



Universidade Federal de Pernambuco  
Centro de Informática

Marcos André Cavalcanti de Albuquerque e Mello

**Uso de modelos de linguagem para melhor experiência em jogos: lições aprendidas**

Recife

2025

Marcos André Cavalcanti de Albuquerque e Mello

**Uso de modelos de linguagem para melhor experiência em jogos: lições aprendidas**

Trabalho apresentado ao Programa de Graduação em Ciência da Computação do Centro de Informática da Universidade Federal de Pernambuco, como requisito parcial para obtenção do grau de Bacharel em Ciência da Computação.

**Orientador (a):** Geber Lisboa Ramalho

Recife

2025

Ficha de identificação da obra elaborada pelo autor,  
através do programa de geração automática do SIB/UFPE

Mello, Marcos André Cavalcanti de Albuquerque e.

Uso de modelos de linguagem para melhor experiência em jogos: lições aprendidas / Marcos André Cavalcanti de Albuquerque e Mello. - Recife, 2025. 48 p. : il., tab.

Orientador(a): Geber Lisboa Ramalho

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de Pernambuco, Centro de Informática, Ciências da Computação - Bacharelado, 2025.

Inclui referências.

1. Inteligência Artificial. 2. Modelos de Linguagem. 3. Jogos Digitais. 4. Geração de Conteúdo Procedimental. 5. NPCs interativos. 6. Design de Jogos. I. Ramalho, Geber Lisboa. (Orientação). II. Título.

000 CDD (22.ed.)

MARCOS ANDRÉ CAVALCANTI DE ALBUQUERQUE E MELLO

**Uso de modelos de linguagem para melhor experiência em jogos: lições aprendidas**

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Ciência da Computação da Universidade Federal de Pernambuco, como requisito parcial para obtenção do título de bacharel em Ciência da Computação.

Aprovado em: 09/04/2025

**BANCA EXAMINADORA**

---

Prof. Geber Lisboa Ramalho (Orientador)

Universidade Federal de Pernambuco

---

Prof. Filipe Carlos de Albuquerque Calegário (Examinador Interno)

Universidade Federal de Pernambuco

## RESUMO

Diante do avanço das tecnologias de inteligência artificial, especialmente dos Modelos de Linguagem de Grande Escala (LLMs), surge a oportunidade de repensar a forma como jogadores interagem com jogos digitais. Atualmente, muitos jogos ainda apresentam interações rígidas e limitadas, o que pode comprometer a imersão e a liberdade do jogador para certos tipos de jogos, como jogos de investigação. Esse cenário configura o problema central deste trabalho: a dificuldade de oferecer interações naturais e flexíveis em jogos digitais. Motivado pela busca de experiências mais dinâmicas e imersivas em jogos, este trabalho investiga como a utilização de LLMs pode aprimorar a experiência do jogador, com foco na geração de conteúdo procedimental e na interação com NPCs. Para validar a proposta, foi desenvolvido um jogo interativo com a temática de investigação, baseado em texto e conversa, no qual o diálogo com os NPCs é realizado a partir da integração com LLMs, que respondem aos questionamentos dos jogadores de forma adaptativa. Os jogadores têm liberdade para conduzir suas investigações, fazendo qualquer tipo de pergunta, o que resulta em uma experiência personalizada e envolvente. A implementação do jogo foi seguida por uma análise qualitativa e quantitativa das respostas dos participantes, a fim de avaliar a eficácia da tecnologia. Os resultados indicaram uma recepção positiva, destacando a flexibilidade e a imersão proporcionadas pela integração com LLMs. No entanto, também foram identificadas limitações nas interações, sugerindo caminhos para aprimoramentos futuros. Este trabalho evidencia o potencial dos LLMs para transformar a experiência em jogos digitais e oferece *insights* valiosos sobre os desafios e oportunidades associados ao uso dessa tecnologia emergente.

**Palavras-chaves:** Inteligência Artificial, Modelos de Linguagem, Jogos Digitais, NPCs Interativos, Geração de Conteúdo Procedimental, Design de Jogos.

## ABSTRACT

With the advancement of artificial intelligence technologies, especially Large Language Models (LLMs), new opportunities arise to rethink how players interact with digital games. Currently, many games still present rigid and limited interactions, which can compromise immersion and player freedom, especially in genres such as investigative games. This scenario outlines the central problem of this work: the difficulty of providing natural and flexible interactions in games. Motivated by the pursuit of more dynamic and immersive gaming experiences, this study investigates how the use of LLMs can enhance the player's experience, focusing on procedural content generation and interaction with non-player characters (NPCs). To validate this approach, an interactive investigation-themed game was developed, based on text and conversation, in which NPCs are powered by LLMs and respond adaptively to players' questions. Players are free to conduct their investigations by asking any kind of question, resulting in a personalized and engaging experience. The implementation of the game was followed by a qualitative and quantitative analysis of player feedback to assess the effectiveness of the technology. The results indicated a positive reception, highlighting the flexibility and immersion provided by the integration of LLMs. However, some interaction limitations were also identified, suggesting areas for future improvements. This work highlights the potential of LLMs to transform digital game experiences and offers valuable insights into the challenges and opportunities of this emerging technology.

**Keywords:** Artificial Intelligence, Language Models, Video Games, Interactive NPCs, Procedural Content Generation, Game Design.

## LISTA DE FIGURAS

Figura 1 – Tela Inicial . . . . .	22
Figura 2 – Tela Principal . . . . .	23
Figura 3 – Tela de Questionário . . . . .	23
Figura 4 – Tela Final . . . . .	24
Figura 5 – Modelagem de Dados . . . . .	26
Figura 6 – Gráfico de Barras com a distribuição de tempo por sessão . . . . .	37
Figura 7 – Gráfico de Barras com o número total de perguntas por sessão . . . . .	37
Figura 8 – Gráfico de barras com a distribuição de pontuação por sessão . . . . .	39

## LISTA DE TABELAS

Tabela 1 – Distribuição da faixa etária dos participantes . . . . .	35
Tabela 2 – Frequência com que os participantes jogam videogames . . . . .	36
Tabela 3 – Média de perguntas feitas por sessão a cada NPC . . . . .	38
Tabela 4 – Mediana das respostas às perguntas sobre a experiência geral dos jogadores	40
Tabela 5 – Mediana das respostas às perguntas sobre a interação com a IA . . . . .	41

## LISTA DE ABREVIATURAS E SIGLAS

<b>API</b>	Application Programming Interface ou Interface de Programação de Aplicações
<b>ChatGPT</b>	Chat Generative Pre-trained Transformer
<b>GPT</b>	Generative Pre-trained Transformer
<b>IA</b>	Inteligência Artificial
<b>IA Generativa</b>	Inteligência Artificial Generativa
<b>LLM</b>	Large Language Models ou Modelos de Linguagem de Grande Escala
<b>NPC</b>	Non-Player Character ou Personagem Não-Jogador
<b>PCG</b>	Procedural Content Generation ou Geração de Conteúdo Procedimental

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>11</b>
<b>2</b>	<b>MODELOS DE LINGUAGEM</b>	<b>12</b>
2.1	DEFINIÇÃO E FUNCIONAMENTO	12
2.2	POPULARIZAÇÃO E IMPACTO DOS MODELOS GPT	13
<b>3</b>	<b>GERAÇÃO DE CONTEÚDO PROCEDIMENTAL EM JOGOS</b>	<b>15</b>
3.1	TIPOS DE GERAÇÃO PROCEDIMENTAL E APLICAÇÕES EM JOGOS	15
3.2	MODELOS DE LINGUAGEM E A EXPANSÃO DA GERAÇÃO PROCEDIMENTAL	16
3.3	DESAFIOS E LIMITAÇÕES DA INTEGRAÇÃO DE LLMS NA GERAÇÃO PROCEDIMENTAL	17
<b>4</b>	<b>JOGO BASEADO EM DIÁLOGO UTILIZANDO MODELOS DE LINGUAGEM</b>	<b>19</b>
4.1	CONCEITO E PROPOSTA DO JOGO	19
4.2	MECÂNICAS E FUNCIONALIDADES	21
4.3	FLUXO DE TELAS	22
<b>5</b>	<b>IMPLEMENTAÇÃO TÉCNICA</b>	<b>25</b>
5.1	DESCRIÇÃO DA APLICAÇÃO DESENVOLVIDA	25
<b>5.1.1</b>	<b>Frontend</b>	<b>25</b>
<b>5.1.2</b>	<b>Backend</b>	<b>26</b>
5.2	INTERAÇÃO COM AS APIS E ESTRUTURA DE PROMPTS	26
<b>5.2.1</b>	<b>Funções utilizadas</b>	<b>27</b>
<b>5.2.2</b>	<b>Definição de prompts para cada personagem</b>	<b>29</b>
<b>6</b>	<b>AVALIAÇÃO DA EXPERIÊNCIA DOS USUÁRIOS</b>	<b>34</b>
6.1	METODOLOGIA DE AVALIAÇÃO	34
6.2	RESULTADOS E ANÁLISE	35
<b>6.2.1</b>	<b>Perfil dos participantes</b>	<b>35</b>
<b>6.2.2</b>	<b>Estatísticas gerais sobre as sessões dos usuários</b>	<b>36</b>
<b>6.2.3</b>	<b>Avaliação da experiência geral do jogo</b>	<b>39</b>
<b>6.2.4</b>	<b>Interação com IA e mecânica principal do jogo</b>	<b>40</b>
<b>6.2.5</b>	<b>Feedbacks Qualitativos</b>	<b>41</b>

7	LIÇÕES APRENDIDAS DURANTE O DESENVOLVIMENTO . . .	43
8	CONCLUSÃO . . . . .	46
	REFERÊNCIAS . . . . .	48

## 1 INTRODUÇÃO

Nos últimos anos, a indústria da tecnologia tem observado inúmeros avanços no campo da Inteligência Artificial (IA), incluindo os Large Language Models ou Modelos de Linguagem de Grande Escala (LLM). A partir disso, é válido refletir em quais esferas essa tecnologia pode contribuir e agregar valor. Os jogos digitais, desde muito tempo, buscam, através da geração de conteúdo procedimental, atingir experiências mais dinâmicas, personalizadas e adaptativas, criando uma interação mais rica e envolvente. No entanto, com o advento dos LLMs, surge a possibilidade de uma evolução ainda mais significativa na forma como os jogadores interagem com os mundos virtuais gerando conteúdo de forma dinâmica.

Este trabalho tem como objetivo explorar a viabilidade do uso de LLMs em jogos através de uma solução prática, que busca implementar um jogo focado na interação entre o jogador e o Non-Player Character ou Personagem Não-Jogador (NPC), utilizando a tecnologia Generative Pre-trained Transformer (GPT) para gerar diálogos mais naturais e variados disponibilizando uma grande flexibilidade na interação com o usuário. Com o uso de LLMs, esses personagens têm o potencial de oferecer respostas mais dinâmicas, personalizadas e adaptativas, criando uma interação mais rica e envolvente.

Além disso, o trabalho examina a resposta dos jogadores à implementação dessa tecnologia, analisando como a integração de LLMs pode impactar a percepção de profundidade e a qualidade das interações em jogos digitais. Através da coleta de *feedback* dos jogadores, busca-se entender a eficácia da utilização de NPCs interativos movidos por LLMs em comparação com abordagens tradicionais de interação em jogos.

