão finalmente descansar em paz.

Fonte: Próprio autor com base nos dados de desenvolvimento.

Além disso o código define um limite de 10000 caracteres para o tamanho da lista `context`. Isso garante que o chatbot não fique sobrecarregado com informações desnecessárias e que a performance da conversa não seja prejudicada. Além disso, é importante destacar que a biblioteca OpenAI ChatCompletion é uma ferramenta poderosa para gerar respostas contextuais. No entanto, é fundamental fornecer a ela um contexto preciso e relevante para que as respostas sejam satisfatórias e adequadas ao longo do jogo.

Figura 7 – Pipeline do projeto.



Fonte: Próprio autor com base nos dados de desenvolvimento.

O diagrama representa como o projeto foi desenvolvido, e apresentado de forma resumida o passo a passo completo de cada etapa do projeto, delineando suas três etapas principais. A primeira etapa abrange a geração da base de dados e o subsequente tratamento dos dados obtidos, essenciais para subsidiar as etapas seguintes. A segunda etapa foca na realização do treinamento dos modelos de linguagem através do método do fine-tuning. Por fim, a terceira etapa direciona-se para o desenvolvimento do Game Master Chatbot, com o propósito de utilizar os dados gerados pelos modelos treinados para realizar a narração de uma sessão de jogo de RPG de mesa.

3.4 Avaliação das ferramentas desenvolvidas

Após o processo de fine-tuning e do desenvolvimento do Game Master Chatbot, é crucial avaliar a relevância dos dados gerados pelo modelo de linguagem para a função de Mestre de RPG e Descrição de NPC de RPG de mesa. É importante destacar que, para o desenvolvimento do contexto narrativo durante as interações, foram utilizados os fine-tunings específicos para a geração de Resumos de Aventuras de RPG de Mesa e Descrições de NPCs de RPG de Mesa.

O processo de avaliação se deu por meio de um questionário elaborado com o uso da Escala Likert de concordância (Likert, 1932). As entrevistas foram conduzidas online, através de plataformas de chamadas de áudio e vídeo, onde cada uma delas foi realizada com 1 a 3 avaliadores por vez. Cada entrevista teve duração média de 30 a 40 minutos, permitindo uma análise detalhada das percepções dos participantes. Durante as entrevistas, as ferramentas desenvolvidas foram apresentadas de forma separada.

Os fine-tunings para a geração de Resumos de Aventuras de RPG de Mesa e para Descrições de NPCs de RPG de Mesa foram discutidos como ferramentas auxiliares para a rotinização para um mestre de RPG, enquanto o Game Master Chatbot utilizava os resultados obtidos nos modelos treinados para adaptar seu contexto de narrativa. As entrevistas foram conduzidas de forma interativa, permitindo que os avaliadores expressassem suas dúvidas e sugestões em relação às gerações dos dados que queriam que fossem gerados, e às escolhas tomadas durante a narração do Game Master Chatbot.

O questionário foi composto por uma série de perguntas destinadas a avaliar diferentes aspectos das ferramentas desenvolvidas. Abaixo estão as perguntas do questionário e suas respectivas finalidades:

Tabela 6: Questionário e a finalidade de cada pergunta.

