

UNIVERSIDADE DE SÃO PAULO

Instituto de Ciências Matemáticas e de Computação

Adquirindo dados de jogadores para predição e
aglomeração de perfis

Rafael Pedrosa Silva Clerici



São Carlos – SP

Adquirindo dados de jogadores para predição e aglomeração de perfis

Rafael Pedrosa Silva Clerici

***Orientador:* Ms. Leonardo Tórtoro Pereira**

Monografia final de conclusão de curso apresentada ao Instituto de Ciências Matemáticas e de Computação – ICMC-USP, como requisito parcial para obtenção do título de Bacharel em Engenharia de Computação.

Área de Concentração: Inteligência Artificial

USP – São Carlos

Julho de 2020

Clerici, Rafael Pedrosa Silva

Adquirindo dados de jogadores para predição e aglomeração de perfis / Rafael Pedrosa Silva Clerici. - São Carlos - SP, 2020.

55 p.; 29,7 cm.

Orientador: Leonardo Tórtoro Pereira.

Monografia (Graduação) - Instituto de Ciências Matemáticas e de Computação (ICMC/USP), São Carlos - SP, 2020.

1. Mineração de dados. 2. Classificação de usuários. 3. Modelagem de jogador. 4. Agrupamento de usuários. 5. Inteligência Artificial. I. Pereira, Leonardo Tórtoro. II. Instituto de Ciências Matemáticas e de Computação (ICMC/USP). III. Título.

*Dedico este trabalho à minha família, namorada e amigos,
que me ajudaram a ser quem eu sou.*

AGRADECIMENTOS

Sou grato a todos os professores, monitores e amigos que me ajudaram nesta jornada pela academia. Agradeço principalmente a Leonardo Tórtoro Pereira, por ser meu orientador, me apoiando além de seus deveres e minhas expectativas. Além de me guiar por todo o processo de desenvolvimento deste trabalho, também me permitiu utilizar seus resultados de pesquisa e seu jogo, o ProCoG, para extrair dados e desenvolver minha própria análise.

Também sou grato aos meus pais, Teresa e João, minha namorada, Ananda, meus amigos e minha família, que estiveram comigo durante todos esses cinco anos da graduação, fazendo companhia nos momentos tristes e felizes.

Por fim, agradeço aos pensadores, artistas, construtores, agricultores, cientistas, engenheiros, garis, médicos e todos os que se esforçam para contribuir que este seja um mundo melhor, mais justo e mais agradável para todos nós.

*“Um bom plano, executado agora,
é melhor que um plano perfeito
executado na semana que vem.”
(George Patton)*

RESUMO

CLERICI, R. P. S.. **Adquirindo dados de jogadores para predição e aglomeração de perfis**. 2020. 55 f. Monografia (Graduação) – Instituto de Ciências Matemáticas e de Computação (ICMC/USP), São Carlos – SP.

Os jogos eletrônicos já formam uma empresa que movimenta bilhões de dólares, empregando milhares de cientistas e engenheiros da computação para resolver problemas usando tecnologia de ponta, incluindo redes neurais artificiais e grandes bases de dados. Porém, uma área pouco explorada é o uso de sistemas inteligentes para prever preferências e performance dos jogadores apenas monitorando a maneira com que interagem com o jogo, classificando-os em tipos diferentes automaticamente. Este trabalho almejou testar este conceito na prática, utilizando técnicas de IA e mineração de dados para caracterizar usuários com base em métricas coletadas ao longo de uma fase de um jogo. Para isso, foi disponibilizado na internet um jogo simples, cujo objetivo era explorar salas e derrotar inimigos, com algumas fases variando em tamanho e dificuldade. Jogadores foram questionados a respeito de suas preferências de jogo e opiniões a respeito das fases, e dados acerca de sua performance foram colhidos. Técnicas de visualização foram feitas para buscar compreender quem era o jogador médio, e qual foi seu desempenho. No total, 55 jogadores diferentes participaram do estudo, jogando 369 partidas no total. Com estes dados, foram aplicados algoritmos de aglomeração e classificação para extrair dados importantes. As aglomerações geradas foram capazes de separar, de maneira satisfatória, jogadores pelo seu nível de habilidade, mas não foram capazes de notar grandes variações em seu estilo de jogo. Os métodos de classificação, por outro lado, foram capazes de prever com acurácia de até 84% as chances de vitória de um jogador a partir de seu perfil relatado, e com até 70% as opiniões que ele sentiria após jogar uma fase.

Palavras-chave: Mineração de dados, Classificação de usuários, Modelagem de jogador, Agrupamento de usuários, Inteligência Artificial.

ABSTRACT

CLERICI, R. P. S.. **Adquirindo dados de jogadores para predição e aglomeração de perfis**. 2020. 55 f. Monografia (Graduação) – Instituto de Ciências Matemáticas e de Computação (ICMC/USP), São Carlos – SP.

The eletronic games industry yearly moves billions of dollars, and employs thousands of computer scientists and engineers, in order to solve problems using cutting-edge technology, including artificial neural networks and big databases. However, an area that has seen little research is the use of intelligent systems to predict the player's feelings, opinions and performance, using only data collected by his or her interactions with the game. This work aimed to test this concept in practice, utilizing AI and Data Mining techniques to create user profiles with data collected from some game levels. To do so, a simple game was made available at an internet server. The goal in the game was to explore a dungeon and defeat the enemies blocking your path to the exit. In total, seven levels were created, with varying sizes and difficulty. Players were answered questions regarding their play preferences and opinions on the missions played. Statistical analysis were made in order to better visualize who was the average player, and how well did they fare. In total, 55 different players played the game, with data collected from 369 matches. Some clustering and classification algorithms were used in order to extract useful information about all this data. The clusters generated were able to satisfactorily separate players by their game skill. There was no big variations in play style were detected. On the other hand, the classification methods were able to predict with up to 84% accuracy whether a player was going to win or lose a level by only their reported profile, and with 70% accuracy his' or her's opinion on the level.

Key-words: Data Mining, Userbase classification, Player modeling, Userbase clustering, Artificial Intelligence.

LISTA DE ILUSTRAÇÕES

Figura 1 – Número de jogadores e taxa de vitória por nível.	39
Figura 2 – Soma das respostas em cada nível da escala Likert para cada pergunta do questionário pré-teste.	40
Figura 3 – Média das respostas dos jogadores para cada pergunta do questionário pós-teste, por nível jogado.	41
Figura 4 – Média das respostas dos jogadores para cada pergunta do questionário pós-teste, por nível jogado, considerando apenas as respostas dos jogadores que conseguiram terminar o nível.	41
Figura 5 – Pós teste por perfil dos dois níveis fáceis	42
Figura 6 – Pós teste por perfil do nível M-R18-K4-L4-L1.21	43
Figura 7 – Telas do jogo ProCoG	53
Figura 8 – Tela de um dos questionários dentro do jogo ProCoG	53
Figura 9 – Pós teste por perfil do maior nível médio e do menor difícil	54
Figura 10 – Pós teste por perfil dos dois maiores níveis difíceis	54
Figura 11 – Taxa de vitória em cada mapa por perfil	55
Figura 12 – Dados de exploração de cada mapa por perfil e nível	55

LISTA DE TABELAS

Tabela 1 – Perguntas do Questionário Pré-teste	37
Tabela 2 – Perguntas do Questionário Pós-teste	38
Tabela 3 – Dados coletados durante o jogo e o tipo da variável usada para coletá-lo . .	38
Tabela 4 – Acurácia da classificação para prever a respostas para cada uma das perguntas do pós teste (Tabela 2) por diferentes métodos	45