Sendo assim, é vital investigar o potencial desses modelos para redefinir a interação no design de jogos digitais, considerando as oportunidades e desafios que surgem com a incorporação de modelos de linguagem. O impacto dessa tecnologia pode ser significativo, oferecendo novas possibilidades para a criação de experiências mais imersivas e inovadoras para os jogadores.

## 2 MODELOS DE LINGUAGEM

Há muito tempo, as IAs dominam as discussões e pesquisas na área da computação. No entanto, após o desenvolvimento e avanços na área da Inteligência Artificial Generativa (IA Generativa), notou-se uma explosão ainda maior pelo interesse nessa tecnologia não só da comunidade técnica, mas também das pessoas comuns. Os modelos de linguagem, muitas vezes disponibilizados em plataformas como *ChatBots*, como por exemplo o Chat Generative Pre-trained Transformer (ChatGPT), rapidamente conquistaram o público geral se apresentando como uma ferramenta de fácil utilização e muito valor.

Como principal funcionalidade, esses modelos têm a capacidade de interpretar, gerar e modificar textos baseados em *prompts*, que são uma série de instruções fornecidas pelo usuário como entrada. A partir de uma evolução acelerada e melhorias constantes, esses modelos vêm sendo aplicados em diferentes áreas como programação, produção de conteúdo e jogos digitais. Porém, ainda surgem algumas dúvidas sobre como essa tecnologia pode verdadeiramente ajudar e agregar em aplicações do tipo.

### 2.1 DEFINIÇÃO E FUNCIONAMENTO

Os modelos de linguagem ou LLMs (*Large Language Models*) são sistemas computacionais treinados para prever e gerar sequências de palavras com base em padrões linguísticos. Para isso, utilizam técnicas de aprendizado profundo, com ênfase em redes neurais baseadas em transformadores, como o próprio GPT.

Os transformadores revolucionaram o processamento de linguagem natural (*Natural Language Processing* - NLP) ao substituir as abordagens tradicionais utilizadas anteriormente, que eram baseadas em redes recorrentes (RNNs) e convolucionais (CNNs) (VASWANI et al., 2017). Esse avanço possibilitou uma maior eficiência e melhor compreensão do contexto linguístico, sendo a base para modelos mais modernos, como o GPT-4. Esses modelos são treinados com uma grande quantidade de dados textuais, permitindo com que eles consigam compreender e responder uma série de consultas de maneira coerente e contextualizada.

A arquitetura dos *transformers* é um tipo de arquitetura de rede neural que altera ou modifica uma sequência informada como entrada em uma sequência de saída. Isso é feito através do contexto e relações rastreadas entre os componentes informados como entrada.

Por exemplo, se é passada como entrada a pergunta “Qual o nome da nossa galáxia?”, o modelo irá usar uma representação matemática que conseguirá identificar a relação entre as palavras “galáxia”, “nossa” e “nome” e então gerar uma saída: “Nossa galáxia é a Via Láctea”.

## 2.2 POPULARIZAÇÃO E IMPACTO DOS MODELOS GPT

A partir da grande evolução no desenvolvimento de modelos linguísticos, o lançamento do GPT-3 em 2020 realizado pela OpenAI, empresa e laboratório de pesquisa de Inteligência Artificial estadunidense, representou um divisor de águas no uso de IA para o processamento de linguagem natural. Com cerca de 175 bilhões de parâmetros, o modelo é capaz de gerar textos humanamente extremamente convincentes e realistas, o que habilitou o seu uso para aplicações como *chatbots*, assistentes virtuais e geração de conteúdo de forma muito eficiente. Os modelos GPT se destacam por sua capacidade de aprendizado a partir de poucos exemplos, abrindo caminho para uma nova gama de interações com sistemas computacionais (BROWN et al., 2020).

A chegada do *ChatGPT*, baseado nos modelos de mesmo sufixo, acelerou a adoção dessa tecnologia pelo público geral, incentivando empresas e desenvolvedores a explorarem novas formas de interação com LLMs. Seu impacto foi tão significativo que praticamente todas as grandes empresas começaram a integrar modelos de IA em seus produtos, transformando completamente a interação digital dos usuários. O impacto do ChatGPT em alguns setores, como no setor educacional e científico é tão amplo que levanta discussões sobre seus benefícios, limitações e estratégias de adoção sustentável (RAHMAN; WATANOBÉ, 2023).

A inteligência artificial sempre foi um dos tópicos mais debatidos do ramo da tecnologia, mas foi com o ChatGPT que essa tecnologia se tornou amplamente acessível e utilizada no cotidiano das pessoas. Esse processo evidenciou o potencial dos modelos de linguagem e os mais diversos tipos de integrações surgiram. As suas aplicações se estendem desde assistentes virtuais, automatização de atendimento ao cliente, apoio à programação e análise de código, geração de conteúdo e até mesmo jornalismo automatizado. Dada a capacidade desses modelos de gerarem textos variados, suas aplicações são praticamente ilimitadas, dependendo apenas da criatividade dos desenvolvedores.

Contudo, por se tratar de uma tecnologia relativamente recente, ainda se tem muitas dúvidas sobre como integrá-la de forma eficiente aos mais diversos tipos de mídia, de uma forma que realmente agregue valor e não seja introduzido apenas para aproveitar a moda. A tendência

a alucinações, que consiste na geração de informações incorretas ou fictícias pelo modelo, o alto custo computacional e financeiro e algumas questões éticas como viés nos dados e segurança da informação, além de problemas de *copyright*, se apresentam como potenciais desafios para implementações do tipo. A discussão sobre potenciais riscos e oportunidades associados a esse tipo de modelo é ampla e há vários alertas sobre a necessidade de responsabilidade no desenvolvimento e adoção dessas tecnologias (BOMMASANI et al., 2021).

Porém, com essas limitações em mente, explorar o potencial de modelos de linguagem com um papel de geração de conteúdo dinâmico se torna uma boa oportunidade para conhecer até onde podem chegar os benefícios de utilizar e fazer soluções utilizando esse tipo de ferramenta. Essa integração potencialmente poderia elevar o nível de interatividade e imersão em mídias que têm nesses fatores seus principais pilares para experiências mais envolventes e adaptáveis, como por exemplo *videogames*.

### 3 GERAÇÃO DE CONTEÚDO PROCEDIMENTAL EM JOGOS

A Procedural Content Generation ou Geração de Conteúdo Procedimental (PCG) é uma técnica amplamente utilizada no desenvolvimento de jogos eletrônicos para criação automática de elementos do jogo como personagens, histórias, missões, mapas, entre outros (TOGELIUS et al., 2011). O seu principal objetivo é reduzir o esforço manual na criação de conteúdo, aumentar a variedade e permitir aos jogadores uma experiência dinâmica e única a cada nova partida. Essa abordagem permite que a experiência de cada jogador seja particular, tornando-se uma estratégia valiosa para manter o envolvimento e a motivação do usuário ao longo do tempo.

#### 3.1 TIPOS DE GERAÇÃO PROCEDIMENTAL E APLICAÇÕES EM JOGOS

Existem diversas formas diferentes de categorização dos diferentes métodos de geração de conteúdo procedimental em jogos, uma das classificações mais recentes (MALEKI; ZHAO, 2024) sugere a seguinte divisão:

**Métodos baseados em busca:** Focados na otimização e exploração de espaços de conteúdo para gerar resultados satisfatórios. Um exemplo é a busca em árvore Monte Carlo (MCTS) que avalia múltiplas possibilidades para selecionar a mais adequada, garantido que o conteúdo gerado que for selecionado atenda a critérios específicos de qualidade e jogabilidade.

**Métodos baseados em aprendizagem de máquina:** Com os recentes avanços na área de aprendizagem de máquina, especialmente em redes neurais profundas e redes adversárias generativas (GANs), tornou-se possível treinar modelos para criar conteúdo complexo. Com isso, começaram a surgir aplicações que utilizam modelos do tipo para gerar texturas realistas ou até mesmo níveis completos de jogos, aprendendo padrões a partir de dados existentes e criando variações inovadoras. Apesar dos LLMs teoricamente se encaixarem aqui, foram colocados em sua própria categoria por conta da sua natureza de modelo como serviço (MaaS).

**Outros métodos:** Englobam técnicas que não se encaixam em outras categorias, como funções de ruído e gramáticas gerativas. As funções de ruído, como o ruído Perlin, são utilizadas para criar terrenos e texturas naturais de forma eficiente. Já as gramáticas gerativas aplicam regras predefinidas para construir estruturas complexas, como níveis de jogo ou missões, garantindo coerência e variedade no conteúdo produzido.

**Modelos de Linguagem em Larga Escala (LLMs):** A integração de LLMs trouxe novas

possibilidades para a PCG. Esses modelos estão sendo usados para gerar narrativas, diálogos e até mesmo design de níveis, proporcionando experiências mais dinâmicas aos jogadores. Por exemplo, um LLM pode criar histórias ramificadas que se adaptam às escolhas do jogador, aumentando a imersão e personalização da experiência de jogo.

Historicamente, a geração procedimental tem sido amplamente empregada em diversos jogos. Minecraft (Mojang Studios, 2011), o jogo mais vendido do mundo até o momento da pesquisa, utiliza algoritmos para criar um mundo virtualmente infinito, garantindo ao jogador ambientes totalmente diferentes e variados a cada instante. Outro exemplo semelhante, No Man's Sky (Hello Games, 2016), utiliza um sistema de geração de conteúdo procedimental para criar planetas, fauna e flora e oferece ao jogador, a partir disso, um universo explorável com bilhões de possibilidades.

Em jogos do gênero *roguelike*, que se baseiam em repetição e inúmeras tentativas partindo do zero, a geração procedimental de conteúdo se torna praticamente essencial para uma garantir uma experiência sempre renovada. Jogos como The Binding of Isaac (Nicalis, 2011) e Hades (Supergiant Games, 2020) utilizam essa técnica para construir *dungeons* e desafios dinâmicos, que tornam cada sessão uma experiência quase completamente nova.

### 3.2 MODELOS DE LINGUAGEM E A EXPANSÃO DA GERAÇÃO PROCEDIMENTAL

A introdução de modelos de linguagem em grande escala trouxe novas possibilidades para a PCG, permitindo uma geração de conteúdo ainda mais dinâmica e adaptável. Enquanto os métodos tradicionais de PCG são baseados em regras e algoritmos pré definidos, LLMs podem criar narrativas, personagens e interações dinâmicas de forma flexível e contextualizada.

Uma das principais vantagens dos LLMs é a sua capacidade de gerar conteúdo virtualmente infinito. Nos jogos, isso representa um salto significativo em termos de rejogabilidade e dinamismo. Enquanto muitos jogos perdem a atratividade quando o conteúdo se esgota, a integração de LLMs permite a criação de diálogos, missões e até mesmo comportamentos de NPCs de forma dinâmica, sem a necessidade de uma grande base de dados pré-configurada.

Um dos exemplos mais notáveis do uso de LLMs na geração de conteúdo procedimental é o *AI Dungeon* (Latitude, 2019), um jogo de narrativa interativa baseado em texto que utiliza os modelos GPT para gerar histórias dinâmicas e responder ao jogador em tempo real. O modelo permite que as histórias se desenvolvam de maneira imprevisível, proporcionando uma experiência única a cada jogada, que também depende da criatividade do jogador.

Além disso, diversos projetos experimentais vêm explorando a integração de LLMs com jogos já estabelecidos. No *The Elder Scrolls V: Skyrim* (Bethesda Game Studios, 2011), mods utilizam IA para gerar diálogos mais naturais e responder de forma coerente às interações dos jogadores com NPCs. Modificações semelhantes foram implementadas no Minecraft, onde NPCs podem reagir de maneira mais orgânica às ações dos jogadores.