Questão	Finalidade da questão
Nome completo	Identificação do participante para evitar dados duplicação ou participação de alguma figura inexistente.
Você joga RPG há quanto tempo?	Verificar o nível de experiência do participante no contexto do RPG de mesa, para validar sua percepção da ferramenta.
Você considera as ferramentas usadas durante a interação fáceis de usar?	Avaliar a usabilidade das ferramentas desenvolvidas, fornecendo insights sobre a experiência do usuário.
Você acredita que a ferramenta auxiliadora de mestres é eficaz para auxiliar o mestre de RPG de mesa em suas narrações?	Avaliar a percepção do participante sobre a eficácia dos modelos de linguagem treinados para um mestre de RPG, considerando sua utilidade prática.
Você sentiu-se imerso na narrativa gerada pelo Game master chatbot?	Avaliar o nível de imersão proporcionado pela narrativa do Game Master Chatbot, um aspecto importante para a experiência de um jogo de RPG de Mesa.
Os resultados apresentados na ferramenta auxiliadora de mestres foram coesos e consistentes?	Verificar se os resultados gerados pelos modelos treinados são coesos e consistentes, para o uso de um mestre de RPG.
A narrativa apresentada pelo Game master chatbot foi coesa e consistente?	Avaliar a qualidade da narrativa gerada pelo Game Master Chatbot, avaliando a fluidez e coerência da narrativa ao longo da interação.
O Game master chatbot conseguiu adaptar-se às escolhas e ações propostas de forma satisfatória?	Verificar a capacidade do Game Master Chatbot de adaptar-se às decisões do jogador durante a narrativa, mantendo a coesão e a lógica da história e as regras estabelecidas pelo sistema de RPG utilizado na narração.
As situações apresentadas durante a sessão de RPG foram diversificadas e interessantes?	Avaliar a variedade de possibilidades e o grau de interesse das situações apresentadas durante a narração do Game master Chatbot.
Você sentiu-se engajado e envolvido durante toda a interação com as ferramentas?	Avaliar o nível de engajamento e envolvimento que as ferramentas provocaram no participante durante sua interação.
Em geral, o quanto você concorda sobre a utilidade proposta pela experiência proporcionada destas ferramentas?	Avaliar a percepção geral do participante sobre a utilidade das ferramentas desenvolvidas para a experiência de uma narração de RPG de mesa.
Existe algum recurso específico que você gostaria de ver implementado ou modificado nas futuras versões, ou alguma crítica em relação as ferramentas apresentadas?	Coletar sugestões e críticas dos participantes para aprimoramentos futuros das ferramentas, fornecendo direcionamento para o desenvolvimento contínuo.

Fonte: Próprio autor com base nos dados de desenvolvimento.

O questionário foi projetado para fornecer uma análise abrangente da experiência dos usuários com as ferramentas desenvolvidas, permitindo identificar pontos fortes e áreas de melhoria para futuras iterações com os modelos de linguagem treinados e o Game Master Chatbot.

4 RESULTADOS E DISCUSSÕES

Neste capítulo, serão apresentados e discutidos os resultados da pesquisa, revelando as descobertas decorrentes da análise dos dados coletados durante o experimento com o Game Master Chatbot e os modelos de linguagem treinados. Os resultados proporcionaram respostas diretas com base em um questionário que utiliza a Escala Likert de concordância. Ao analisar as respostas dos participantes, é possível identificar pontos fortes e áreas de melhoria nas ferramentas, oferecendo insights valiosos para o aprimoramento contínuo do Game Master Chatbot e dos modelos de linguagem associados. Para uma compreensão mais clara, neste capítulo, enfocaremos a visão geral dos resultados da pesquisa, destacando como foi realizada a entrevista aos avaliadores e quais conclusões foram adquiridas através dos dados coletados e exibidos nos gráficos.

4.1 Visão geral dos resultados da pesquisa.

Nesta seção, forneceremos uma visão detalhada do processo de avaliação do Game Master Chatbot e dos modelos de linguagem treinados. Os avaliadores, que são membros ativos de comunidades nas redes sociais dedicadas à organização de mesas de RPG online e à divulgação de informações sobre jogos de RPG, participaram ativamente da interação com as ferramentas, oferecendo feedbacks valiosos e percepções relevantes.


Essa introdução oferece uma compreensão inicial do processo de avaliação conduzido com os participantes, estabelecendo o contexto para a análise dos resultados que serão apresentados a seguir. Por meio de gráficos, exploraremos os dados coletados dos 15 avaliadores que participaram da demonstração das ferramentas. Vale ressaltar que as avaliações foram conduzidas online, através de ferramentas de comunicação de áudio e vídeo, permitindo que os participantes expressassem suas dúvidas, críticas e opiniões de forma interativa. Como critério de seleção, todos os avaliadores possuíam um mínimo de 5 anos de experiência em RPG de mesa, garantindo um nível consistente de familiaridade com o tema e proporcionando insights valiosos para a avaliação das ferramentas desenvolvidas.

Inicialmente, os avaliadores selecionados foram introduzidos à plataforma da OpenAI, com destaque para a janela de Playground, onde puderam vivenciar o funcionamento prático dos modelos de linguagem treinados por meio do fine-tuning. Foi demonstrado como inserir os dados necessários e em que ordem, para que os modelos pudessem retornar respostas de forma adequada. Em seguida, os modelos foram colocados à prova com sugestões dos próprios avaliadores, permitindo uma avaliação direta de sua capacidade e eficácia.