LISTA DE ABREVIATURAS E SIGLAS

Algoritmos Evolutivos AE

Aprendizado de Máquina AM

Geração Procedural de Conteúdo GPC

Inteligência Artificial IA

SUMÁRIO

1	INTRODUÇÃO	21
1.1	Motivação e Contextualização	21
1.2	Objetivos	23
1.3	Organização	23
2	MÉTODOS, TÉCNICAS E TECNOLOGIAS UTILIZADAS	25
2.1	Ferramentas e tecnologias	25
2.2	Técnicas e algoritmos	26
2.2.1	<i>Mineração de dados</i>	26
2.2.1.1	<i>Classificação</i>	26
2.2.1.2	<i>Aglomerção</i>	26
2.2.2	<i>Algoritmos Evolutivos</i>	27
2.2.3	<i>Redes Neurais Artificiais</i>	27
2.3	Experimentos	28
2.3.1	<i>Teste de Prova</i>	28
2.3.2	<i>Teste em Larga Escala</i>	28
3	DESENVOLVIMENTO	31
3.1	O Problema	31
3.2	Atividades Realizadas	31
3.2.1	<i>Planejamento</i>	32
3.2.2	<i>Teste de Prova</i>	34
3.2.3	<i>Teste em Larga Escala</i>	35
3.3	Resultados	38
3.4	Dificuldades e Limitações	45
4	CONCLUSÃO	47
	REFERÊNCIAS	49
	ANEXO A DADOS EXTRAS SOBRE OS NÍVEIS	53

INTRODUÇÃO

1.1 Motivação e Contextualização

A indústria de jogos eletrônicos já lucra mais de 150 bilhões de dólares ao ano, empregando mais de 220 mil funcionários ao redor do globo, superando até mesmo a escala da indústria cinematográfica (NEWZOO..., 2020). Ela também é uma grande fomentadora no desenvolvimento de novas técnicas em múltiplas áreas da computação, e acaba trazendo diretamente ao consumidor diversas tecnologias de ponta. Somando-se ao crescente poder dos métodos de IA (Inteligência Artificial), várias aplicações interessantes permitem um grau de interação ainda maior entre o jogador e a máquina, como a possibilidade de simulações cada vez mais complexas de ambientes e agentes. Qualquer tipo de programa é limitado pelo escopo de seu desenvolvimento, ou seja, um usuário não é capaz de fazer ou interagir com algo além do que os cientistas e engenheiros implementaram. Porém, sistemas inteligentes poderiam gerar ou modificar conteúdo sob demanda, gerando assim experiências muito mais profundas e enriquecedoras.

Neste trabalho, explorou-se o desenvolvimento de um sistema inteligente o bastante para detectar os padrões e preferências do jogador. Uma aplicação bastante recorrente são programas capazes de ler bases de dados contendo frases e conectar palavras por semelhanças de contexto semântico, "aprendendo" a criar suas próprias frases. A partir disto, é possível criar robôs para corrigir e sugerir melhorias em textos, ler comentários de usuários humanos e extrair significado de suas opiniões e até mesmo conversar diretamente com eles, estes últimos tipo ficando conhecidos como *chatbots* (SERBAN *et al.*, 2017). Os sistemas de recomendações para compras e filmes se utilizam de técnicas semelhantes, mas sem uma interação direta e explícita do usuário. Tais sistemas trabalham com informações secundárias, como histórico de compras, tempo de uso e dados deixados em seu perfil de usuário. Este tipo de programa reduz a carga nos trabalhadores enquanto melhora significativamente a experiência do usuário. Porém, menções sobre aplicações na indústria de jogos são escassas, apesar delas serem bastante promissoras.

Qualquer tipo de informação é valiosa, ainda mais quando se trata de uma indústria de porte tão grande. Estratégias de mineração de dados já são utilizadas a fim de prover desenvolvedores e publicadoras as opiniões de seus jogadores, motivando a criação de plataformas mais complexas e ambiciosas. Análise de mercado é vital numa área onde projetos chegam a custar mais de cem milhões de dólares, como foi o caso de títulos como *Grand Theft Auto V*, publicado pela *Rockstar Games*, e *Call Of Duty: Modern Warfare 2*, produzido pela *Infinity Ward*, ambos

gastando mais de duzentos milhões de dólares (HOW... , 2009; VILLAPAZ, 2013). Também é possível, graças à internet, lançar atualizações aos jogadores depois do produto ter sido lançado. Saber reconhecer problemas e possíveis melhorias aprimora a experiência dos usuários e pode ser a chave para manter os produtores no mercado (NEWZOO... , 2020), porém dados são só números e é necessário extrair significado dos mesmos. Redes Neurais artificiais têm se mostrado ferramentas poderosas neste ramo, superando a capacidade dos melhores humanos em diversos experimentos e demonstrações. Um exemplo recente é a *AlphaStar*, uma IA da empresa *OpenAI*, que foi capaz de aprender com maestria como jogar dois jogos muito complexos, a ponto de derrotar jogadores profissionais em ambos: *Dota 2* e *Starcraft II* (OPENAI *et al.*, 2019; VINYALS *et al.*, 2019).

Unindo as Redes Neurais, técnicas de GPC (Geração Procedural de Conteúdo) e a natureza interativa dos jogos eletrônicos (sejam eles para entretenimento ou simuladores sérios para treinamento), pode ser possível criar um ciclo retroalimentativo, criando conteúdo que engaja o jogador mais diretamente por prover com maior precisão o que ele ou ela quer ou precisa (MELHART *et al.*, 2019). No caso, como os sistemas de geração procedural criam conteúdo de jogo a partir de regras e métricas fornecidas pelo criador à máquina, é fácil imaginar um sistema onde parte dessas regras são baseadas nas preferências e estilos do jogador, como pode ser visto no trabalho de Bicho e Martinho. Nele, um jogo de corrida infinita leva em conta qual caminho, entre dois possíveis, o jogador escolheu em cada segmento do jogo para aumentar a dificuldade do tipo de desafio específico daquele caminho, caso o jogador o escolha novamente (BICHO; MARTINHO, 2018).

Outro benefício da GPC é para os denominados Jogos Sérios, sistemas interativos semelhantes aos jogos comuns e usados para ensinar e treinar estudantes e profissionais, seja apresentando conteúdos de forma mais divertida e dinâmica, ou permitindo o manuseio de ferramentas caras, complexas ou perigosas com a segurança do mundo virtual. Em (RODRIGUES; BRANCHER, 2019) é reportado que o uso de GPC permitiu maior imersão dos alunos em um jogo de ensino de matemática. E em (HOOSHYAR; YOUSEFI; LIM, 2018) utilizou-se GPC alimentada por dados dos usuários: níveis foram criados por um designer ao alimentar um Algoritmo Genético com parâmetros correspondentes ao desempenho de cada jogador.

Além disso, jogos sérios (jogos cujo principal objetivo é ensinar ou reabilitar, ao invés de apenas entreter) podem ser usados para a reabilitação de pacientes ou prevenção de doenças. Os autores em (Kern *et al.*, 2019) utilizam GPC para a reabilitação do caminhar em um jogo de realidade virtual, mantendo os pacientes mais engajados, com maior sentimento de autonomia e menos cansados do que comparado ao tratamento tradicional. Já o trabalho de (Esfahlani *et al.*, 2017) usou dados de usuários para desenvolver programas de reabilitação motora personalizados através de lógica *fuzzy*, adaptando o conteúdo às necessidades de cada paciente.

Portanto, são notáveis as contribuições que um sistema capaz de utilizar dados de jogadores para adaptar o conteúdo de jogos de acordo com as necessidades de cada grupo, tanto

na indústria de jogos como na educação, saúde e outras aplicações de jogos sérios.

1.2 Objetivos

Através desta pesquisa, objetivou-se desenvolver e testar algoritmos de AM (Aprendizado de Máquina) capazes de receber diversas informações a respeito do desempenho de jogadores ao terminar cada partida de um jogo e classificá-los em tipos diferentes, comparando seus resultados com a auto-avaliação dos próprios. Para isso, foi utilizado como base o projeto desenvolvido por Pereira, capaz de gerar proceduralmente níveis para um protótipo de jogo de ação-aventura, já validado com usuários, além de uma extensão do mesmo, ainda não publicada, capaz de gerar inimigos proceduralmente com diferentes parâmetros de dificuldade (PEREIRA, 2018). Alguns dos parâmetros que foram coletados são a quantidade do mapa explorada, chaves coletadas, vidas perdidas, quantidade de inimigos atingidos sem receber dano, entre outras. Visou-se então, ao verificar a eficácia do algoritmo de AM, prever desejos de jogadores a partir de sua performance, sendo capaz de apontar qual parte do jogo eles possuíram maior ou menor interesse.