### 3.3 DESAFIOS E LIMITAÇÕES DA INTEGRAÇÃO DE LLMS NA GERAÇÃO PROCEDIMENTAL

Apesar do grande potencial dos modelos de linguagem para a geração de conteúdo procedimental, sua integração ainda enfrenta desafios significativos. Questões como coerência narrativa, controle sobre o conteúdo gerado e custos computacionais elevados são fatores críticos a serem considerados. Modelos de linguagem frequentemente apresentam alucinações, gerando conteúdo inconsistente ou sem sentido dentro do universo do jogo, mesmo utilizando versões mais recentes como o GPT-4 (BUBECK et al., 2023). Para jogos que exigem consistência narrativa, isso pode comprometer a experiência do jogador. Estratégias como *fine-tuning* de modelos específicos para determinados contextos têm potencial para mitigar esse problema, mas demandam recursos computacionais adicionais.

Outro fator limitante é o alto custo computacional aliado com o custo monetário. Modelos como GPT-4 exigem servidores potentes para processamento em tempo real, tornando sua implementação inviável para muitos desenvolvedores independentes. Alternativas incluem o uso de modelos menores e otimizados, como os da família LLaMA (TOUVRON et al., 2023), que oferecem desempenho semelhante com menor demanda computacional.

Além disso, a necessidade de supervisão humana sobre o conteúdo gerado ainda é alta. Diferente de abordagens tradicionais de PCG, onde o conteúdo pode ser pré-avaliado e refinado, modelos de linguagem operam de maneira mais imprevisível, exigindo mecanismos de filtragem e ajustes constantes. É de se considerar o esforço necessário para contextualizar e integrar corretamente o modelo ao universo que o desenvolvedor deseja criar, garantindo que as respostas geradas sejam coerentes e mantenham o jogador imerso na história e jogabilidade.

A combinação entre PCG e modelos de linguagem pode transformar a forma como os jogos são criados e consumidos. Com a capacidade de gerar conteúdo dinâmico e adaptável, os jogos podem oferecer experiências praticamente infinitas, garantindo uma maior imersão e longevidade. Contudo, por se tratar de uma tecnologia emergente, ainda existem muitos

desafios e questionamentos válidos a serem superados e respondidos para que essa abordagem seja amplamente adotada na indústria de jogos.

A partir disso, é interessante entender como a integração de modelos de linguagem em jogos pode impactar a imersão e a jogabilidade, investigando os benefícios e desafios dessa abordagem. A ideia proposta sugere implementar um jogo que tem sua ideia principal baseada na integração com LLMs servindo como uma experimentação prática do potencial real impacto dessa tecnologia no futuro dos *videogames*.

## 4 JOGO BASEADO EM DIÁLOGO UTILIZANDO MODELOS DE LINGUAGEM

Como parte de uma experimentação prática, foi desenvolvido um jogo cuja principal mecânica principal é a integração com modelos de linguagem, mais precisamente o GPT-4. Inicialmente, será definida a intenção, o conceito e o *game design* estabelecido, para então abordar em detalhes a implementação e as tecnologias utilizadas.

O objetivo é criar uma experiência interativa e instigante, explorando a liberdade e flexibilidade proporcionada pela inteligência artificial. A hipótese central é que um jogo investigativo baseado em LLMs pode oferecer uma experiência mais dinâmica e imersiva do que um jogo com opções rígidas e diálogos previamente roteirizados. Isso se dá pela premissa que os modelos de linguagem permitem respostas variadas e contextualmente relevantes, se adaptando às perguntas dos jogadores de maneira orgânica. Assim, o jogo evita interações previsíveis e proporciona um ambiente de investigação mais autêntico, onde os jogadores precisam formular boas perguntas e interpretar respostas para avançar na narrativa.

Além disso, a utilização de LLMs possibilita múltiplos caminhos na investigação, permitindo que os jogadores extraiam informações por meio do diálogo com NPCs, construindo, assim, um enredo dinâmico e imersivo. Caso os testes com jogadores apresentem resultados positivos e *feedback* favorável, isso poderá indicar que os modelos de linguagem têm potencial para melhorar a experiência dos jogadores e serem amplamente utilizados no desenvolvimento de jogos no futuro.

### 4.1 CONCEITO E PROPOSTA DO JOGO

O jogo “Assassinato na Mansão Lehmann” é uma experiência investigativa baseada em diálogo, na qual o jogador assume o papel de um detetive encarregado de resolver um misterioso assassinato. O objetivo central é responder a perguntas cruciais, como: “Quem é o assassino?” ou “Qual foi a arma do crime?”. A narrativa se desenvolve por meio de interações com NPCs, que possuem personalidades distintas e oferecem respostas baseadas em seus traços psicológicos, histórico e intenções.

O caso investigado gira em torno da morte do empresário Fabrício Lehmann, encontrado boiando na piscina de sua mansão após um tiro à queima-roupa. Três personagens são considerados suspeitos e estão acessíveis para interrogação: A esposa da vítima, e também empresária

Laura Lehmann, o mordomo Alfredo, fiel à família há gerações e Paulo Yohen, sócio e investidor na empresa controlada pela família Lehmann. Além deles, o policial Ricardo se apresenta como peça chave nessa investigação por ter sido o responsável por reunir informações do crime e juntado os suspeitos na delegacia.

Paulo, Fabrício e Laura estavam reunidos para discutir a possibilidade da venda das ações das empresas Lehmann. Fabrício tinha bastante interesse em sua venda, o que não agradava Laura nem um pouco. Paulo estava naquele dia na mansão de Fabrício para discutir com seu colega a possibilidade de adquirir as ações da empresa. Alfredo apenas acompanhava tudo no seu papel como mordomo, após ter dispensado todos os funcionários da casa, ele sabia e tinha participação direta no plano que estava prestes a ser realizado.

Os personagens da história possuem diferenças marcantes em suas personalidades e histórias, com cada um deles compondo um elemento chave na investigação:

**Policial Ricardo:** Responsável por ter feito a investigação inicial e coletado algumas evidências do crime, irá guiar e auxiliar o jogador na investigação, provendo algumas das informações iniciais importantes para contextualizar o caso.

**Mordomo Alfredo:** Leal, discreto, mas ressentido. Ele é cúmplice do crime, ajudou a encobrir a verdadeira culpada e tentou incriminar Paulo. Sua lealdade havia acabado com a morte do antigo dono da empresa, o pai de Fabrício. Suas experiências pessoais com Fabrício contribuíram para que ele, mesmo que bastante receoso, fosse além e ajudasse no crime. Como principal virtude para auxiliar na investigação, ele é conhecido como um péssimo mentiroso, e fica nervoso quando pressionado.

**Paulo Yohen:** Apesar de temperamental e explosivo, ele é completamente inocente. Se tornou o suspeito número um devido às evidências que foram plantadas para incriminá-lo, como a arma do crime ter sido a sua própria arma pessoal e o fato de que ele tem um álibi fraco no horário do crime.

**Laura Lehmann:** Extremamente manipuladora e estrategista, uma excelente atriz e consegue mentir com uma facilidade impressionante. Planejou todo o crime para obter o controle da empresa, ela não poderia suportar a ideia de Fabrício seguir adiante com seu plano de vendê-la, ainda mais com a chance dela cair nas mãos de Paulo ao invés das suas. Viu no crime uma excelente oportunidade de se livrar de dois problemas de uma vez só ao incriminar Paulo, que estava lá em uma reunião de negócios.

A partir do diálogo e das descobertas que o jogador faz ao interrogar os personagens, ele deve analisar as respostas obtidas para encontrar inconsistências nos depoimentos e pistas

---

ocultas para então descobrir a verdade. Assim que o jogador se sentir confiante com as informações que tem, deve responder um questionário que contém algumas perguntas chaves para delimitar o que de fato aconteceu naquela noite, essas são as perguntas:

- Quem assassinou Fabrício Lehmann?
- Qual foi a arma utilizada e onde foi encontrada?
- Qual foi a motivação para o crime?
- Qual o horário aproximado do assassinato?
- Onde o assassinato aconteceu?
- Quem mais esteve diretamente envolvido no assassinato?
- Quem foi incriminado?
- Qual foi o plano elaborado para a realização do crime?

Respondendo a essas perguntas, o jogador terá concluído seu trabalho e poderá chegar ao seu veredito final sobre o que realmente aconteceu naquela noite.

## 4.2 MECÂNICAS E FUNCIONALIDADES

A principal mecânica do jogo se baseia em interrogar os NPCs por meio de um sistema de diálogo dinâmico. O jogador não está limitado com opções de diálogo e poderá digitar perguntas livremente, como: “O que estava fazendo no momento do crime?” ou então “Qual sua relação com a vítima?”. Com isso, descobrirá as informações relevantes e valiosas para desvendar o caso.

Inicialmente, apenas o Policial Ricardo estará disponível para conversar. Conforme o nome de um dos outros personagens for mencionado, o *chat* referente a aquele personagem é desbloqueado, liberando novas conversas. O jogador pode realizar qualquer pergunta que deseja, mas caso desvie muito do foco será orientado pelo NPC a fazer alguma pergunta mais relevante para a investigação. A todo momento o jogador pode trocar entre as conversas se desejar retomar ou começar a interrogação com algum outro personagem.

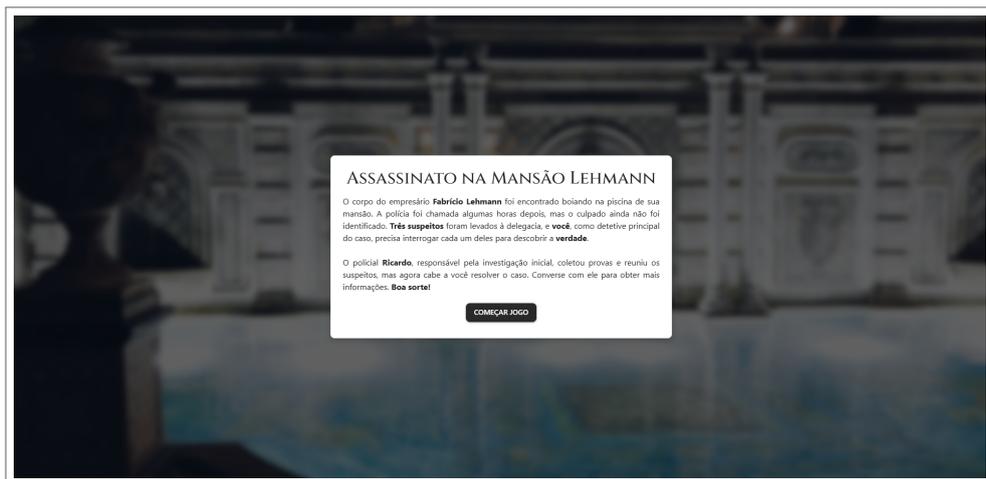
Por fim, quando o jogador estiver satisfeito com as suas descobertas, poderá tentar resolver o mistério, onde ele será apresentado ao questionário final. Com base na precisão das respostas,

irá receber uma classificação (Ruim, mediano ou ótimo), disponibilizada através de um texto descritivo sobre seu desempenho. Caso deseje, poderá reiniciar a investigação para explorar novas perguntas e aprimorar sua pontuação.