Na segunda etapa, utilizando os dados coletados durante a demonstração dos modelos de linguagem treinados, os avaliadores foram convidados a avaliar o Game Master Chatbot em ação. De forma prática, o Chatbot narrou o resumo de aventura gerado no modelo de linguagem treinado, e os avaliadores um a um participaram de uma sessão de jogo utilizando personagens gerados pelo modelo treinado. Antes do início do jogo, o Chatbot introduziu as regras do sistema de RPG que seria utilizado, questionando os jogadores sobre temas que gostariam ou não de serem abordados durante a narrativa. Além disso, foi apresentada uma mensagem padrão para interromper o jogo, caso necessário. Uma vez esclarecidas todas as dúvidas e instruções, o jogo teve início. Conforme o resumo proposto foi sendo concluído, o jogo se encerrava. No entanto, os jogadores tinham a opção de permitir que o game master chatbot continuasse a narrativa, levando o jogo por novos caminhos com base nas interações anteriores.

A seguir, por meio de gráficos, serão explorados os dados coletados dos 15 avaliadores que participaram da demonstração das ferramentas. Além das conclusões sobre os dados coletados durante as avaliações, serão fornecidas informações adicionais registradas pelo autor durante as avaliações, incluindo críticas e sugestões expressas na questão intitulada "Existe algum recurso específico que você gostaria de ver implementado ou modificado nas futuras versões, ou alguma crítica em relação às ferramentas apresentadas?", que está referenciada no Tabela 5.


Figura 8: Facilidade de uso dos Modelos treinados via plataforma da OpenIA e do Game master Chatbot.



Fonte: Próprio autor com base nos dados da pesquisa com avaliadores.

Com base nos dados do Gráfico 1, que avalia a facilidade de uso dos modelos treinados via plataforma da OpenAI e do Game Master Chatbot, observa-se uma experiência positiva da maioria dos avaliadores em relação à usabilidade das ferramentas. Os resultados sugerem que durante as avaliações, os usuários não encontraram dificuldades significativas para entender o funcionamento das ferramentas, exigindo apenas uma explicação inicial para compreendê-las.


Figura 9: Usabilidade dos modelos de linguagem treinados para um mestre de RPG



Fonte: Próprio autor com base nos dados da pesquisa com avaliadores.

Com base nos dados do Gráfico 2, que avalia a usabilidade dos modelos de linguagem treinados para um mestre de RPG, observa-se uma distribuição variada de respostas. Vale ressaltar que os modelos de linguagem treinados foram identificados como "Ferramenta auxiliadora de mestres" para facilitar a compreensão pelos avaliadores. Embora os textos gerados tenham sido percebidos como úteis para proporcionar ideias, alguns avaliadores observaram a presença de erros gramaticais, o que afetou ligeiramente a compreensão do texto gerado.

Figura 10: Capacidade de reter a atenção do usuário do Game master chatbot




Fonte: Próprio autor com base nos dados da pesquisa com avaliadores.

O Gráfico 3 apresenta informações sobre a capacidade do Game Master Chatbot em reter a atenção dos usuários durante a narração. Os avaliadores mantiveram-se atentos e participativos ao longo da interação. Os avaliadores decidiram explorar o uso do Chatbot de maneiras diferentes, seguindo abordagens como testar suas reações a diferentes decisões ou acompanhar o desenvolvimento da narrativa. No entanto, a falta de recursos visuais e auditivos foi identificada como um obstáculo para manter a atenção dos avaliadores, afinal durante uma pesquisa de Design sonoro para RPG, Ribas Nicolas de Oliveira e Teixeira Narle Silva (2016) afirmam que os seguintes resultados foram obtidos.

[...] embora o som esteja mais relacionado com a imersão sensorial, de acordo com as definições teóricas, ele acabou influenciando os jogadores a sentirem-se mais imersos imaginativamente, logo por estarem mais focados no conteúdo narrativo e representativo do jogo, e também mais imersos nos desafios, quando afirmam que a música nos momentos decisivos aumentou a dramaticidade da situação dando mais vida as batalhas...

Além disso, a ausência de urgência para passar de uma ação para outra também foi apontada como um fator que afetou a capacidade do chatbot em reter a atenção dos avaliadores.

Figura 11: Coesão e consistência dos modelos de linguagem treinados




Fonte: Próprio autor com base nos dados da pesquisa com avaliadores.

O Gráfico 4 aborda a coesão e consistência dos modelos de linguagem treinados. Houve observações positivas sobre a consistência dos dados gerados pelos modelos. No entanto, os avaliadores também identificaram erros gramaticais, especialmente em casos de informações mais complexas utilizadas nos testes ou em idiomas diferentes do idioma original dos dados utilizados para o treinamento, isso também se deve ao fato da base de dados utilizada no treinamento possuir uma quantidade de dados não tão ampla.