Vários métodos diferentes para tal classificação foram avaliados, a fim de comparar e buscar soluções mais ou menos eficientes, realizando um estudo comparativo das mesmas. Foram comparadas Redes Neurais Artificiais, algoritmos de K-Próximos Vizinhos, Florestas de Decisão e Classificadores Bayesianos Ingênuos (*Naive Bayes*).

1.3 Organização

No Capítulo 2, estão descritas as ferramentas e inspirações para o trabalho e o que se pretende alcançar com cada escolha, além de como se pretendeu encarar a proposta e resolver eventuais dificuldades. Já no Capítulo 3, discorreu-se acerca do desenvolvimento em si do projeto, quais métodos foram implementados, que tipo de dificuldades surgiram em decorrência dos mesmos, como estas foram superadas e que tipo de resultado se obteve ao final de tudo. A conclusão, no Capítulo 4, o último desta monografia, revisa o que foi implementado, como o foi, quais informações foram obtidas e como pode-se interpretá-las, determinando se o projeto cumpriu ou não seus objetivos.

MÉTODOS, TÉCNICAS E TECNOLOGIAS UTILIZADAS

Nesta seção, os componentes fundamentais do projeto são apresentados: as ferramentas, as estratégias e os testes planejados para validar os métodos. Junto com tais apresentações estão as justificativas para a escolha. Deve-se ter em mente que este trabalho utiliza como base o protótipo de jogo desenvolvido em (PEREIRA, 2018). Portanto, haverá várias referências ao mesmo ao longo da parte de ferramentas.

2.1 Ferramentas e tecnologias

O primeiro programa utilizado foi o Weka. Desenvolvido pela universidade neozelandesa de Waikato, ele reúne múltiplos algoritmos de classificação, regressão e aglomeração ("*clustering*"), prontos para serem executados em bases de dados, todos eles envolvidos numa interface relativamente amigável ao usuário. Ele foi utilizado para fazer os testes de base, comprovando que a ideia é executável e extraíndo os resultados preliminares. Seus usos serão melhor descritos no capítulo 3.

A segunda ferramenta foi a *engine* de jogos Unity. Feita para acelerar o desenvolvimento de aplicações como jogos e filmes, ela foi utilizada posteriormente para programar o jogo *ProCoG*, desenvolvido para testes da dissertação de mestrado de Pereira (PEREIRA, 2018). Nela, foram implementadas todas as características do jogo, incluindo os questionários para coleta de dados. Ela também foi utilizada para expandir o escopo do *ProCoG*, com o objetivo de permitir mais estilos diferentes de jogo. Originalmente, ele era calibrado para apenas gerar um caminho de salas; tal sistema foi modificado para adicionar inimigos (entidades controlados pelo computador que causam dano no personagem e o impedem de progredir sem que sejam derrotados), tesouros (recompensas adicionais e optativas para os jogadores que explorarem melhor o mapa), combos (um contador de quantos inimigos o jogador derrotou sem que fosse atingido por seus ataques) e uma tabela de pontuação, permitindo que o jogador avaliasse seu desempenho e decidisse tentar a fase novamente ou seguir adiante. Foram também implementadas novas armas para que o personagem use, concedendo mais oportunidades do usuário escolher a maneira com que joga.

O *ProCoG* em si é um jogo relativamente simples de ação-aventura, onde se atravessa um labirinto de salas buscando tesouros e a saída, enfrentando vários inimigos no caminho. Seu estilo

foi bastante inspirado nas séries de grande sucesso *The Legend of Zelda* e *The Binding of Isaac*. Os labirintos e inimigos são gerados por AE (Algoritmos Evolutivos), os quais serão melhor descritos na seção 2.2. Foram implementados métodos para a coleta de dados anonimizados da performance dos jogadores e um conjunto de perguntas acerca de sua experiência ao jogar. Assim, foi possível verificar o desempenho deles nas diversas fases e agrupá-los em arquétipos diferentes. Além disso, pôde-se cruzar tais dados com as informações cedidas no questionário, o que serviu de guia para encontrar padrões; esperou-se que jogadores autodeclarados fãs de exploração visitem mais salas e encontrem todos os tesouros espalhados pela fase, do que os que não são, por exemplo.

A última ferramenta foi o *scikit learn* (PEDREGOSA *et al.*, 2011), uma biblioteca de algoritmos para mineração de dados na linguagem Python. Mantido por uma comunidade de desenvolvedores, é um pacote de ferramentas bastante completo e versátil, implementando a maioria dos métodos convencionais. Assim, o foco pôde ser dado à interpretação e coleta de dados, sem a necessidade de verificar o funcionamento dos algoritmos. Ele foi utilizado nas análises mais profundas do segundo experimento, o Teste em Larga Escala.

2.2 Técnicas e algoritmos

2.2.1 Mineração de dados

Consiste, de forma geral, em métodos para extrair informação a partir de volumes de dados. A informação e a origem dos dados em si são extremamente variados. Alguns exemplos são algoritmos para prever a saúde de pacientes conforme os dados coletados em exames ou analisar demandas que necessitarão da alocação de mais recursos (ARTIFICIAL..., 2017; YADAV *et al.*, 2017; CIO; KURGAN,). Ela se subdivide em várias outras áreas, porém, apenas duas foram relevantes para os propósitos deste trabalho.

2.2.1.1 Classificação

Cria conjuntos de regras para tentar encaixar um dado em uma classe específica. Com um conjunto suficientemente grande de dados devidamente classificados, pode-se "estender" a classificação e tentar prever a classe de novos casos. Tal processo de criar as regras é chamado de *Treinamento*. Este tipo foi utilizado ao tentar prever se um jogador gostará da fase ou não, se achará os inimigos fáceis ou difíceis, assim em diante.

2.2.1.2 Aglomeração

São algoritmos que buscam semelhanças entre os dados para então agrupá-los automaticamente. Os critérios para o cálculo de semelhança são definidos pelo usuário e variam

de algoritmo para algoritmo. Este tipo foi utilizado ao buscar tipos diferentes de jogadores, analisando quais aglomerados são formados e quais características eles possuem em comum.

2.2.2 Algoritmos Evolutivos

São uma heurística para otimização de problemas, que consiste em testar várias possíveis soluções, descobrir quais possuem melhor retorno, e produzir novas variantes baseadas nelas. Inspirado na evolução biológica, tais algoritmos, quando aplicados corretamente, são capazes de produzir soluções especializadas e satisfatórias para situações extremamente complexas, as quais é impossível ou inviável encontrar uma solução determinística. Seu principal problema é necessitar de muitos ciclos de processamento para simular e buscar a vasta gama de soluções existentes.

Eles foram utilizados para gerar fases no jogo ProCoG. Mapas recebem parâmetros que determinam uma estrutura geral, como quantidade de salas e linearidade (uma medida do quão ramificados são os caminhos dentro do labirinto). O algoritmo simula um possível jogador percorrendo os mapas e verifica o quão próximo ele está dos critérios estabelecidos, dando a ele uma nota como descrito em (PEREIRA, 2018). O jogo também foi adaptado para gerar inimigos de maneira evolutiva. Cada um possui uma quantidade de parâmetros, definindo quantos pontos de vida, velocidade, comportamento, entre outros. Tais parâmetros possuem um nível de "poder". Indivíduos são evoluídos de forma a gerar inimigos diferentes mas com poder semelhante, com o objetivo de criar vários oponentes diferentes sem que um seja significativamente mais forte que o outro.

Devido à maneira em que o ProCoG foi implementado, o conteúdo gerado por meio destes algoritmos pode ser gerado em tempo real, garantindo aos jogadores uma experiência única a cada vez que ligarem o jogo. Porém, para fins de comparação, um mesmo conjunto de fases e inimigos foi utilizado neste trabalho. Eles foram gerados pelos algoritmos antes do experimento, salvos, e enviados junto com o jogo ProCoG para os participantes.

2.2.3 Redes Neurais Artificiais

Uma outra ferramenta inspirada na biologia, Redes Neurais imitam a estrutura de um cérebro, recebendo uma entrada e calculando sua saída por meio de operações em pequenos conjuntos de dados, chamados de neurônios. Seu funcionamento é simples: cada um recebe vários sinais como entrada, cada um deles contendo um peso, e realiza uma operação matemática sobre eles (como uma soma simples). O resultado desta operação é sua saída, que pode até mesmo servir de entrada para outro neurônio. Essas Redes são compostas por muitos neurônios, cujas conexões e múltiplas camadas de processamento simples permitem o surgimento de comportamentos mais complexos, um fenômeno conhecido por emergência.