### 4.3 FLUXO DE TELAS

O fluxo de telas do jogo segue uma estrutura organizada para guiar o jogador durante a investigação. Inicialmente, ao começar o jogo, o jogador é direcionado para a tela inicial, onde são apresentadas informações básicas sobre a história e o objetivo da investigação. Nesta tela (Ver Figura 1), há um botão destacado, "Começar Jogo", que permite avançar para a experiência interativa.

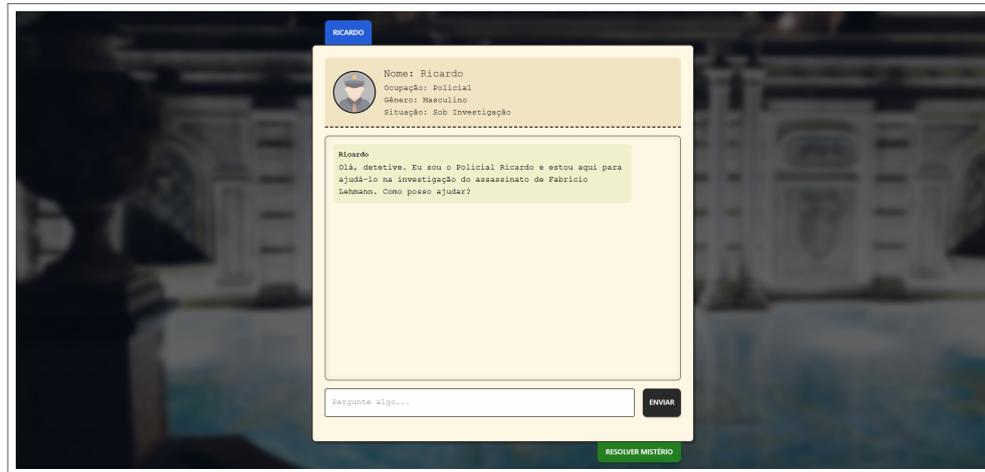
Figura 1 – Tela Inicial



Ao prosseguir, o jogador acessa a tela principal (Ver Figura 2), onde a investigação tem início. O primeiro personagem apresentado é o policial Ricardo, exibido em um cabeçalho contendo informações como nome, ocupação, gênero e situação. Nesta tela, o jogador tem acesso a uma caixa de texto, onde pode digitar suas perguntas, e ao histórico da conversa.

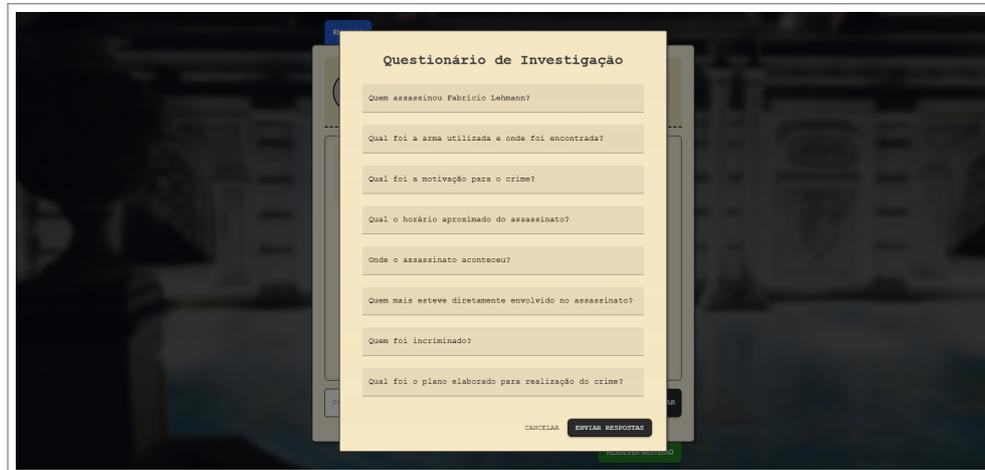
Conforme a investigação avança e novos personagens são mencionados, suas abas correspondentes são desbloqueadas e aparecem no topo da tela. Para indicar que um novo personagem está disponível para interrogatório, a aba correspondente pisca com a cor verde. O jogador pode alternar entre as conversas clicando nas respectivas abas, o que modifica o conteúdo da conversa exibida.

Figura 2 – Tela Principal



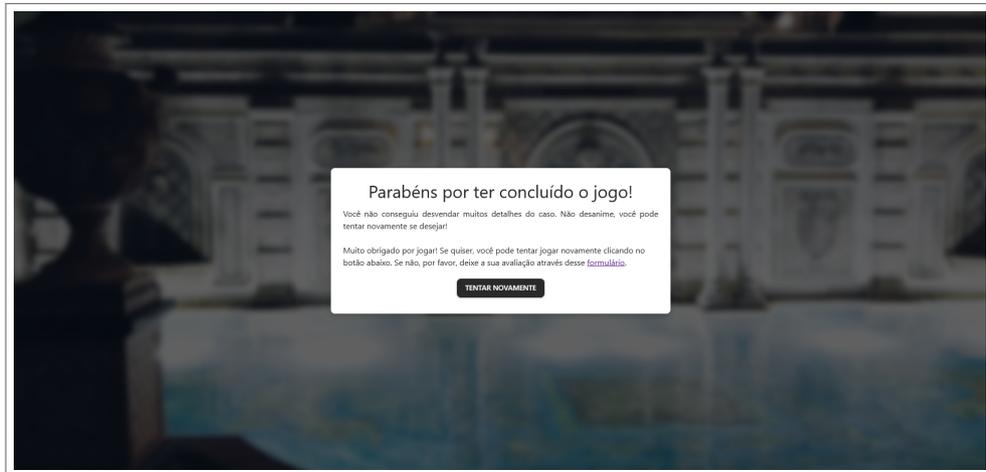
Abaixo da área de diálogo, há um botão denominado "Resolver Mistério", que permite ao jogador acessar o questionário final. Neste modal (Ver Figura 3), são apresentadas perguntas-chave relacionadas ao crime, como a identidade do assassino, a arma utilizada e a motivação do crime.

Figura 3 – Tela de Questionário



Por fim, ao concluir o questionário, o jogador é redirecionado para a tela de resultados (Ver Figura 4), onde recebe um *feedback* baseado em seu desempenho. O jogo exibe um texto condizente com o número de acertos e oferece a opção de tentar novamente por meio do botão "Tentar Novamente", para caso o jogador deseje jogar mais uma vez.

Figura 4 – Tela Final



## 5 IMPLEMENTAÇÃO TÉCNICA

A implementação do “Assassinato na Mansão Lehmann” baseia-se em um site desenvolvido em React (Meta, 2025) com *backend* em Node.js (OpenJS Foundation, 2025) e TypeScript (Microsoft, 2025), utilizando o Prisma (Prisma Labs, 2025) para a interação com o banco de dados PostgreSQL (PostgreSQL Global Development Group, 2025). A integração com modelos de linguagem é atingida fazendo uso das Application Programming Interface ou Interface de Programação de Aplicações (API) da OpenAI (OpenAI, 2025a), utilizando o modelo GPT-4o.

Além de dividir o projeto entre *frontend* e *backend*, grande parte do desenvolvimento focou na definição da estrutura ideal de *prompts* para otimizar a integração com as LLMs. A partir dos desafios enfrentados durante a implementação, tem-se uma ideia de potenciais desafios e benefícios encontrados na tentativa de trazer os modelos de linguagem para o cotidiano dos jogos digitais.

### 5.1 DESCRIÇÃO DA APLICAÇÃO DESENVOLVIDA

A estrutura do projeto foi dividida entre o *frontend* e o *backend*, com o uso das tecnologias descritas anteriormente.

#### 5.1.1 Frontend

O *frontend* foi desenvolvido com React, estruturado de forma a manter a modularidade e reutilização de componentes. As principais páginas do jogo são:

**WelcomeScreen:** Tela inicial do jogo.

**MainScreen:** Tela principal onde ocorre a interação entre jogador e NPCs.

**EndScreen:** Tela final do jogo, onde o resultado é apresentado ao jogador.

Os principais componentes utilizados são:

**BasePage:** Componente padrão utilizado para manter a consistência de layout entre as páginas.

**QuizDialog:** Modal que exibe o questionário final ao jogador.

**GameBody:** Estrutura central da tela de jogo, contendo as abas de interação.

**Chat:** Componente principal do jogo, onde ocorre a conversa entre o jogador e os perso-

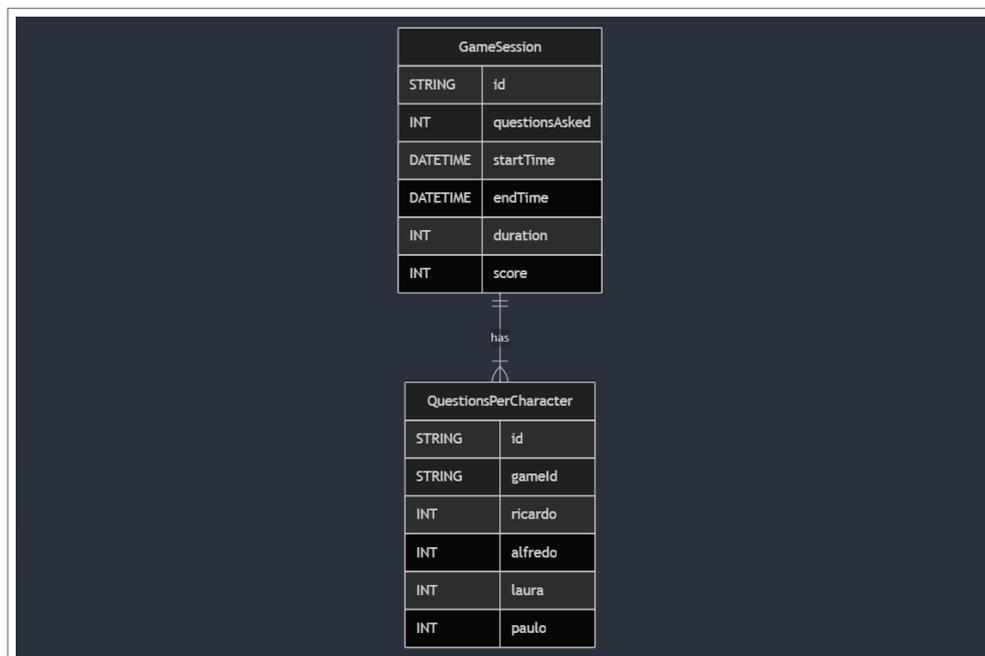
nagens.

**ChatHeader:** Cabeçalho do chat, exibindo informações sobre a investigação.

### 5.1.2 Backend

O *backend* foi desenvolvido utilizando as tecnologias Node.js e TypeScript, para o banco de dados foi utilizado PostgreSQL e Prisma. Sua implementação teve como principais objetivos evitar a exposição dos *prompts* de configuração e *API keys*, além de coletar métricas importantes sobre a jogabilidade, como a quantidade de perguntas feitas a cada NPC e o tempo total de jogo. Na Figura 5 é exibida a modelagem dos dados.

Figura 5 – Modelagem de Dados



## 5.2 INTERAÇÃO COM AS APIS E ESTRUTURA DE PROMPTS

Para gerenciar a interação com os NPCs e avaliar as respostas do jogador, foram criadas três principais APIs:

**start-game:** Responsável por inicializar e retornar a sessão do jogador.

**ask-question:** Atualiza o número de perguntas feitas e realiza a chamada para a API da OpenAI através da função `chatWithNPC()`.

**finish-game:** Finaliza a sessão do jogador e chama a função `evaluateAnswers()`, que realiza a chamada para a API da OpenAI com o intuito de avaliar as respostas do jogador.