Figura 12: Coesão e consistência da narração do Game master chatbot

Grafico da Questão: A narrativa apresentada pelo Game master chatbot foi coesa e consistente?




Fonte: Próprio autor com base nos dados da pesquisa com avaliadores.

O Gráfico 5 destaca a percepção dos participantes sobre a coesão e consistência da narrativa apresentada pelo Game Master Chatbot. Observou-se que o chatbot manteve essa coesão e consistência mesmo diante de situações diversas, envolvendo diferentes aventuras, personagens e decisões dos jogadores. Além disso, o chatbot foi capaz de corrigir informações gramaticalmente incorretas e se comportou de forma condizente com um mestre de RPG, respondendo a dúvidas e propondo situações de acordo com o contexto do jogo.

Figura 13: Adaptatividade do Game master Chatbot a diferentes e interações


Grafico da Questão: O Game master chatbot conseguiu adaptar-se às escolhas e ações propostas de forma satisfatória?



Fonte: Próprio autor com base nos dados da pesquisa com avaliadores.

O Gráfico 6 destaca a avaliação da adaptabilidade do Game Master Chatbot às escolhas e ações propostas pelos jogadores. Durante a análise, verificou-se que o chatbot foi, em sua maioria, capaz de se adaptar satisfatoriamente às diferentes interações, fornecendo respostas que correspondiam às decisões dos jogadores. Contudo, identificaram-se casos em que o chatbot se mostrou volátil, permitindo ações que poderiam ser consideradas pouco realistas ou fora do contexto do jogo, especialmente quando o jogador insistiu em uma ação específica.

Figura 14: Diversificação e atratividade das interações do Game master chatbot




Fonte: Próprio autor com base nos dados da pesquisa com avaliadores.

O Gráfico 7 analisa a diversificação e a atratividade das interações do Game Master Chatbot durante a sessão de RPG. As interações se mostraram diversificadas com base no contexto da aventura previamente gerada pelo modelo treinado, mostrando rumos interessantes sempre que provocado a explorar situações ou ambientes fora dos demonstrados a princípio na aventura gerada. No entanto, algumas sugestões de melhoria apontaram a falta de referências a conteúdos gramaticais e fictícios já desenvolvidos, destacando uma oportunidade perdida para enriquecer a narrativa e aumentar a atratividade ao longo da sessão.

Figura 15: Nível de engajamento e envolvimento que as ferramentas provocaram aos avaliadores.

Gráfico da Questão: Você sentiu-se engajado e envolvido durante toda a interação com as ferramentas?




Fonte: Próprio autor com base nos dados da pesquisa com avaliadores.

O Gráfico 8 avalia o nível de engajamento e envolvimento dos avaliadores durante a interação com as ferramentas apresentadas. Como destacado anteriormente neste capítulo, as entrevistas foram conduzidas por meio de transmissões de vídeo, nas quais o autor instruiu os avaliadores sobre o funcionamento das ferramentas, seguido pelos comandos de interações dos avaliadores. Esse método foi adotado devido à restrição das chaves de acesso da OpenAI, que impediu os avaliadores de utilizarem diretamente as ferramentas. Além disso, algumas sugestões ao fim do questionário, levantaram a possibilidade de que o Game Master Chatbot fosse mais útil para jogadores iniciantes, proporcionando uma maneira de aprender o funcionamento do jogo de RPG de mesa. Tais pontos apresentados podem comprometer a experiência e, conseqüentemente, o engajamento e envolvimento para alguns avaliadores.

Figura 16: Avaliação geral sobre utilidade das ferramentas, incluindo modelos de linguagem treinados e o Game master chatbot

Gráfico da Questão: Em geral, o quanto você concorda sobre a utilidade proposta pela experiência proporcionada destas ferramentas?



Fonte: Próprio autor com base nos dados da pesquisa com avaliadores.

O Gráfico 9 apresenta uma avaliação geral sobre a utilidade das ferramentas, abrangendo os modelos de linguagem treinados e o Game master chatbot. Os avaliadores reconheceram amplamente as funcionalidades dessas ferramentas, destacando sua utilidade em diversas áreas.