Sua natureza adaptável permite que se adaptem a diversos tipos de ambientes, restrições

e problemas, sendo uma poderosa ferramenta para a mineração de dados. Porém, devido à quantidade de conexões possíveis e operações matemáticas contidas nos neurônios, é difícil encontrar a combinação (ou arquitetura) ideal para a situação que se pretende resolver. Além disso, de forma análoga aos algoritmos evolutivos, calibrar uma Rede Neural Artificial para operar corretamente necessita de bastante poder computacional, mas a estrutura gerada no final deste processo consegue realizar a tarefa a que foi designada rapidamente.

Redes Neurais foram utilizadas a fim de melhor prever e buscar padrões entre comportamentos de jogadores. Contudo, os resultados imediatos de seu emprego foram limitados, uma vez que redes mais complexas exigem mais dados e tempo para alcançarem um alto nível de precisão e confiabilidade.

2.3 Experimentos

Foram realizados dois experimentos neste trabalho. O primeiro teve escala menor e serviu como base para o segundo, como um estágio de prova do conceito. Desta forma, quaisquer problemas que ameaçassem o trabalho foram detectados e resolvidos antes que ocorressem consequências desastrosas. Eles serão denominados teste de Prova e teste de Larga Escala.

2.3.1 *Teste de Prova*

Durante a pesquisa de Pereira ([PEREIRA, 2018](#)), vários dados foram extraídos contendo métricas e preferências de jogadores reais. Analisados diretamente pelo autor, tais dados foram coletados para verificar se os objetivos haviam sido cumpridos, ou seja, se os algoritmos evolutivos eram capazes de criar fases e inimigos semelhantes aos que um humano desenvolveria, e se tal conteúdo era capaz de divertir o jogador.

Uma questão importante a se considerar está na quantidade de dados necessários para se alcançar bons resultados no teste de larga escala, devido às exigências das técnicas de mineração de dados. Para isso, o programa Weka foi utilizado para testar potenciais relações interessantes nesses dados. O procedimento foi mais rápido, uma vez que não houve necessidade de coletar ou pré-processar os dados. Com ele, pôde-se validar a ideia central do trabalho, já que uma base limitada de dados gerou resultados positivos.

2.3.2 *Teste em Larga Escala*

Com as informações obtidas no teste de Prova, foi arquitetado este segundo experimento. Nele, uma nova coleta de dados, mais abrangente, foi realizada para buscar registrar indícios de diferentes comportamentos de jogadores. Foram coletadas métricas simples, como se ele venceu ou não a fase, até algumas mais abstratas, como a quantidade de inimigos derrotados de

uma só vez, para detectar maestria no combate, e vezes que o jogador passou pela mesma sala, verificando frustração.

Para coletar tais informações, o jogo foi disponibilizado em um servidor acadêmico para que qualquer pessoa com acesso a um computador conectado à internet pudesse jogá-lo. Jogadores receberam algumas perguntas antes de jogar, junto com instruções comentando o propósito das mesmas. Depois disso, foram direcionados a uma tela onde podem escolher entre fases diferentes, e puderam jogar quantas vezes quiser. Tais fases foram iguais para todos os jogadores, para que comparações de performance sejam válidas, mas possibilitaram uma margem de escolha, com o propósito de permitir que jogadores mais habilidosos conseguissem se divertir sem que o jogo seja difícil demais para os menos habilidosos.

As perguntas (melhor discutidas no capítulo 3) e as fases foram compostas de forma a minimizar o viés inerente de tal pesquisa. Jogadores foram informados que é uma pesquisa para testar os algoritmos envolvidos na criação dos mapas e inimigos, para que eles jogassem da maneira que preferissem. O método para colher informações a respeito dos jogadores foi baseado em outras pesquisas da área, como as de (HEIJNE, 2016) e (RIVERA-VILLICANA *et al.*, 2018), melhor discutidas no capítulo 3.

DESENVOLVIMENTO

3.1 O Problema

Assim como descrito no capítulo de introdução, a indústria de jogos eletrônicos movimenta e emprega vastas quantias de recursos materiais, intelectuais e humanos. A experimentação com novas técnicas para extração de conhecimento é sempre bem-vinda para criar produtos de maior qualidade e melhor atender os desejos dos jogadores. Por meio do protótipo de jogo ProCoG, desenvolvido por (PEREIRA, 2018), dados acerca de vários jogadores foram coletados para serem analisados. No Anexo A encontram-se imagens do jogo e de um dos questionários dentro do jogo.

Um servidor abrigou uma versão melhorada do ProCog, e participantes foram convidados à jogá-lo por meio de redes sociais. Coletando dados explícitos (pesquisas de satisfação) e implícitos (tempo gasto para passar de fase, vidas perdidas, etc), foi criada uma base de dados contendo informações de diversos jogadores voluntários diferentes, com suas preferências e estilo de jogo registrados.

3.2 Atividades Realizadas

O trabalho realizado pode ser dividido em três partes. A primeira foi o planejamento e revisão bibliográfica, onde pesquisas realizadas por outros autores foram estudadas a fim de melhor compreender quais comportamentos, estilos e preferências poderiam surgir a partir das interações dos jogadores. Assim, garantir-se-ia a confiabilidade da pesquisa, já que os métodos de teste das partes seguintes seriam organizados de maneira a melhor tirar proveito da situação. Também foram estudadas as pesquisas originais de (PEREIRA, 2018), com revisão do código e resultados produzidos, para que houvesse a devida familiaridade com o jogo que serviria de base para toda a pesquisa subsequente.

A segunda e terceira partes foram descritas anteriormente, no capítulo de Métodos. Elas consistem no Teste de Prova e o Teste em Larga Escala. No primeiro teste, dados obtidos durante a pesquisa de Pereira foram submetidos a algumas técnicas de mineração de dados, a fim de confirmar se a ideia é mesmo viável. O segundo teste foi realizado com uma versão atualizada do jogo, com mais informações sendo coletadas e com diferentes perguntas nas pesquisas de satisfação.

3.2.1 Planejamento

Vários pesquisadores anteriores já se empenharam em tipificar, agrupar e categorizar jogadores pelas maneiras que preferem jogar. A obra mais famosa é, provavelmente, a de Bartle, conhecida popularmente por "Taxonomia de jogadores". Estudando principalmente jogos com múltiplos usuários como *MUDs* (*Multi-User Dungeons*, jogos de exploração envolvendo vários jogadores ao mesmo tempo) e *MMORPGs* (*Massive Multiplayer Online Role Playing Games*, jogos onde você cria um personagem próprio e explora o mundo povoado por muitos outros personagens também controlados por jogadores), ele dividiu os jogadores em quatro tipos, que se apoiam em dois eixos. Pessoas podem se interessar em Interagir ou Agir com outras Pessoas ou com o Mundo do Jogo. Assim, cada quadrante deste eixo produz um arquétipo: os Matadores, Agem com Pessoas, tendem a se interessar por competições e duelos. Os Socializadores, Interação com Pessoas, se interessam em se relacionar com os outros jogadores. Os Conquistadores, Agem sobre o Mundo, gostam de testar os limites do jogo e ver o quão longe conseguem chegar. Por fim, há os Exploradores, Interação com o Mundo, preferindo saborear a narrativa, arte e história por trás do jogo. Posteriormente ampliaram esta classificação para jogos de jogador único, e adicionaram ramificações aos arquétipos, mas a essência permanece a mesma (BARTLE, 2003). Porém existem críticas questionando a abrangência dessa classificação e se ela de fato se reproduz na realidade.