### 5.2.1 Funções utilizadas

As APIs foram invocadas a partir da implementação das seguintes funções:

#### **chatWithNPC()**

Esta função configura a conversa entre o usuário e os personagens. Os parâmetros são os seguintes:

- **npcKey**: Nome do NPC.
- **messages**: Lista contendo todas as mensagens da conversa para aquele NPC.

Cada mensagem possui dois atributos:

- **role**: Define o papel da mensagem (*user*, *assistant* ou *developer*). *user* indica que é uma mensagem do usuário, *assistant* representa uma resposta do modelo e *developer* é usada para configurar o comportamento do modelo, sobrepondo outras instruções.
- **content**: Conteúdo da mensagem em si.

A interação com a API do ChatGPT é feita através da biblioteca OpenAI para Node.js, disponibilizada oficialmente pela OpenAI (OpenAI, 2025b). Inicialmente é necessário inicializar uma instância da OpenAI, passando uma chave de API. Essa chave requer autenticação na plataforma da OpenAI e é necessário um valor inicial de 5 dólares para obtê-la. A invocação ocorre através da função `openai.chat.completions.create()`, onde são passados alguns parâmetros:

- **Modelo desejado**: No desenvolvimento foi utilizado o GPT-4o.
- **Lista de mensagens**.
- **Parâmetros de customização**, como `max_completion_tokens`.

No caso da função de conversa, utilizou-se `max_completion_tokens` com valor 256, pois esse número evitou respostas excessivamente longas ou truncadas.

Além das mensagens da conversa, são adicionadas mensagens de configuração para moldar o comportamento do modelo. Por exemplo:

"Se forem feitas perguntas vagas, responda de uma forma vaga para que o detetive possa pedir mais detalhes, ou faça perguntas mais específicas."

Para cada um dos personagens, a estruturação dos *prompts* foi pensada numa separação entre configurações específicas para configurar o comportamento e fatos da história, com o objetivo de oferecer a contextualização necessária para o modelo.

As configurações específicas têm em mente moldar o comportamento com base no perfil de cada personagem como definido pelo roteiro. Exemplo para o personagem Alfredo:

"Ao proferir mentiras, você deve gaguejar ou hesitar. Você é um péssimo mentiroso."

Os fatos da história consistem em uma lista de frases objetivas com informações relevantes da história de forma geral e também informações conhecidas especificamente por aquele personagem. Essa estruturação foi feita como uma lista para permitir facilmente a adição, remoção ou manutenção de um fato em específico. A função de construção do prompt também recebe como parâmetro qual o NPC em questão para retornar as informações apropriadas. Esse é um exemplo de fato da história específico para Laura:

"Você afirma que estava no quarto lendo um livro no momento do crime, e que não ouviu nada."

Esse é um exemplo de fato geral, informado a todos os NPCs:

"A família Lehmann é conhecida por sua riqueza e influência na comunidade local."

Ao longo do desenvolvimento vários fatos e configurações foram removidas, adicionadas ou ajustadas com o objetivo de conseguir a melhor experiência possível ao jogador e que ao mesmo tempo mantivessem um certo nível de lógica e sentido com o roteiro escrito.

### **evaluateAnswers()**

Essa função recebe as respostas do jogador e avalia sua precisão em relação às respostas corretas. Um objeto de resposta é estruturado como a seguir:

```
{ "Qual foi a arma utilizada e onde foi encontrada?": "Revólver calibre .38, encontrada no carro de Paulo Yohen" }
```

A comparação entre a resposta do jogador e a resposta correta é feita via API da OpenAI, utilizando um prompt estruturado com as seguintes regras:

- A pontuação total é de 100 pontos.

- Cada questão tem peso igual.
- Respostas corretas recebem a pontuação máxima.
- Respostas parcialmente corretas recebem uma pontuação proporcional baseada na similaridade semântica.
- Respostas erradas ou ausentes recebem 0 pontos.

A partir dessas regras, o modelo compara as respostas corretas com as respostas do jogador e então retorna a pontuação. Para garantir consistência na saída, o formato de resposta é definido como `json_object` através do parâmetro `response_format`, assegurando que a pontuação seja sempre um valor entre 0 a 100. Isso é feito através dos *structured outputs* ofertados pela OpenAI e garantem que a formatação da resposta esteja necessariamente em JSON. Não foi necessário definir explicitamente os campos, apenas o atributo *score* é retornado.

A pontuação é utilizada para exibir um *feedback* ao jogador na tela de conclusão, essa foi a lógica definida:

- Acima de 65: *Feedback* positivo.
- Entre 30 e 65: *Feedback* neutro.
- Abaixo de 30: Sugestão para tentar novamente.

Foi necessário definir as regras de maneira bastante explícita, do contrário o modelo apresentava um comportamento muito imprevisível. Em algumas situações, informar uma das respostas certas retornava o valor 13, porém em outras o valor 40, afetando diretamente o que seria considerado um *score* alto ou baixo no jogo.

### 5.2.2 Definição de prompts para cada personagem

Cada personagem cumpre um papel específico no roteiro e tem um comportamento levemente diferente, esses detalhes foram todos levados em conta no momento de estruturar os *prompts* passados na chamada de API de cada um dos personagens. Como detalhado anteriormente, cada personagem possui dois tipos de *prompts* diferentes, o primeiro é responsável por configurar o comportamento dele com base em sua personalidade; o segundo serve para dar

---

contexto e indicar quais fatos aquela personagem tem conhecimento. Segue um detalhamento com alguns dos *prompts* usados para cada um dos personagens.

### **Policia Ricardo**

Ricardo é um personagem simples que serve apenas para dar contexto do caso para o jogador, portanto sua personalidade não é tão elaborada e ele precisa apenas se ater em responder perguntas diretas sobre o caso, por isso seus *prompts* foram estruturados da seguinte forma:

"Você deve fornecer informações relevantes ao detetive, mas não revelar tudo de uma vez."

"Tente não informar todas as informações de uma vez, para que o detetive possa fazer perguntas mais específicas. Mantenha um diálogo engajante e natural."

"Oriente o detetive a direcionar as perguntas para os suspeitos caso você não tenha as informações necessárias."

Esses são alguns fatos conhecidos por Ricardo, também informados a ele por meio de instruções:

"O horário estimado da morte de Fabrício Lehmann é entre 22h e 23h, de acordo com a autópsia."

"Os registros das câmeras de segurança da mansão pararam de funcionar cerca de 2 semanas antes do crime."

"Laura Lehmann alega que estava no quarto lendo um livro no momento do crime, e não ouviu nada."

Com isso, o personagem já apresentou um comportamento satisfatório, sem ser necessária nenhuma configuração mais complexa.

### **Mordomo Alfredo**

Alfredo é um personagem vital por ter participação direta no assassinato já que foi cúmplice de Laura. Por isso, foi interessante adicionar algumas características que facilitassem o descobrimento de fatos importantes pelo jogador. A ideia central é que ele não é um bom mentiroso e é possível obter informações críticas dele ao fazer várias perguntas insistentes sobre um tópico ou então perguntas bem direcionadas. Com isso em mente, esses foram alguns *prompts* de configuração passados para ele, com o objetivo de ajustar seu comportamento nessa direção:

"Ao proferir mentiras, você deve gaguejar ou hesitar. Você é um péssimo mentiroso."

"Você responde e conversa de forma elegante, mas está ansioso depois de tudo o que aconteceu."

"Você deve responder às perguntas do detetive tentando parecer inocente e esconder seu envolvimento."

Esses são alguns fatos conhecidos por Alfredo, também passados como instrução, sendo possível ao jogador obtê-los através do diálogo com o personagem:

"Apesar de sua lealdade à família, nunca gostou de Fabrício."

"Você foi orientado por Laura a liberar o resto dos funcionários da casa mais cedo, porém era um procedimento comum para uma reunião de negócios."

"Você levou o casaco de Laura para ela, as cerca de 22:00, você só irá informar isso se for pressionado, você dirá que sentiu que ela estaria com frio naquela temperatura, e não que foi ela quem pediu o casaco."

Como no exemplo acima, os fatos mais críticos, que deveriam ser revelados apenas sob pressão já que Alfredo não era bom mentiroso, eram indicados diretamente no *prompt*. A partir disso, o comportamento da conversa já estava adequado e é possível obter essas informações fazendo perguntas específicas ou sendo insistente sobre esse acontecimento. Por exemplo, ao perguntar diretamente "Laura quem pediu o casaco para você?", o personagem irá responder e explicar o que aconteceu corretamente. Porém, essa informação não irá ser revelada com uma pergunta vaga como "O que fazia às 22 horas?".

### **Paulo Yohen**

Paulo também é peça-chave para o entendimento do caso, já que houve uma tentativa de incriminá-lo. Ele será sempre sincero em suas respostas e irá revelar tudo que sabe ao jogador, porém também é necessário realizar perguntas direcionadas. Paulo tem um temperamento forte portanto demonstrará indignação ao ser acusado ou ao descobrir que está sendo incriminado. Esses foram alguns *prompts* de configuração utilizados.

"Você deve responder às perguntas do detetive com indignação e nervosismo, pois sabe que está sendo incriminado injustamente."

"Você é extremamente temperamental e impulsivo, o que pode te prejudicar durante o interrogatório."

"Caso comece a ser pressionado, comece a se exaltar e falar mais alto, utilizando exclamações."

Esses são alguns fatos conhecidos por ele:

"Você foi convidado por Fabrício para um jantar naquela noite, para discutir a venda das ações da empresa."

"Se pressionado você irá informar que achou estranho o fato que teve um sono muito pesado, achou um pouco estranho porque você costuma ter dificuldade em pegar no sono. Mas na hora não deu importância pois a reunião foi longa."

"Após ser um pouco mais questionado e pressionado, você irá se lembrar que em certo momento enquanto cochilava, ouviu o barulho de alguém indo para a área da piscina.",

Com isso, o personagem também apresentou um comportamento adequado. Com o objetivo de trazer um senso de progressão ao jogo, e para evitar que acontecimentos vitais fossem revelados muito cedo, alguns dos fatos conhecidos por Paulo só eram revelados após certa insistência ou perguntas direcionadas. Para que perguntas como "O que de estranho aconteceu aquela noite?" revelem de imediato todas as partes mais importantes da história.

### **Laura Lehmann**

Laura, sendo a culpada do crime, apresentava um comportamento definitivamente suspeito. A intenção foi passar isso a partir dos *prompts*, para gerar suspeita no jogador. Alguns exemplos de instruções de configuração utilizadas:

"Você está sendo interrogada pelo detetive sobre o caso, mas deve esconder seu envolvimento no crime."

"Você deve demonstrar luto e tristeza pela morte do seu marido."

"Se for acusada você entrará bastante na defensiva e irá ofender e ser agressiva com o detetive."

---

Laura sabe de vários fatos vitais, afinal é a grande culpada, porém ela é orientada a não revelar isso em nenhum momento. Exemplos de alguns fatos conhecidos por ela:

"Você realmente sentiu a morte de Fabrício, não esperava que as coisas chegassem a esse ponto."

"Você não informará isso ao detetive, mas se ele perguntar sobre o casaco, você dirá que estava com frio enquanto conversava com Fabrício, e por isso pediu para Alfredo lhe trazer."

"Se pressionada, você dirá que estava passando um pouco mal no dia e que não se lembrar muito bem de alguns acontecimentos."