Surgiram sugestões para novas funcionalidades, como a geração de itens e respostas de diálogos para os modelos treinados através do fine-tuning, mostrando-se útil para os mestres na preparação de sessões de jogo de RPG. Além disso, a contextualização do Game master Chatbot foi apontada, sugerindo sua utilização como uma ferramenta para introduzir jogadores iniciantes aos jogos de RPG de mesa ou até mesmo novos mestres. Esta função poderia proporcionar uma instrução mais dinâmica do que a convencional, realizada através da leitura de livros de regras. O chatbot também foi destacado como um auxiliar para os mestres durante as sessões, servindo como uma ferramenta de armazenamento de informações sobre as mesas de jogo e de geração de resultados com base em acontecimentos passados. Essa combinação une a experiência convencional de uma sessão de RPG de mesa com o potencial de geração de texto de um modelo de linguagem.

Além disso, foi apontada a viabilidade dessas ferramentas para a narração de aventuras mais complexas e extensas, bem como a modificação dessas, produzidas por indústrias de RPG. Também foi mencionada a possibilidade de inserção de

outros sistemas de RPG, proporcionando uma maior variedade de opções de jogo e permitindo a adaptação de aventuras prontas desenvolvidas para um sistema específico para outro sistema disponível nas opções da ferramenta.

5 CONCLUSÃO

O objetivo deste projeto é investigar a viabilidade e eficácia de ferramentas baseadas em inteligência artificial, mais especificamente os modelos de linguagem, como modelos de linguagem treinados através do processo de fine-tuning, para criar conteúdo destinado à roteirização de sessões de RPG de mesa, além de um chatbot com modelo de linguagem integrado para desempenhar a função de mestre de RPG de mesa. O propósito é aprimorar as experiências de jogadores e mestres de RPG de mesa. A motivação para este projeto surge das possibilidades de inovação no cenário das sessões de RPG de mesa, particularmente na função desempenhada pelo mestre do jogo. A ideia é explorar o potencial da tecnologia para oferecer suporte aos mestres, assim como criar e executar narrativas dinâmicas e estimular a imersão dos jogadores de RPG de mesa.

Uma avaliação abrangente foi realizada permitindo uma análise detalhada da usabilidade das ferramentas desenvolvidas, com a participação dos avaliadores. Durante esse processo, identificaram-se os pontos fortes e as áreas que demandam melhorias em cada uma das ferramentas. Os avaliadores forneceram feedback valioso sobre a experiência de uso, destacando aspectos positivos e apontando possíveis melhorias para aprimorar a eficácia e a utilidade das ferramentas no contexto das sessões de RPG de mesa, em especial para função de mestre do jogo.

Os resultados da pesquisa demonstram que os modelos de linguagem treinados e o Game Master Chatbot não devem ser vistos como substitutos dos métodos tradicionais de narração de RPG de mesa, mas sim como uma alternativa diferente da narração convencional, bem como uma alternativa de ferramentas complementares, enriquecendo a experiência de geração de informações narrativas e da própria narração. Essas ferramentas desempenham um papel valioso como apoio para jogadores e mestres de RPG de mesa, proporcionando uma experiência mais dinâmica e abrangente em possibilidades.

É crucial reconhecer que, apesar das contribuições relevantes e dos benefícios observados, foram identificadas possíveis limitações e ameaças durante o desenvolvimento deste trabalho. Uma das limitações está relacionada ao investimento financeiro limitado, o qual comprometeu a geração das bases de dados e do treinamento dos modelos de linguagem. O desenvolvimento das

funcionalidades em um período de tempo restrito resultou em limitações adicionais, especialmente relacionadas aos conhecimentos técnicos necessários para a integração dos modelos de linguagem treinados diretamente no Game Master Chatbot. Destaca-se também o obstáculo na escolha dos avaliadores com conhecimento prévio, uma vez que a pesquisa foi conduzida com um grupo específico de indivíduos, o que pode restringir a generalização dos resultados para usuários com diferentes perfis e níveis de experiência. Questões técnicas, como falhas temporárias nas ferramentas durante a avaliação, também podem ter influenciado a experiência dos avaliadores. Por fim, embora os resultados refletem o estado atual das ferramentas, mudanças subsequentes podem impactar algumas conclusões ao longo do tempo.

Para trabalhos futuros, embora as ferramentas tenham apresentado aspectos positivos, a pesquisa integrou a busca por necessidades de novas implementações, bem como críticas sobre o desempenho de algumas funcionalidades do modelo de linguagem treinado e do chatbot de RPG. Essas sugestões e críticas foram avaliadas, e aquelas consideradas relevantes foram utilizadas como descobertas para orientar melhorias nos modelos de linguagem treinados e no Game Master Chatbot.