Vahlo et al. buscaram criar uma nova maneira de agrupar jogadores a partir de pesquisas de opinião, de modo que esta nova "taxonomia" teria base na realidade. Eles analisaram várias revistas que discutiam e avaliavam jogos, buscando encontrar ações granulares que jogadores poderiam realizar e tentar listar todas elas, totalizando 33 ações diferentes. Depois disso, agruparam em cinco dinâmicas, ou seja, conjuntos de ações que definiam momentos de jogo. Elas foram: Atacar, voltada para ações mais agressivas como destruir inimigos, quebrar leis, hackear e invadir bases inimigas; Gerência, contendo ações como construir cidades, adquirir recursos, realizar investimentos e proteger seus trabalhadores de perigo; Aventura, voltada para explorar mundos, conhecer personagens e descobrir segredos; Cuidar, relacionada a formar laços com personagens e animais do jogo; Coordenar, focada em coordenação motora como realizar saltos precisos e realizar ações em ritmo. Um formulário questionando suas preferências foi enviado para mais de 2500 pessoas, e algoritmos de agrupamento foram aplicados para tentar discernir tais grupos. No final, sete arquétipos surgiram. Cada dinâmica, exceto Aventura, possuía um agrupamento com grande interesse quase exclusivo por ela. Os outros dois grupos gostavam de duas dinâmicas misturadas: Aventura e Atacar, Aventura e Coordenar e, por fim, Atacar e Coordenar. São grupos de jogadores bastante distintos da taxonomia de Bartle, e feitos para se aplicarem a qualquer jogo. Porém, eles parecem não entrar em detalhes se os jogadores possuem alguma preferência por jogos multi ou único jogador (VAHLO et al., 2017).

Um estudo mais próximo do intuito deste trabalho é o desempenhado por Melhart et al (MELHART et al., 2019). Sua equipe envolveu ambos pesquisadores da área de jogos (incluindo

Georgios Yannakakis, um dos grandes nomes na área) e desenvolvedores da empresa *Ubisoft*, um dos maiores estúdios de jogos do mundo, lucrando mais de 1,5 Bilhão de Euros em 2019 para 2020 (EARNINGS..., 2020). A equipe decidiu analisar os dados anonimizados de vários jogadores do jogo *Tom Clancy's The Division* entre os anos de 2016 e 2018, para tentar extrair informações de perfis e realizar previsões do que os jogadores sentiram ou sentirão ao jogar. Depois da coleta, foram enviados questionários padrão *Ubisoft* aos jogadores, avaliando os sentimentos deles de acordo com a teoria de Autodeterminação. No caso, ela buscava avaliar os sentimentos de: Competência, a sensação de ter vencido um obstáculo ou aprendido algo; Autonomia, a sensação de tomar suas próprias escolhas e moldar seu próprio caminho; Relacionamento, a necessidade de pertencer a comunidades; Presença, também conhecida por Imersão, não é comumente integrada ao resto da teoria, porém possui grande importância nas experiências virtuais proporcionadas pelos jogos eletrônicos. Os dados de 298 jogadores foram utilizados para a pesquisa.

Neste caso, foram criados quatro grupos de jogadores, cada um com seus próprios fatores de motivação e estilos de jogo: os novatos, os quais ainda estão explorando o jogo e não tem um perfil tão definido; os sociais, que se interessam por atividades com outros jogadores, principalmente combates; os fãs cooperativos, jogadores muito experientes que gostam de interagir com outros jogadores formando equipes contra os inimigos controlados pela máquina e realizar missões, e os elites, que também são experientes mas não tem um estilo favorito de jogo. Tais agrupamentos foram realizados pelo método de *k-means*. Com os dados coletados, foram treinadas redes neurais artificiais com vários tipos diferentes de função para seus *kernels* para prever as motivações e sentimentos dos jogadores a partir dos dados coletados. Seus resultados de precisão chegaram a, em alguns casos, 90% de acerto, principalmente com *kernels* de funções de base radial (*RBF*, *Radial Basis Functions*). Porém, a rede tinha dificuldades em prever alguns aspectos mais subjetivos, e em vários casos os jogadores relataram preferências diferentes das que eles apresentavam segundo seus dados de jogo. Os pesquisadores concluíram que foi possível criar agrupamentos e utilizá-los para prever gostos de jogadores, mas não foi uma tarefa simples (MELHART *et al.*, 2019).

Considerando as decisões e resultados obtidos pelas pesquisas anteriormente citadas, decidiu-se pela utilização do jogo ProCoG, criado durante a pesquisa de Pereira, para captar dados anonimizados de jogadores. Foram também planejados dois questionários inspirados no da *Ubisoft*, mas retirando algumas perguntas que não se aplicam ao jogo deste trabalho. Por exemplo, o ProCoG não apresenta história, personagens ou interações com outros jogadores, logo, perguntas sobre estes assuntos não fazem sentido neste contexto. Decidiu-se também modificar a estrutura básica do jogo para adicionar algumas ações diferentes, buscando criar dinâmicas de jogo diferentes. Para o pré-teste (Tabela 1), diversas questões foram inspiradas no trabalho de (RIVERA-VILLICANA *et al.*, 2018), que identificavam perfis de jogadores. Outras, no trabalho de (HEIJNE, 2016), que focavam em entender a experiência do jogador com jogos e o gênero em específico de ação-aventura. Além disso, diversos dados coletados de jogabilidade

(Tabela 3) foram também inspirados no trabalho de Heijne (HEIJNE, 2016), que realizou extensa coleta e análise de dados em um jogo de ação-aventura, com sucesso na análise de alguns deles. Seu trabalho também inspirou algumas questões de nosso questionário pós teste (Tabela 2), além do já referido questionário da Ubisoft por Azadvar et al. (AZADVAR; CANOSSA, 2018).

O ProCoG básico consistia num gerador de mapas contendo diversas salas interconectadas, e os jogadores deveriam explorá-las em busca da saída, a qual poderia estar obstruída por portões; para abri-los, era necessário encontrar a chave correspondente, oculta em alguma das salas. Este ciclo básico de jogo instigava os jogadores interessados em exploração, mas não os demais. Foram adicionadas algumas mecânicas: inimigos, para prover um desafio maior e divertir todos os jogadores interessados em Atacar; Tesouros, moedas espalhadas pelas salas, cuja quantia total e coletada aparecem no final da fase, convidando os jogadores interessados em colecionar a coletar todas e ter uma pontuação "perfeita"; um sistema de Combo, mostrando aos jogadores quantos golpes conseguiram acertar em seus inimigos sem que tenham recebido dano, recompensando jogadores cautelosos e que detém a maestria do jogo; opções de armas diferentes para completar a fase, todas com poder parecido, mas funcionamento um pouco diferente (três armas variando em sua velocidade de disparo e dano causado por projétil e uma disparando três projéteis em cone de uma só vez, mas com dano reduzido); e um conjunto de sete mapas distintos, com configurações próprias de tamanho, "linearidade"(quantas ramificações existem entre o início e o fim da fase) e poder dos inimigos, para averiguar qual tipo de perfil desempenha melhor em qual situação.

Como o exame de Vahlo et al. (VAHLO *et al.*, 2017) foi realizado com milhares de pessoas e analisou uma enorme variedade de jogos, considerou-se que os grupos produzidos neste estudo não seriam tão diversos, provavelmente assemelhando-se mais aos da pesquisa de Melhart et al (MELHART *et al.*, 2019). Logo, foi procurada a maior variedade possível de maneiras de jogar um mesmo jogo, a fim de produzir grupos distintos e reconhecíveis para que informações interessantes possam ser extraídas.

3.2.2 Teste de Prova

Antes de iniciar os preparativos para o Teste em Larga Escala, foi realizado o Teste de Prova como garantia de que a ideia era sólida, e o tempo investido desenvolvendo a nova versão do ProCoG e disponibilizando-a na internet não seria em vão. Utilizando os dados da pesquisa de (PEREIRA, 2018), foram realizadas investigações no Weka, programa de mineração de dados.

A base de dados consistiu de registros sobre a performance e as respostas dos jogadores ao longo de um conjunto de fases, totalizando 678 entradas. Jogadores poderiam jogar uma ou mais fases, e deveriam, ao encerrar a fase, dar uma nota de um a cinco (escala Likert) ao quão divertida, difícil e semelhante ao que um humano faria;

Ao aplicar diferentes algoritmos de aglomeração, os que produziram resultados mais

interessantes foram o método de K-próximos vizinhos e o *COBWEB*, que gera aglomerações hierárquicas. Nos dois casos, a base de dados foi separada em dois grupos, cuja principal distinção pareceu ser o nível de habilidade entre os jogadores: os de um dos grupos, em média, deram notas mais altas para a dificuldade e tiveram mais dificuldade em encontrar a saída (encontraram menos salas e passaram por elas mais vezes).