Apesar do modelo ter conhecimento dos seus atos a partir dos *prompts*, ele mantinha isso muito bem em segredo, e a partir de alguns questionamentos, apresentava um comportamento suspeito, evitando algumas respostas. Isso foi o ideal para o progresso do jogo. Contextualizar o modelo com alguns fatos que a personagem realmente fez, mesmo que não fossem revelados ao jogador, serviu como uma boa forma de contextualizar o modelo e obter respostas melhores, já que agora ele tinha conhecimento também do que evitar responder.

Com isso, a partir dos testes manuais realizados, os modelos já apresentaram resultados satisfatórios, não sendo necessário ajustar os parâmetros além dos previamente definidos. Optou-se por manter a experimentação simples, evitando a introdução de novas variáveis, como ajustes de temperatura ou outros hiperparâmetros, pois o modelo, mesmo em sua configuração padrão e com os prompts aplicados, demonstrou um comportamento coerente e eficaz. Observou-se que os modelos se mostraram fiéis às instruções fornecidas, exibindo consistência e qualidade nos depoimentos gerados. A estrutura de fatos e configurações previamente estabelecida revelou-se robusta, permitindo que os NPCs respondessem de forma convincente desde as primeiras interações. Com base nesses resultados iniciais positivos, seguiram-se os testes com usuários, com o objetivo de obter uma avaliação mais ampla e detalhada da experiência.

O código-fonte pode ser encontrado através do *link*: <<https://github.com/MarcosND/tg-project>>

## 6 AVALIAÇÃO DA EXPERIÊNCIA DOS USUÁRIOS

A fim de validar o potencial dos LLMs em aprimorar a experiência dos jogos digitais, foram realizados testes com usuários a partir da implementação apresentada. Esses testes buscaram obter *feedbacks* sobre a experiência do jogador e identificar áreas de melhoria. Para isso, foi elaborado um formulário de avaliação disponibilizado após a conclusão do jogo, buscando capturar aspectos quantitativos e qualitativos da experiência. Além disso, métricas como tempo médio de jogo, número total de perguntas e interações por personagem foram coletadas. O jogo foi disponibilizado *online* utilizando a plataforma Railway (Railway Corporation, 2025) para *deployment*.

### 6.1 METODOLOGIA DE AVALIAÇÃO

A fim de avaliar a experiência dos jogadores, foi adotada uma combinação de dados quantitativos e qualitativos. Para isso, foi elaborado um formulário com perguntas estruturadas em quatro seções:

**Perfil do Jogador:** Coleta de dados demográficos e preferências de jogo, como gêneros favoritos, idade e frequência de jogo.

**Experiência geral durante o jogo:** Aplicação de uma escala Likert de 1 (discordo totalmente) a 5 (concordo totalmente) para medir a percepção dos jogadores sobre a experiência, com afirmações como "Tive uma experiência positiva no geral" ou "Apreciei a flexibilidade e liberdade oferecidas pelo jogo".

**Funcionalidade de Diálogo:** Avaliação específica do sistema de conversação baseado em LLMs, também medida por meio da escala Likert. Os jogadores avaliaram aspectos como repetitividade e naturalidade das respostas, com afirmações como "As respostas geradas foram repetitivas" ou "O diálogo soou natural e realista baseado no contexto". A análise dessa seção é essencial para medir a eficácia dos LLMs em proporcionar interações realistas (SVIKHNUSHINA; PU, 2022).

**Feedback Geral e Experiências Futuras:** Seção com questões abertas para que os jogadores expressem suas opiniões sobre os aspectos mais apreciados e sugerir melhorias.

Além das respostas do formulário, foram coletados dados quantitativos durante as sessões de jogo, incluindo métricas como tempo médio de jogo, número total de perguntas feitas pelos

jogadores e número de perguntas feitas para cada um dos personagens. Essas informações permitem uma análise objetiva do impacto da mecânica baseada em LLMs e complementam os *insights* qualitativos e quantitativos extraídos dos *feedbacks* dos participantes.

A análise dos dados foi realizada por meio de estatísticas descritivas para os dados quantitativos e categorização temática para os *feedbacks* qualitativos. A seguir, são apresentados os principais resultados obtidos.

## 6.2 RESULTADOS E ANÁLISE

Esta seção apresenta os resultados obtidos através da coleta de dados e *feedbacks* dos usuários, com o objetivo de entender e analisar a experiência geral observada pelos usuários.

### 6.2.1 Perfil dos participantes

A amostra foi composta por 11 participantes, majoritariamente entre 18 e 23 anos, caracterizado por um público jovem e familiarizado com jogos digitais (Ver Tabela 1). A frequência de jogo variou entre algumas vezes por semana e diariamente, refletindo um público com experiência significativa no meio.

Tabela 1 – Distribuição da faixa etária dos participantes

<b>Faixa Etária</b>	<b>Quantidade</b>
Abaixo de 18 anos	2
18 a 23 anos	7
24 a 30 anos	2
<b>Total</b>	<b>11</b>

Os gêneros de jogos mais apreciados pelos participantes foram Aventura, RPG, Ação e *Shooters*, o que sugere um perfil de jogador que valoriza narrativas envolventes e mecânicas de progressão.

Os dados sobre a frequência com que os participantes jogam videogames (Tabela 2) reforçam o perfil de um público já habituado ao meio. Como pode ser observado, a maioria dos jogadores joga pelo menos algumas vezes por semana, com uma parcela significativa jogando diariamente. Esse fator sugere que os participantes possuem familiaridade com mecânicas e sistemas comuns em jogos digitais, o que pode influenciar na forma como interagem com o

Tabela 2 – Frequência com que os participantes jogam videogames

<b>Frequência</b>	<b>Quantidade</b>
Todos os dias	4
Algumas vezes por semana	5
Algumas vezes por mês	1
Nunca	1
<b>Total</b>	<b>11</b>

jogo desenvolvido. Jogadores frequentes tendem a se adaptar mais rapidamente a novas experiências e podem ter uma compreensão mais intuitiva das dinâmicas propostas, o que pode impactar sua percepção sobre a fluidez da narrativa e da mecânica baseada em LLMs.

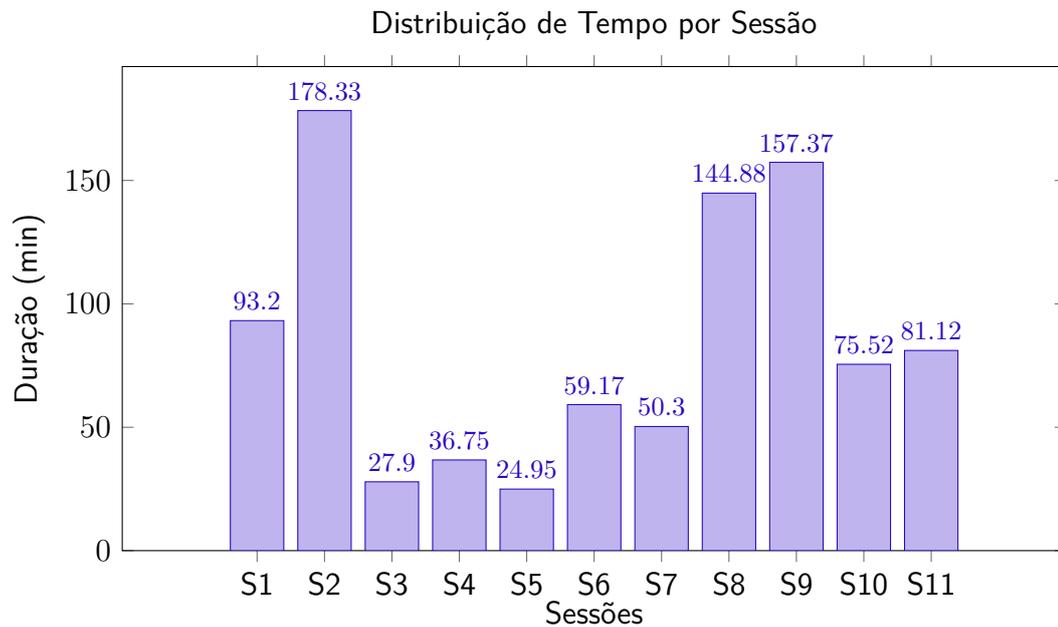
### **6.2.2 Estatísticas gerais sobre as sessões dos usuários**

Durante a sessão de jogo dos usuários foram coletadas algumas métricas que ajudam a entender o tempo médio de jogo, o número médio de perguntas feitas e quais NPCs foram mais requisitados. A análise dessas métricas oferece uma visão sobre o engajamento dos jogadores e a interação com os personagens virtuais.

#### **Tempo médio de jogo**

O tempo médio de uma sessão de jogo foi de aproximadamente 1 hora e 24 minutos. O tempo total variou significativamente entre os jogadores, com a sessão mais curta durando 24 minutos e 57 segundos, enquanto a mais longa se estendeu por 2 horas e 58 minutos. O jogador poderia a qualquer momento parar de jogar e voltar algum tempo depois, portanto o intervalo não representa um tempo contínuo de jogo mas apenas o tempo que a sessão ficou aberta. A Figura 6 apresenta a distribuição do tempo entre as diferentes sessões.

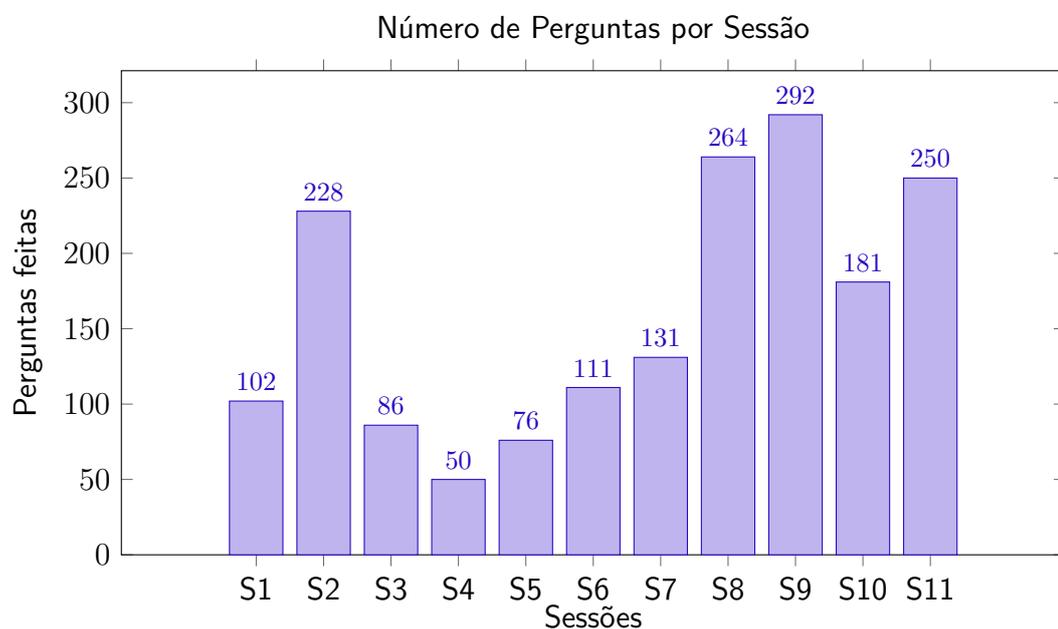
Figura 6 – Gráfico de Barras com a distribuição de tempo por sessão



### Número médio de perguntas feitas

Os jogadores fizeram em média 161 perguntas por sessão. A quantidade de perguntas variou de 50 perguntas para a menor quantidade de perguntas feitas até 292 perguntas na maior. O alto número médio de perguntas reforça o engajamento proporcionado pela mecânica de diálogo baseada em modelos de linguagem, indicando que os jogadores exploraram ativamente as interações para avançar na investigação. A Figura 7 apresenta a distribuição de perguntas totais feitas por sessão.