Dentre os possíveis trabalhos futuros, destaca-se a expansão das bases de dados usadas no treinamento dos modelos de linguagem, visando corrigir inconsistências e diversificar os dados gerados. Além disso, novos métodos e funcionalidades para o Game Master Chatbot podem ser explorados, como a integração de rolagens de dados virtuais e a ampliação das opções de adaptação do chatbot, para funções específicas como auxiliar jogadores iniciantes ou instruir novos mestres de RPG. Implementar o método RAG para gerar a inclusão de possibilidades narrativas em outros sistemas de RPG e referências bibliográficas sobre diferentes temáticas de RPG, enriquecendo o conteúdo e a experiência do usuário (Oracle, 2024). Outra perspectiva importante é a integração dos modelos de linguagem treinados no Game Master Chatbot, bem como sua incorporação em uma interface web. É esperado que, como método de melhoria contínua, avaliações periódicas sejam realizadas para acompanhar as mudanças na plataforma.

Teve-se como foco apresentar a usabilidade de modelos de linguagem, demonstrando o processo de geração de bases de dados com o uso desses modelos, além do desenvolvimento de modelos de linguagem treinados por meio de

fine-tuning e a criação de um chatbot baseado em modelos de linguagem. Foi escolhido abordar os RPGs de mesa para demonstrar essas funcionalidades devido às possibilidades de geração diversificada que existem durante uma partida desse tipo de jogo, bem como para explorar o potencial de melhorias na experiência de jogo proporcionada por essas ferramentas, especialmente para função de um mestre de RPG.

Este trabalho oferece uma base para a compreensão e aplicação prática das tecnologias apresentadas. É esperado que esse estudo sirva de apoio para futuras pesquisas e desenvolvimentos voltados à criação e aprimoramento de ferramentas baseadas em modelos de linguagem, bem como para o desenvolvimento de ferramentas relacionadas aos RPGs de Mesa, contribuindo para avanços significativos nesse campo de estudo e na experiência dos jogadores e mestres de RPG.

REFERÊNCIAS

Beurer-Kellner, L.; Fischer, M.; Vechev, M. **Prompting Is Programming: A Query Language for Large Language Models**. Proc. ACM Program. Lang., v. 7, PLDI, Article 186, 24 páginas, jun. 2023. Disponível em: <https://doi.org/10.1145/3591300>.

Bottou, L.. **Large-Scale Machine Learning with Stochastic Gradient Descent**. In Y. Lechevallier & G. Saporta (Eds.), Proceedings of COMPSTAT'2010 (pp. 16). Physica-Verlag HD. 2010. Disponível em: https://doi.org/10.1007/978-3-7908-2604-3_16

Bowman, S. L.. **The functions of role-playing games: How participants create community, solve problems and explore identity**. Jefferson, NC: McFarland & Company. 2010.

Brown, T. B. et al. **Language models are few-shot learners**. In: Advances in Neural Information Processing Systems, v. 33, p. 1877-1888, 2020.

Chen, H., & Ding, N.. **Probing the “Creativity” of Large Language Models: Can models produce divergent semantic association?** In Findings of the Association for Computational Linguistics: EMNLP 2023 (pp. 12881–12888). Singapore: Association for Computational Linguistics. 2023.

DEVLIN, Jacob; CHANG, Mingwei; LEE, Kenton; TOUTANOVA, Kristina. **BERT: Pre-training of deep bidirectional transformers for language understanding**. In: Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Volume 1. Association for Computational Linguistics, 2019.

FUKATSU, Takayuki. **Chat Reincarnation: The Case of My Childhood Girl Friend Who Was Supposed to be Dead Becoming a Hero in Another World**. arXiv preprint arXiv:2301.06849, 2023.

GUINNESS, Harry. **Como usar o Dall-E 2**. Zapier Blog. Disponível em: <https://zapier.com/blog/generate-blog-images-with-dall-e-and-zapier/>.

GYGAX, Gary; ARNESON, Dave. **Dungeons & Dragons**. Lake Geneva, WI: Tactical Studies Rules, 1974.

Ha, H., Lee, J., Han, W., & Chun, B. G.. **Meta-Learning of Prompt Generation for Lightweight Prompt Engineering on Language-Model-as-a-Service**. In Findings of the Association for Computational Linguistics: EMNLP 2023, páginas 2433–2445, Singapura. Association for Computational Linguistics. 2023.