Também foram aplicados alguns métodos preditivos, explorando a possibilidade de se prever a nota que o usuário deu para diferentes critérios de acordo com sua performance. Análises iniciais não foram promissoras, alcançando baixas precisões. Ao inspecionar melhor os resultados, percebeu-se que os dados eram bastante desbalanceados, com notas de três a quatro muito mais frequentes que as outras. Assim, após amostrar as entradas de forma mais balanceada, o método de Florestas de Decisão foi capaz de alcançar 83% de acurácia, com valores de Precisão e Revocação acima de 80%, ao prever a dificuldade percebida pelo usuário, baseando-se nos dados de performance do mesmo.

Tais resultados foram limitados pelo escopo das informações coletadas, e da versão testada do jogo. Como o jogo só possuía um objetivo e uma ação (entrar em salas buscando caminhos) para alcançá-lo, era improvável que padrões reconhecidamente distintos aparecessem entre os usuários. Mesmo assim, foi possível categorizar jogadores em dois agrupamentos distintos e prever suas opiniões a respeito do jogo. Portanto, pode-se concluir que as técnicas utilizadas foram capazes de render informações úteis acerca da experiência dos jogadores.

3.2.3 Teste em Larga Escala

De acordo com os resultados do Teste de Prova, decidiu-se ampliar o jogo base para aumentar a quantidade de ações no jogo, visando habilitar a emergência de comportamentos diferentes ao jogar. Foram também preparados dois questionários, um antes de iniciar o jogo e outro depois de jogar cada fase, a fim de tomar conhecimento das opiniões e criar um perfil simples de quem é aquele que está jogando.

As adições foram:

- Inimigos: utilizando-se de um sistema já em desenvolvimento por Pereira (autoria própria), foram criados e adicionados inimigos (agentes controlados por uma Inteligência Artificial simples que procuram impedir o jogador de vencer o jogo) nas salas das fases. Cada sala poderia possuir três ou quatro inimigos selecionados de uma lista de 20 tipos diferentes, com atributos variados e maneiras diferentes de agir e atacar o personagem do jogador. Ao entrar numa sala com inimigos, as portas são fechadas, e o jogador só poderá prosseguir ao derrotar todos eles. Inimigos não são repostos nas salas em que o jogador já percorreu.
- Vidas: parte do sistema de inimigos, o personagem do jogador possui 10 vidas. Golpes sofridos dos inimigos fazem-no perdê-las. Caso todas as vidas sejam perdidas, o jogador

perde a fase. Vidas são repostas no início de cada fase. Ao perder uma fase, o jogador pode tentá-la novamente quantas vezes quiser, ou desistir e passar para a próxima.

- **Armas:** também parte do sistema de inimigos, o personagem do jogador possui uma arma capaz de atirar projéteis pela tela. Ao acertar inimigos, os projéteis aplicam dano neles, fazendo-os perder vidas, de maneira semelhante ao jogador. Caso as vidas do inimigo sejam esgotadas, ele é derrotado, e sai do jogo. Havia quatro variantes de arma: a Comum, cujos atributos servem de referência para as outras; a Metralhadora, que dispara mais rapidamente, mas causa menos dano por projétil; o Canhão, que dispara mais lentamente, mas causa mais dano por projétil; e o Tiro Triplo, que dispara três projéteis de uma vez, cada um formando ângulo de 45° com o outro. Jogadores podem escolher a arma todo início de fase.
- **Sistema de Combo:** cada golpe atingido pelo jogador num inimigo incrementa seu valor de Combo. Ao sofrer um golpe, esse valor volta a zero. Ao final da partida, o jogador é informado acerca de seu maior valor de Combo. Ele é criado para incentivar e recompensar jogadores habilidosos, capazes de derrotar vários inimigos de uma vez só.
- **Tesouros:** os mapas originais eram gerados com várias salas e portas conectando-as, numa estrutura de árvore. Os nós folha poderiam conter uma chave, capaz de abrir portas trancadas espalhadas pela fase. Logo, para se chegar ao fim, todas as chaves deveriam ser encontradas. Porém, não era certeza de que, ao seguir um caminho, o jogador encontraria uma chave. Decidiu-se adicionar Tesouros, gerados em todos os nós folha sem chave. A quantidade de tesouros encontrada, junto com a quantia total, é apresentada ao jogador após concluir a fase. Para conseguir todos os tesouros, é necessário explorar o nível inteiro. Eles surgem como recompensa e incentivo a continuar explorando o nível depois de ter encontrado o caminho certo, e como alvo para jogadores perfeccionistas, que gostam de "completar 100%" seus jogos.
- **Sistema de Mapa:** um diagrama mostrando as salas ao redor do personagem do jogador fica exposto na tela, para facilitar a exploração e mostrar o quão perto do fim da fase o jogador está. Salas já visitadas são mostradas numa cor diferente, de forma a evitar que o jogador ande em círculos. A quantidade de salas únicas visitadas é mostrada ao jogador ao concluir a fase, junto com a quantidade total, de forma semelhante aos Tesouros.
- **Tela de pontuação:** uma tela simples mostrando ao jogador quantos tesouros e sala ele visitou ao longo da fase. Ela também permite que o jogador jogue a mesma fase novamente ou passe adiante para uma nova fase.

Foram geradas sete fases de tamanhos e dificuldades variadas, e mantidas as mesmas ao longo de todo o experimento, para que uma comparação válida pudesse ser feita entre as performances. Ao iniciar o jogo, jogadores podiam escolher em qual fase começariam a jogar,

e a máquina escolheria as próximas fases para eles, buscando manter o nível de dificuldade próximo. Jogadores também poderiam jogar uma fase novamente quantas vezes quisessem antes de prosseguir adiante. As fases vinham com anotações de sua dificuldade, comprimento e linearidade (quantas ramificações até chegar ao final). As informações eram coletadas fase-a-fase, logo usuários poderiam deixar o jogo no momento que quisessem sem comprometer os dados da pesquisa.

As perguntas realizadas no pré-teste, todas em escala Likert de um a cinco (jogadores poderiam não responder se quisessem), a fim de formar uma imagem de quem é o jogador são apresentadas na Tabela 1. As perguntas realizadas no pós-teste, todas em escala Likert de um a cinco (jogadores poderiam não responder se quisessem), depois de cada fase jogada estão na Tabela 2. Por fim, a Tabela 3 contém os dados coletados a cada jogada, tenha o jogador vencido ou não a fase. As perguntas foram desenvolvidas pelos autores, com base nos trabalhos discutidos em na subseção sobre Planejamento.

Tabela 1 – Perguntas do Questionário Pré-teste

Pergunta	Tipo
1 - Sou um(a) jogador(a) experiente	Likert 1-5
2 - Sou um(a) jogador(a) experiente no gênero ação-aventura.	Likert 1-5
3 - Qual a dificuldade que você costuma jogar seus jogos? (Existem diversas nomenclaturas nos jogos. Tente escolher a que para você é a mais adequada na escala usada).	Likert 1-5
4 -Quando jogo, eu normalmente exploro todos os lugares, elementos e personagens do mundo virtual	Likert 1-5
5 - Quando jogo, eu normalmente completo todas as missões, incluindo aquelas que não são necessárias para terminar o jogo (por exemplo, missões secundárias).	Likert 1-5
6 - Quando jogo, eu normalmente apenas faço o necessário para passar de um nível (ou de uma fase) ou para completar uma missão.	Likert 1-5
7 - Para você, a parte mais legal do jogo é a ação?	Likert 1-5
8 - Gosto muito de jogos que exigem reflexo e pensamento rápido (ação, luta, tiro, etc.)	Likert 1-5
9 - Gosto muito de jogos de exploração (aventura, mundo aberto, etc.)	Likert 1-5
10 - Gosto muito de jogos que exigem lógica (estratégia, quebra-cabeças, investigação, etc.)	Likert 1-5
11 - Gosto muito de jogos de simulação (esportes, corrida, etc.)	Likert 1-5

O jogo foi publicado em um servidor acadêmico e disponibilizado na internet, com pessoas convidadas a jogar e participar da pesquisa. Todos os participantes foram avisados que seus dados seriam coletados, anonimamente, para uma pesquisa, mas não foi explicitado sobre o que seria a pesquisa, de forma a minimizar o viés nos estilos de jogo.