Figura 7 – Gráfico de Barras com o número total de perguntas por sessão



### **NPCs mais requisitados**

Os personagens não jogáveis (NPCs) foram questionados com diferentes frequências. A Tabela 3 apresenta a distribuição do número médio de perguntas feitas a cada NPC.

Tabela 3 – Média de perguntas feitas por sessão a cada NPC

<b>NPC</b>	<b>Média de Perguntas por Sessão</b>
Ricardo	29
Alfredo	49
Laura	44
Paulo	40

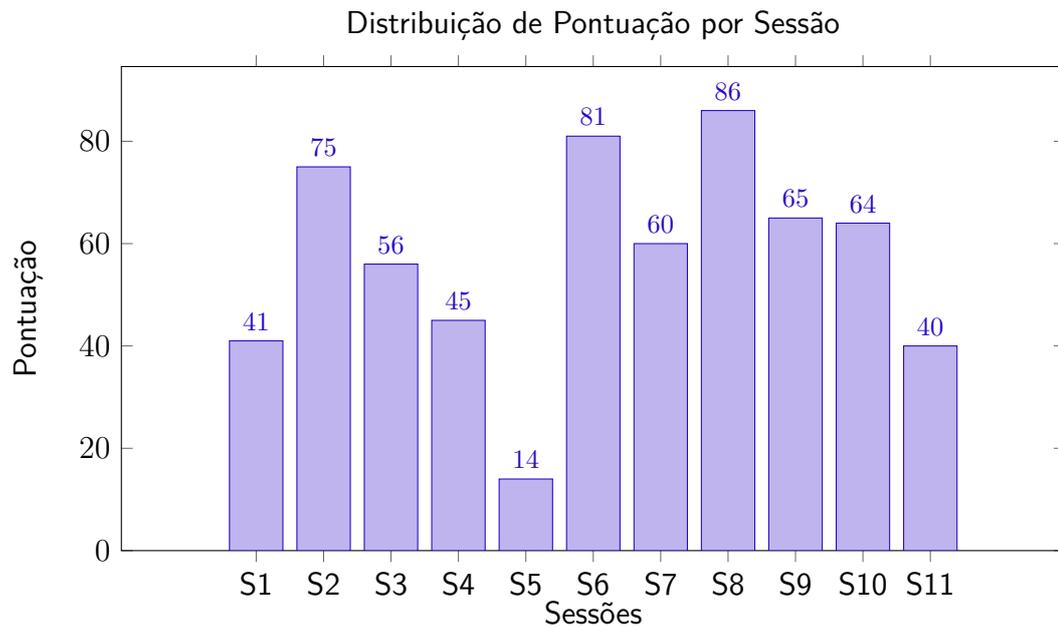
O NPC Alfredo foi o mais questionado, indicando que os jogadores o consideram uma fonte importante de informações no jogo, enquanto Ricardo foi o menos questionado. Isso faz sentido com relação ao propósito de cada um: enquanto Ricardo serve como uma porta de entrada para as investigações, Alfredo é a peça-chave, sendo mais propenso a delatar informações e também estando diretamente envolvido no plano.

### **Relação entre pontuação e perguntas feitas**

A pontuação média dos jogadores foi de aproximadamente 54,5 pontos, com a pontuação mais baixa registrada em 14 pontos e a mais alta em 86 pontos. Observa-se que as sessões com um maior número de perguntas geralmente resultaram em pontuações mais elevadas. Por exemplo, a sessão com a maior pontuação (86 pontos) foi uma das que tiveram um alto número de perguntas (264 perguntas). Por outro lado, a sessão com a pontuação mais baixa (14 pontos) registrou apenas 76 perguntas.

Essa relação sugere que um maior envolvimento na investigação, expresso pelo número de perguntas feitas, pode ter contribuído para melhores resultados. Para reforçar essa análise, a Figura 8 apresenta a distribuição de pontuação por sessão.

Figura 8 – Gráfico de barras com a distribuição de pontuação por sessão



Essas estatísticas fornecem algumas noções importantes sobre a interação dos jogadores com o jogo, ajudando a entender um pouco do comportamento exercido pelos jogadores durante a experiência e dados valiosos sobre o jogo de modo geral.

### 6.2.3 Avaliação da experiência geral do jogo

A partir dos dados obtidos como resposta do formulário, algumas métricas também foram obtidas. De modo geral, a recepção do jogo foi positiva, com a maioria dos participantes atribuindo notas entre 4 e 5 para perguntas que tinham como objetivo medir a experiência geral.

Os principais pontos destacados incluem:

- **Engajamento:** A maioria relatou que se sentiu envolvida durante a investigação;
- **Dificuldade:** O nível de desafio foi considerado adequado pela maioria;
- **Satisfação:** Descobrir informações ao longo da investigação foi uma experiência instigante para a maioria dos jogadores.

Na Tabela 4, são apresentadas as perguntas feitas nessa seção e as respectivas medianas dos resultados obtidos:

Tabela 4 – Mediana das respostas às perguntas sobre a experiência geral dos jogadores

Perguntas	Mediana
Senti que tive uma experiência positiva no geral	5
Me senti engajado e envolvido pelo jogo	5
Senti que o nível de dificuldade foi adequado	4
Senti satisfação ao descobrir informações durante o jogo	5
Achei a proposta do jogo inovadora e interessante	5
Gostei da flexibilidade e experiência mais livre do jogo	5
Acredito que teria uma experiência pior se as opções de diálogo fossem rígidas	5

É interessante destacar como as duas últimas perguntas tiveram um alto nível de aceitação, indicando que o principal benefício trazido pela integração com modelos de linguagem (LLMs) de fato agregou valor à experiência dos usuários.

#### 6.2.4 Interação com IA e mecânica principal do jogo

A interação com NPCs baseados em IA foi a mecânica central e o grande diferencial do jogo. Os participantes observaram que o sistema oferecia um nível significativo de liberdade na investigação, tornando a experiência mais imersiva e dinâmica.

Os principais pontos destacados incluem:

- **Exploração:** A possibilidade de fazer perguntas ilimitadas aumentou a vontade de explorar mais o jogo.
- **Inovação:** A IA foi percebida como um diferencial inovador.
- **Direcionamento:** Alguns jogadores apontaram a necessidade de mais guias ou dicas para auxiliar na condução da investigação.

Na Tabela 5, segue as perguntas feitas nessa seção e a mediana do resultado obtido para cada uma delas.

Tabela 5 – Mediana das respostas às perguntas sobre a interação com a IA

Perguntas	Mediana
As respostas geradas foram repetitivas	2
As respostas geradas foram coerentes e úteis	4
Fiquei confuso ou perdido com algumas das respostas geradas	3
O diálogo soou natural e realista baseado no contexto	5
O fato de serem geradas respostas diferentes aumenta minha vontade de jogar novamente	5
Tive momentos onde minha pergunta não foi entendida corretamente	2
Me senti engajado durante a conversa	5
Poder fazer perguntas ilimitadas aumenta minha vontade de jogar	5
Tiveram momentos onde senti uma certa fricção no diálogo	2

É interessante observar que, nas perguntas que buscavam avaliar o quão suave foi a interação entre os jogadores e a Inteligência Artificial, algumas respostas obtiveram notas mais baixas. Isso sugere que ainda há espaço para melhorias, especialmente no sentido de reduzir o nível de fricção no diálogo e tornar a experiência mais fluida e natural.

Apesar disso, o fato de a IA gerar respostas variadas foi um dos aspectos mais bem avaliados, indicando que essa capacidade de gerar conteúdo quase que de forma infinita é percebida como um diferencial relevante e um fator que enriquece a experiência dos usuários.

### 6.2.5 Feedbacks Qualitativos

Além das avaliações quantitativas, os participantes também forneceram *feedbacks* abertos sobre o que mais gostaram e o que poderia ser melhorado no jogo.

#### Pontos mais apreciados

Entre os pontos mais apreciados por praticamente todos os participantes, destacou-se a sensação de liberdade na investigação, a oportunidade de conduzir todo o processo investigativo de forma autônoma e de controlar diretamente os acontecimentos. A imersão proporcionada pelas respostas geradas pela IA também foi amplamente valorizada.

Aqui estão algumas avaliações feitas a partir da pergunta “O que mais gostou no jogo?”:

“A simulação de conversar com ‘pessoas’ envolvidas em um crime, com liberdade para fazer minhas próprias perguntas. Achei a mecânica EXCELENTE.”

“A liberdade e interação com o jogo proporcionam uma imersão incrível. Observar as nuances dos personagens e aplicá-las foi muito bom.”

“O fato de eu poder fazer minhas próprias perguntas e a IA gerar respostas, ao invés de perguntas prontas, fez com que eu não me sentisse guiado pelo jogo.”

A partir dessas respostas, é possível concluir que os usuários se sentiram genuinamente instigados pela imersão proporcionada pelas IAs, que geraram respostas dinâmicas e promoveram um alto grau de liberdade nas interações.

### **Sugestões de melhorias e percepções para o futuro**

A maioria das sugestões de melhorias se concentrou em fatores não diretamente relacionados à integração com LLMs, como, por exemplo, a adição de novas funcionalidades ao jogo, como a implementação de dicas ou ajustes na interface.

Essas sugestões podem servir como base para futuras iterações do jogo, com o objetivo de aprimorar a experiência do usuário de forma geral. No entanto, elas oferecem pouco impacto na motivação principal da pesquisa, que foca no uso dos modelos de linguagem para melhorar a imersão e a liberdade na interação do jogador com o jogo.

As avaliações mostram que, de maneira geral, os jogadores ficaram satisfeitos com o jogo. Cerca de 90,9% afirmaram que definitivamente jogariam jogos desse estilo novamente, enquanto os 9,1% restantes indicaram que talvez o fizessem.

Além disso, 81,8% dos participantes acreditam que o uso de modelos de linguagem ou IAs em jogos tem o potencial de melhorar a experiência dos jogadores, enquanto 18,2% consideram que isso poderia, mas não necessariamente, trazer melhorias.

## 7 LIÇÕES APRENDIDAS DURANTE O DESENVOLVIMENTO

Durante o desenvolvimento, observou-se a necessidade de estruturar cuidadosamente os *prompts*. Pequenas variações podiam levar a respostas inconsistentes e divergentes. Afinal de contas, um desafio comum ao realizar integrações com LLMs são as alucinações, que ocorrem quando os NPCs tentam inventar informações irrelevantes ou falsas para a história. Para um jogo de investigação, as alucinações podem comprometer completamente a experiência do jogador, por esse motivo foi preferível evitar que os modelos contassem mentiras explícitas, e como alternativa, apenas omitirem a revelação de algumas informações até serem pressionados. A estrutura dos *prompts* foi refinada para garantir que cada NPC mantivesse uma personalidade distinta e contribuísse para a investigação do jogador de maneira natural e imersiva com base nesses desafios.

Devido a esses fatores, a utilização dos *prompts* de configuração foi fundamental para evitar, principalmente, a revelação de informações antes do momento adequado ou que não fossem relevantes para o caso. As instruções listadas a seguir foram as mais importantes e eram aplicadas a cada interação com o jogador:

"Você faz parte da investigação do assassinato de Fabrício Lehmann. Responda às perguntas do detetive com base nas informações que você possui."