Hawkes-Robinson, William. **Role-playing Games Used as Educational and Therapeutic Tools for Youth and Adults**. 2008. Disponível em: https://www.researchgate.net/publication/237074784_Role-playing_Games_Used_as_Educational_and_Therapeutic_Tools_for_Youth_and_Adults

He, K., Zhang, X., Ren, S., & Sun, J. **Deep Residual Learning for Image Recognition**. In 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) (pp. 770-778). Las Vegas, NV, USA. doi: 10.1109/CVPR.2016.90. 2016. Disponível em: <https://ieeexplore.ieee.org/document/7780459>

Jaffe, T., & Lockey, C.. **Candela Obscura**. Darrington Press. 2023.

Jurafsky, D., & Martin, J. H.. **Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition (3rd ed.)**. Prentice Hall. 2020.

Kingma, D. P., & Ba, J.. **Adam: A Method for Stochastic Optimization**. CoRR abs/1412.6980. 2014. Disponível em: <https://www.semanticscholar.org/paper/Adam%3A-A-Method-for-Stochastic-Optimization-Kingma-Ba/a6cb366736791bcccc5c8639de5a8f9636bf87e8>

LeCun, Y.; Bengio, Y.; Hinton, G. **Deep Learning**. *Nature*, v. 521, p. 436-444, 2015.

LEEWAYHERTZ. **Prompt Engineering: A Key Ingredient for Successful Large Language Model Applications**. 2023. Disponível em: <https://www.leewayhertz.com/prompt-engineering/>.

Likert, Rensis. **A technique for the measurement of attitudes**. Archives of Psychology, 140(1), 1-55, 1932. Disponível em: https://legacy.voteview.com/pdf/Likert_1932.pdf.

Liu, G., Zhang, Y., Lei, Y., Chen, Y., Wang, R., Li, Z., & Xie, L. **PromptStyle: Controllable Style Transfer for Text-to-Speech with Natural Language Descriptions**. 2023. Disponível em: https://www.isca-archive.org/interspeech_2023/liu23t_interspeech.pdf

Lo, R. et al. **Hierarchical Prompting Assists Large Language Model on Web Navigation**. In: Findings of the Association for Computational Linguistics: EMNLP 2023. Singapore: Association for Computational Linguistics, 2023.

Lu, H., Bao, S., He, H., Wang, F., Wu, H., & Wang, H.. **Towards Boosting the Open-Domain Chatbot with Human Feedback**. Baidu Inc., China. 2023. Disponível em: <https://aclanthology.org/2023.acl-long.224.pdf>

Kelly, J., Mateas, M., & Wardrip-Fruin, N.. **Towards Computational Support with Language Models for TTRPG Game Masters**. In Proceedings of the 18th International Conference on the Foundations of Digital Games (FDG '23) (pp. 1-4). Association for Computing Machinery. 2023. Disponível em: <https://doi.org/10.1145/3582437.3587202>.

MURRAY, Janet H. **A Teoria da Imersão no RPG**. RedeRPG, 4 mar. 2018. Disponível em: <https://www.rederpg.com.br/2018/03/04/teoria-da-imersao-no-rpg/>.

Nothelfer, C.. **The use of natural language processing techniques in information retrieval**. 2011.

OPENAI. **Fine-tuning guide**. OpenAI API. 2023. Disponível em: <https://platform.openai.com/docs/guides/fine-tuning>.

Oracle. **Generative AI: Retrieval Augmented Generation (RAG)**. 2024. Disponível em: <https://blogs.oracle.com/ai-and-datascience/post/oci-generative-ai-agents-rag-service>..

Pan, S. J., & Yang, Q. **A Survey on Transfer Learning**. IEEE Transactions on Knowledge and Data Engineering, 22(10), 1345-1359. doi: 10.1109/TKDE.2009.191.2010. Disponível em: <https://ieeexplore.ieee.org/document/5288526>

PETERSON, Jon. **Playing at the World: A History of Simulating Wars, People, and Fantastic Adventures from Chess to Role-Playing Games**. San Francisco: University of California Press, 2012.

Prass, Henrique Luiz Telles da Silva; Webe, Raul Fernando. **Análise de Jogos de RPG em Mesas Virtuais**. 2017. Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) - Universidade Federal do Rio Grande do Sul, Porto Alegre.

Radford, A., Narasimhan, K., Salimans, T., & Sutskever, I. **Improving language understanding by generative pre-training**. 2018. Disponível em: <https://s3-us-west-2.amazonaws.com/openai-assets/research-covers/language-unsupervised/language-understanding-paper.pdf>.