Tabela 2 – Perguntas do Questionário Pós-teste

Pergunta	Tipo
1 - O quanto você concorda com a afirmação: "Este nível foi divertido de jogar"?	Likert 1-5
2 - O quanto você concorda com a afirmação: "O desafio deste nível for na medida certa"?	Likert 1-5
3 - O quanto você concorda com a afirmação: "Eu tive que visitar muitas vezes algumas salas"?	Likert 1-5
4 - O quão difícil foi completar este nível?	Nota 1-5, 1 = muito fácil 5 = muito difícil
5 - O quão difícil você achou o combate contra os inimigos deste nível?	Nota 1-5, 1 = muito fácil 5 = muito difícil
6- O quão difícil foi encontrar o caminho para a saída deste nível?	Nota 1-5, 1 = muito fácil 5 = muito difícil

Tabela 3 – Dados coletados durante o jogo e o tipo da variável usada para coletá-lo

Dado	Tipo
Código identificador anônimo	String
Fase jogada	String
Número de tentativas nesta mesma fase	Integer
Número de tentativas em todas as fases no total	Integer
Quantidade de salas visitadas	Integer
Quantidade de salas únicas visitadas	Integer, 1-22
Chaves encontradas	Integer, 0-4
Portas destrancadas	Integer, 0-4
Combo máximo	Integer
Tesouro encontrado	Integer, 0-300
Arma escolhida	Integer, 1-4
Nível de dificuldade da fase	Integer, 0-2
Quantidade de derrotas sofridas	Integer
Se esta jogada foi uma vitória ou derrota	Booleano
Quantidade de dano sofrido por cada inimigo diferente	Conjunto de Integers

3.3 Resultados

Após deixar o servidor aberto por um período de duas semanas (entre Junho e Julho 2020) e com divulgação em redes sociais, foram coletados dados de 55 sessões (acessos ao servidor) diferentes. Nelas, os jogadores tentaram jogar 369 partidas diferentes, independente do nível escolhido. Foram 134 partidas em níveis diferentes (ou seja, ignorando aquelas que o jogador repetiu o mesmo nível). Muitos jogadores tentaram apenas uma única vez completar dado nível, porém, alguns tentaram por diversas vezes: um mesmo jogador chegou a jogar o mesmo nível 55 vezes (o nível apelidado de Nível Z, de dificuldade mais alta, completando-o com sucesso ao final). Além disso, esse mesmo jogador também foi o que mais teve tentativas de jogar fases no total: ele jogou 69 vezes, independente da fase.

Uma análise geral dos dados foi essencial para o bom entendimento da base com a qual iremos experimentar algoritmos de Aprendizado de Máquina, e será discutida a seguir. A Figura 1 apresenta, à esquerda, quantos jogadores jogaram cada nível, e à direita a porcentagem destes que terminaram com sucesso o nível. Se tornou evidente que a maioria dos usuários preferiu escolher o nível mais fácil e mais curto para iniciar o jogo, uma vez que ele tem mais que o dobro de partidas que os outros. Também foi possível notar que os dois níveis fáceis tiveram uma taxa de vitória mais de 2 vezes maior que os níveis médios, e estes, cerca de 10 pontos percentuais à mais que os difíceis. Essa tendência mostrou que a dificuldade percebida relativa entre as três possibilidades foi como esperada. Porém, acreditamos que os níveis poderiam ter sido mais fáceis, uma vez que apenas metade dos jogadores conseguiu terminar os níveis fáceis. Alguns jogadores relataram em *feedbacks* por extenso esse problema indicado, que também pode ser visto nos dados: a dificuldade estava relativamente elevada mesmo nos níveis mais fáceis. Isto possivelmente influenciou no menor nível de pessoas jogando os níveis de maior dificuldade, uma vez que o médio já estava muito desafiador para a grande maioria.




Figura 1 – Número de jogadores e taxa de vitória por nível.

Essa dificuldade elevada foi especialmente desconfortável para boa parte dos participantes, já que costumam jogar em dificuldades médias, como pode ser visto na Figura 2: mais de 30 dos 55 participantes afirmaram preferir tal dificuldade. A maioria dos jogadores tinha uma experiência média a grande com jogos e jogos de ação-aventura. Em sua maioria eles tinham características de exploradores, "complecionistas"(interessados em completar todos os objetivos dados) e com gosto por combate e ação (perguntas 4, 5 e 7). Eles afirmaram gostar de jogos voltados para pensamento rápido, exploração e uso de lógica, mas não muito de jogos de simulação, segundo suas respostas às questões de 8 a 11.

Conhecendo melhor os jogadores que participaram, foi possível fazer uma análise de melhor qualidade de suas respostas no questionário pós-teste sobre cada nível, apresentadas na Figura 3. Podemos observar, por exemplo, que os níveis mais fáceis foram tidos como mais divertidos e balanceados que os mais difíceis, com a média das respostas em escala Likert dos fáceis próxima à 4, enquanto à dos difíceis entre 2 e 3. Isso provavelmente ocorreu devido aos




Figura 2 – Soma das respostas em cada nível da escala Likert para cada pergunta do questionário pré-teste.

jogadores ficarem frustrados de perder várias vezes nos níveis mais difíceis, especialmente pois a maioria dos jogadores não tinha costume de jogar em dificuldades altas. Isso é corroborado com as respostas da pergunta 2, sobre o desafio ser balanceado: a média das opiniões diz que os níveis mais fáceis eram mais balanceados que os mais difíceis. Os níveis difíceis e médios foram considerados quase que igualmente difíceis no geral e em combate, com exceção do nível mais curto dos difíceis. Porém deve-se lembrar que poucas pessoas jogaram tais níveis mais difíceis (menos de 10 em cada) e, portanto, a relevância estatística desses dados não é garantida. Há também um certo viés nesses dados, uma vez que a maioria dos jogadores que alcançaram estas fases eram mais habilidosos e persistentes que a média.

Outro dado interessante foi que a sensação de ter que revisitar mais salas foi maior de acordo com o aumento do tamanho dos níveis, mesmo quando eles eram mais lineares (linearidade 1.21, por exemplo) e, portanto, menos suscetíveis ao *backtracking* por parte do jogador. Uma possível explicação pode ser que como os combates exigiam muita dedicação dos jogadores e ocorriam em toda sala, eles tendiam a esquecer informações importantes do mapeamento da fase (localização de portas trancadas por chaves que acabaram de coletar, por exemplo) e, mesmo com o minimapa, revisitavam muitas salas. A dificuldade de exploração foi sentida de maneira relativamente proporcional à sensação de *backtracking*, como esperado.

De modo a reduzir o ruído devido ao baixo número de jogadores, além daqueles que não conseguiram completar o nível e, portanto, podem não ter explorado o nível em sua totalidade, a Figura 4 mostra a média das respostas dadas apenas por jogadores que terminaram os níveis, e apenas dos 3 níveis com mais respostas. Nestas condições, foram obtidas as respostas de 23, 6 e 12 usuários para cada nível, de cima para baixo, na legenda do gráfico. Com esta análise mais precisa, podemos ver que a noção de *backtracking* e dificuldade de exploração ainda são maiores no maior nível (22 salas). Porém o nível médio foi considerado mais divertido, mesmo com sua dificuldade geral e de combate considerada maiores que o dos fáceis. Além disso, o nível




Figura 3 – Média das respostas dos jogadores para cada pergunta do questionário pós-teste, por nível jogado.

com mais salas da dificuldade fácil foi considerado mais difícil que o menor, provavelmente devido ao maior número de inimigos presente nele e, portanto, demandando maior resistência do jogador para superar todos os desafios. Notou-se que a dificuldade média e o maior nível da dificuldade fácil foram tidos como os mais balanceados, e o médio mais divertido que os fáceis. Isso provavelmente se deu pelo fato de que os jogadores que conseguiram completar eram mais habilidosos e sentiram-se recompensados por sua maestria ao terminar um nível de dificuldade razoavelmente elevada.




Figura 4 – Média das respostas dos jogadores para cada pergunta do questionário pós-teste, por nível jogado, considerando apenas as respostas dos jogadores que conseguiram terminar o nível.