"Não tente inventar informações que você não tem conhecimento. Se forem feitas perguntas que você não sabe responder, diga que isso não é relevante para o caso."

"Responda apenas estritamente o que lhe foi perguntado, sem adicionar informações desnecessárias. Responda sempre em menos de três frases."

"Responda com as informações apenas se algo tiver sido especificamente perguntado."

Esses *prompts* guiaram as respostas geradas pelos modelos, contribuindo para um resultado satisfatório. A obtenção de informações durante os interrogatórios não era trivial, o que tornou a experiência mais desafiadora e envolvente. Para acessar respostas-chave, os jogadores precisavam formular perguntas direcionadas, o que aumentava o nível de entretenimento e incentivava a imersão na investigação.

Outro desafio foi a natureza de caixa-preta dos modelos de linguagem. Ao utilizar um modelo como o GPT, seus parâmetros e decisões são um mistério, e o algoritmo funciona de forma conhecida apenas pelos seus desenvolvedores. Isso é evidente quando em alguns momentos mesmo com *prompts* explícitos, as respostas geradas não são desejadas e não é possível entender exatamente o motivo. Um exemplo disso aconteceu na função `evaluateAnswers()`, mesmo com uma instrução clara para retornar apenas um número, o modelo continuava trazendo respostas em escrito, sendo necessário definir o tipo da resposta de forma rígida.

Em contrapartida, um dos principais benefícios do uso de LLMs é a capacidade de configurar rapidamente o comportamento de NPCs apenas com texto fazendo uso dos *prompts*, agilizando consideravelmente o tempo de desenvolvimento. Como exemplo prático, um problema identificado foi que o modelo sempre adicionava frases como “Como posso lhe ajudar agora?” após cada mensagem da conversa, quebrando a imersão da conversa e diminuindo o realismo. Ao adicionar *prompts* de configuração como:

"Evite perguntar a todo momento se o detetive tem algo mais a perguntar, para que a conversa soe de forma mais natural."

"Adicione reticências e pausas em suas respostas para que a conversa soe mais natural."

Essa questão foi rapidamente resolvida, e o modelo começou a apresentar um comportamento mais realista e imersivo.

É possível notar, então, que a configuração de comportamentos específicos para cada personagem, baseada em suas características, e a definição de um certo ritmo de progressão no jogo foram possíveis graças à flexibilidade dos modelos de linguagem através da engenharia de *prompt*.

No entanto, o maior desafio durante o desenvolvimento foi, sem dúvidas, delimitar com precisão a história e os fatos conhecidos por cada personagem. Isso se mostrou essencial para evitar que os modelos, ao serem questionados sobre algo desconhecido, inventassem informações, o que poderia comprometer a coerência do roteiro.

Para mitigar esse problema, foi necessária uma inspeção minuciosa dos fatos atribuídos a cada personagem. Ainda assim, quanto maior o roteiro e mais complexa a história, mais desafiador se torna esse processo em projetos futuros. Esse é, definitivamente, um dos maiores desafios ao desenvolver jogos baseados em modelos de linguagem: garantir que todas as

informações relevantes sejam configuradas corretamente e passadas como instruções. Esse processo exige extensas sessões de testes para minimizar inconsistências e assegurar a integridade narrativa.

Um exemplo prático dessa questão ocorreu com o personagem Paulo Yohen. Como não foi definida claramente a localização original de sua arma em nenhuma de suas instruções, o modelo gerava respostas inconsistentes quando questionado sobre esse detalhe. Em algumas interações, ele afirmava que a arma estava em seu cofre; em outras, mencionava que ela se encontrava em seu escritório. Essas variações interferiam diretamente na investigação do jogador, tornando evidente a necessidade de maior controle sobre as informações fornecidas ao modelo.

Os refinamentos mencionados anteriormente foram fundamentais para garantir uma conversa fluida e realista entre o jogador e os personagens, demonstrando a notável flexibilidade na configuração desses modelos. Esse processo foi essencial para reduzir problemas conhecidos no uso de modelos de linguagem, como alucinações e a revelação prematura de informações relevantes para a investigação. Como resultado, durante a fase de testes, observou-se um mínimo de inconsistências, e o modelo se comportou de maneira coerente com as instruções definidas nos *prompts*.

## 8 CONCLUSÃO

A pesquisa realizada neste trabalho demonstrou que os modelos de linguagem, como o GPT, oferecem um potencial significativo para transformar a experiência geral em jogos digitais. O *feedback* obtido através da pesquisa com jogadores foi amplamente positivo, com a maioria dos participantes destacando a melhoria na qualidade da interação e o aumento da imersão proporcionado pelos NPCs interativos.

No entanto, apesar do potencial identificado, algumas limitações deste estudo devem ser consideradas. Primeiramente, a pesquisa contou com apenas 11 participantes, o que representa uma amostra relativamente pequena e pode não ser suficientemente representativa da experiência de um público mais amplo. Além disso, há o risco de viés de resposta, pois os jogadores que participaram do estudo tinham um interesse maior em tecnologia ou inteligência artificial e uma experiência considerável em jogos digitais, influenciando suas percepções sobre a experiência.

Apesar disso, ainda há alguns desafios a serem superados, foi observado uma grande dificuldade na configuração dos LLMs para evitar alucinações e inconsistências na narrativa. Embora a engenharia de *prompt* tenha ajudado a mitigar esses problemas, jogos mais complexos demandam um controle ainda mais rigoroso sobre o conhecimento dos NPCs para garantir coerência na experiência. Além disso, o custo computacional e a latência da geração de respostas podem ser fatores críticos para a escalabilidade dessa abordagem em jogos comerciais considerando um escopo ainda maior.

É fundamental que os desenvolvedores de jogos considerem cuidadosamente como e quando integrar LLMs em seus projetos. O *game design* deve ser estratégico ao decidir se é válido ou não usar tais modelos, considerando o tipo de jogo, os recursos disponíveis e o impacto que a integração de LLMs pode ter na narrativa e na jogabilidade. A adaptação de um modelo de linguagem para um jogo exige um equilíbrio entre complexidade técnica e a capacidade de criar uma experiência autêntica e envolvente para o jogador.

Os LLMs apresentam um enorme potencial para evoluir ainda mais o design de jogos, permitindo não apenas NPCs interativos, mas também a criação de enredos adaptativos que reagem às escolhas dos jogadores de maneira mais natural e personalizada. Outras possíveis funcionalidades incluem a adaptação da dificuldade do jogo com base no comportamento do jogador e a introdução de mecânicas de narrativa que permitem aos jogadores explorar histórias

únicas e não lineares.

Portanto, embora ainda existam desafios técnicos a serem superados, como a precisão e a consistência das respostas, os resultados obtidos sugerem que os LLMs têm o potencial de se tornar uma parte fundamental do futuro dos jogos digitais, abrindo novas possibilidades de design e proporcionando experiências cada vez mais ricas e imersivas para os jogadores.

## REFERÊNCIAS

- Bethesda Game Studios. *The Elder Scrolls V: Skyrim*. 2011. Disponível em: <<https://elderscrolls.bethesda.net/skyrim>>.
- BOMMASANI, R.; HUDSON, D. A.; ADELI, E.; ALTMAN, R.; ARORA, S.; ARX, S. von et al. On the opportunities and risks of foundation models. *arXiv preprint arXiv:2108.07258*, 2021. Disponível em: <<https://arxiv.org/abs/2108.07258>>.
- BROWN, T.; MANN, B.; RYDER, N.; SUBBIAH, M.; KAPLAN, J.; DHARIWAL, P.; NEELAKANTAN, A.; SHYAM, P.; SASTRY, G.; ASKELL, A. et al. Language models are few-shot learners. *NeurIPS*, 2020. Disponível em: <<https://arxiv.org/abs/2005.14165>>.
- BUBECK, S.; CHANDRASEKARAN, V.; ELDAN, R.; GEHRKE, J.; HORVITZ, E.; KAMAR, E.; LEE, P.; LEE, Y. T.; LI, Y.; LUNDBERG, S.; NORI, H.; PALANGI, H.; RIBEIRO, M. T.; ZHANG, Y. Sparks of artificial general intelligence: Early experiments with gpt-4. *arXiv preprint arXiv:2303.12712*, 2023.
- Hello Games. *No Man's Sky*. 2016. Disponível em: <<https://www.nomanssky.com/>>.
- Latitude. *AI Dungeon*. 2019. Disponível em: <<https://play.aidungeon.io/>>.
- MALEKI, M. F.; ZHAO, R. Procedural content generation in games: A survey with insights on emerging llm integration. *ArXiv*, 2024. Disponível em: <<https://doi.org/10.1609/aiide.v20i1.31877>>.
- Meta. *React: A JavaScript library for building user interfaces*. 2025. Disponível em: <<https://react.dev/>>.
- Microsoft. *TypeScript: JavaScript with syntax for types*. 2025. Disponível em: <<https://www.typescriptlang.org/>>.
- Mojang Studios. *Minecraft*. 2011. Disponível em: <<https://www.minecraft.net/>>.
- Nicalis. *The Binding of Isaac*. 2011. Disponível em: <<https://bindingofisaac.com/>>.
- OpenAI. *OpenAI API: Access GPT models*. 2025. Disponível em: <<https://platform.openai.com/>>.
- OpenAI. *OpenAI Node.js Library*. 2025. Acesso em: 2 abr. 2025. Disponível em: <<https://www.npmjs.com/package/openai>>.
- OpenJS Foundation. *Node.js*. 2025. Disponível em: <<https://nodejs.org/>>.
- PostgreSQL Global Development Group. *PostgreSQL: The world's most advanced open-source relational database*. 2025. Disponível em: <<https://www.postgresql.org/>>.
- Prisma Labs. *Prisma: Modern Database Toolkit*. 2025. Disponível em: <<https://www.prisma.io/>>.
- RAHMAN, M. M.; WATANOBE, Y. Chatgpt for education and research: Opportunities, threats, and strategies. *Applied Sciences*, MDPI, v. 13, n. 9, p. 5783, 2023. Disponível em: <<https://www.mdpi.com/2076-3417/13/9/5783>>.

---

Railway Corporation. *Railway: Deploy your apps effortlessly*. 2025. Acesso em: 02 abr. 2025. Disponível em: <<https://railway.app/>>.

Supergiant Games. *Hades*. 2020. Disponível em: <<https://www.supergiantgames.com/games/hades/>>.

SVIKHNUSHINA, E.; PU, P. Key qualities of conversational chatbots – the peace model. *ACM Transactions on Interactive Intelligent Systems*, v. 12, n. 4, 2022. Disponível em: <<https://infoscience.epfl.ch/record/292298>>.

TOGELIUS, J.; YANNAKAKIS, G. N.; STANLEY, K. O.; BROWNE, C. Search-based procedural content generation: A taxonomy and survey. *IEEE Transactions on Computational Intelligence and AI in Games*, v. 3, n. 3, p. 172–186, Sept. 2011.

TOUVRON, H. et al. Llama: Open and efficient foundation language models. *arXiv preprint*, 2023. Disponível em: <<https://arxiv.org/abs/2302.13971>>.

VASWANI, A.; SHAZEER, N.; PARMAR, N.; USZKOREIT, J.; JONES, L.; GOMEZ, A. N.; KAISER, L.; POLOSUKHIN, I. Attention is all you need. *Advances in Neural Information Processing Systems*, v. 30, 2017. Disponível em: <<https://arxiv.org/abs/1706.03762>>.