Raffel, C. et al. **Exploring the limits of transfer learning with a unified text-to-text transformer**. 2019. Disponível em: <https://arxiv.org/abs/1910.10683>.

Randi, M. A. F.; Carvalho, H. F. de. **Aprendizagem através de Role-Playing Games: uma Abordagem para a Educação Ativa**. Universidade Federal do Paraná, Curitiba, PR, Brasil; Universidade Estadual de Campinas, Campinas, SP, Brasil. 2013. Disponível em: <https://www.scielo.br/j/rbem/a/Sm7kZcNXWWNvd3rnc7grsGB/?format=pdf&lang=en>.

RIBAS, Nícolas de Oliveira; TEIXEIRA, Narle Silva. **Design sonoro no rpg de mesa: uma estratégia para imersão**. 2016. 11 f. Tese (Doutorado) - Curso de Design, Congresso Brasileiro de Pesquisa e Desenvolvimento em Design, Fucapi, Belo Horizonte, 2016.

RPG GEEK. **Fórum de RPG**. 2024. Disponível em:
<https://rpggeek.com/forums/region/2/rpg>.

Ruder, S. **An overview of gradient descent optimization algorithms**. arXiv preprint arXiv:1609.04747. 2016. Disponível em:
<https://www.ruder.io/optimizing-gradient-descent/>

RUDER, S. **Recent Advances in Language Model Fine-Tuning**. 2023. Disponível em: <https://www.ruder.io/recent-advances-lm-fine-tuning/>.

SCHOLTZ, Peter. **How to play Dungeons & Dragons and other pen-and-paper games online**. Polygon, 17 mar. 2020. Disponível em:
<https://www.polygon.com/2020/3/17/21182538/how-to-play-dungeons-dragons-pen-and-paper-games-online-virtual-tabletop-coronavirus>.

Su, Y., Wang, X., Qin, Y., Chan, C.-M., Lin, Y., Wang, H., Wen, K., Liu, Z., Li, P., Li, J., Hou, L., Sun, M., & Zhou, J. **On Transferability of Prompt Tuning for Natural Language Processing**. In Proceedings of the 2022 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies (pp. 3949–3969). 2022. Seattle, United States: Association for Computational Linguistics.

VASQUES, Rafael Carneiro. **As Potencialidades do RPG (Role Playing Game) na Educação Escolar**. 2008. 140 f. Dissertação (Mestrado em Educação Escolar) – Faculdade de Ciências e Letras, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Araraquara, 2008.

VASWANI, Ashish et al. **Attention is all you need.** In: Proceedings of the 31st Conference on Neural Information Processing Systems (NIPS), Long Beach, CA, USA, 2017. Disponível em: <https://papers.nips.cc/>.

VISHAL ANAND, Er. **Azure Prompt Engineering, a practical hands-on approach.** Medium, 2023. Disponível em: <https://er-vishalanand.medium.com/prompt-engineering-a-practical-hands-on-approach-0318d8426a47>.

WALTON, Nick et al. **AI Dungeon 2: Creating Infinitely Generated Text Adventures with Deep Learning Language Models.** 2019. Disponível em: <https://pcc4318.wordpress.com/2019/11/21/ai-dungeon-2-creating-infinitely-generated-text-adventures-with-deep-learning-language-models/>.

ZAPIER. **Prompt Engineering: The Ultimate Guide.** 2023. Disponível em: <https://zapier.com/blog/prompt-engineering/>.

Zhang, Q., Dong, J., Chen, H., Zha, D., Yu, Z., & Huang, X. **KnowGPT: Knowledge Injection for Large Language Models.** 2023. Disponível em: <https://arxiv.org/abs/2312.06185v4>

WIZARDS OF THE COAST. **D&D Beyond.** Seattle, WA: Wizards of the Coast, 2020. Disponível em: <https://www.dndbeyond.com/>.

ANEXO A – Sessão de RPG com o Game Master Chatbot

O link abaixo exemplifica a eficácia dos modelos de linguagem treinados e a utilização do Game master Chatbot em uma sessão de jogo. Apesar de breve, a demonstração destaca claramente as funcionalidades do Chatbot, evidenciando sua habilidade em se adaptar a diferentes situações e personalizar narrativas conforme necessário.

Link em Anexo:
https://drive.google.com/file/d/1nc0ls8XuyXD6lowl3bRpMliTQD1xY_QD/view?usp=sharing