De modo a verificar se as preferências dos jogadores poderiam afetar suas respostas sobre os níveis, eles foram divididos em alguns grupos de perfis teóricos baseados nas respostas do questionário pré-teste. Aqueles que responderam com 4 ou 5 (positivamente) na questão 4 e 9, ambas relacionadas à exploração, foram categorizados como *exploradores*. Já aqueles que responderam com 4 ou 5 para as questões 7 e 8, relacionadas ao combate e ação, foram

categorizados como *combatentes*. Por fim, quem respondeu acima de 3 para as questões 2 e 3, relacionadas à experiência com jogos da área e com jogos difíceis, foram chamados de *hardcore/veteranos*. Foram comparadas suas respostas entre si e perante à resposta da média de todos os respondentes, que foi atribuída como *baseline*. De modo a respeitar o limite de páginas desta monografia, serão apresentados aqui os resultados dos 3 níveis com maior número de jogadores, como discutido no parágrafo anterior. Porém, os resultados para os outros 4 níveis encontram-se no Anexo A.

Na Figura 5 pode-se verificar a análise para os dois níveis da dificuldade fácil. No nível à esquerda, menor, pode-se observar que a diferença mais significativa das respostas provêm dos jogadores veteranos: eles acharam o nível mais balanceado, porém, mais fácil tanto no geral como no combate, e levemente mais fácil na exploração e com menos *backtracking*. Mas tudo isso sem achar menos divertido. Pode-se considerar uma análise precisa, advinda da experiência deles nesse tipo de jogo, que os permite identificar com mais facilidade questões de dificuldade e complexidade. Já na figura da direita, no nível fácil maior, a maior diferença dá-se pelos combatentes, que acharam o nível com menor *backtracking* e dificuldade de exploração que os outros, além de um pouco menos balanceado. É possível que isso tenha ocorrido uma vez que, por não terem um gosto maior por exploração e sim por combate, eles não tiveram problemas em navegar pelas salas como os perfis de exploradores e *baseline*, e estes podem ter atribuído erroneamente à exploração a dificuldade extra causada pela necessidade de sobreviver ao combate por tantas salas. O fato dos jogadores classificados como veteranos terem votado que a dificuldade geral, de exploração e a necessidade de *backtracking* como menores que os exploradores e *baseline* corrobora com esta interpretação dos dados.



(a) Pós teste por perfil do nível E-R14-K3-L3-L1.51. (b) Pós teste por perfil do nível E-R22-K4-L4-L1.62.

Figura 5 – Pós teste por perfil dos dois níveis fáceis

Por fim, na Figura 6 pode-se observar uma maior divergência dos dados. Os perfis diferentes do *baseline* acharam o nível mais divertido: provavelmente por serem mais experientes tiveram mais diversão no desafio maior. Eles também acharam o desafio mais balanceado (exploradores e veteranos mais que combatentes). Os veteranos e combatentes acharam o nível com menos necessidades de *backtracking* que os outros dois. Porém, os veteranos acharam o

nível menos difícil de forma geral e nos outros aspectos. Enquanto os exploradores e combatentes só divergiram de opinião da *baseline* quanto à dificuldade de exploração, que acharam menos difícil. De modo geral, os dados mostraram que o desafio maior foi bem aceito pelos perfis melhores definidos, mesmo que não focados em combate ou dificuldade, como os exploradores.




Figura 6 – Pós teste por perfil do nível M-R18-K4-L4-L1.21

Depois dessas análises, iniciou-se o processo de exploração de agrupamentos. Vários algoritmos foram testados, utilizando o método de pontuação por silhueta (*silhouette score*) para determinar bons conjuntos; quanto maior melhor. Os dados foram normalizados, de forma a remover o viés por números grandes, como o valor de Tesouros acumulados. Devido ao menor número de jogadores nas fases mais difíceis, só foram agrupadas as performances de jogadores nas duas fases mais fáceis e na média de tamanho mais curto. Os algoritmos utilizados para aglomeração e cálculo de silhueta foram tirados da biblioteca scikit learn (PEDREGOSA *et al.*, 2011).

Os algoritmos que obtiveram melhor pontuação foram os de K-próximos vizinhos e o agrupador aglomerativo de "Ward", com valores de silhueta praticamente idênticos entre os dois. Suas pontuações indicaram que até três agrupamentos eram possíveis na fase fácil mais curta, com pontuação próxima de 0,4 para dois agrupamentos e 0,3 para três. As outras fases possuíam pontuação próxima de 0,3 para dois agrupamentos. Algoritmos baseados em densidade não se mostraram muito eficazes, uma vez que englobaram todos os jogadores em um único grande agrupamento.

Ao investigar as características desses agrupamentos, percebeu-se que sua principal distinção era se o jogador venceu ou perdeu. No caso da fase fácil menor, um terceiro grupo foi gerado contendo apenas dois jogadores que não responderam os questionários. Uma única exceção foi vista nos da fase média, onde um jogador que perdeu foi agrupado junto aos vencedores por possuir características bastante próximas de performance e personalidade, indicando que ele deve ter sido derrotado perto do fim.

Decidiu-se criar agrupamentos de maior número, mesmo com pontuações de silhueta

muito baixas. Ao criar três agrupamentos nas fases média e fácil longa, notou-se que os agrupamentos de perdedores e vencedores, respectivamente, foram divididos em dois. Sua distinção mais perceptível foi o desempenho, uma vez que um dos agrupamentos havia coletado mais Tesouros e aberto mais portas, ou seja, exploraram mais trechos do mapa mesmo perdendo ou ganhando.

Foram também criados agrupamentos levando em consideração apenas as respostas das perguntas antes e depois de jogo, buscando encontrar diferentes arquétipos de jogadores. Porém nenhum resultado apresentou pontuação de silhueta maior que 0,2. Isso pode ser explicado pela semelhança nas respostas dos vários jogadores, como pôde ser visualizado na figura 2. Ao criar dois agrupamentos distintos, notou-se que a principal distinção era o nível de habilidade autorrelatado, ou seja, um resultado pouco diferente das outras tentativas de agrupamento.

Tais semelhanças também explicaram o motivo dos algoritmos baseados em densidade não terem sido muito eficazes. Talvez, com uma base de dados maior, seria possível encontrar estilos demarcadamente diferentes entre os jogadores, o que acaba por ser uma limitação deste trabalho.

Após explorar os agrupamentos, foram aplicados quatro algoritmos de classificação na base de dados completa (contendo todas as jogadas de todos os jogadores em todas as fases, tenham sido elas vencedoras ou não). Os quatro algoritmos foram: Redes Neurais Artificiais simples (estilo Perceptron de Múltiplas Camadas, com camada oculta de tamanho igual à quantidade de entradas), K-próximos vizinhos, Florestas de decisão (*Random Forests*) e classificadores bayesianos ingênuos (*Naive Bayes*). Todos eles, junto com os métodos de cálculo de acurácia, foram tirados da biblioteca scikit learn (PEDREGOSA *et al.*, 2011).

O primeiro experimento foi tentar prever se o jogador venceu a fase ou não, baseando-se apenas nos dados de sua performance. Todos os algoritmos obtiveram altas taxas de acurácia, consistentemente acima de 94%; o algoritmo com a maior taxa foi a de Florestas de decisão, alcançando 97%. As taxas de precisão e revocação também foram bastante altas, a mais baixa ficando em 76% (revocação); as taxas mais altas foram também as das Florestas de decisão, alcançando 93% e 90%, respectivamente. Era de se esperar altas taxas de acurácia, já que a chance de um jogador, que explorou poucas salas e destrancou poucas portas, achar a saída é baixa.

O experimento anterior foi replicado, mas utilizando os dados de perfil, coletados no pré-teste. Todos os algoritmos, exceto o de K-próximos vizinhos, obtiveram acurácia muito baixa, próxima de 64%. Porém ao adicionar apenas a dificuldade da fase jogada à entrada, os resultados subiram em todos esses métodos. Os resultados subiram de 64% para 84% no caso das Redes Neurais, 65% para 74% nos Classificadores Bayesianos, 81% para 84% no de K-Próximos Vizinhos e 64% para 71% no caso das Florestas de Decisão. As taxas de revocação e precisão foram baixas, com o maior resultado em 30%. É provável que, como os jogadores eram semelhantes entre si, o método de K-Vizinhos conseguiu uma pontuação alta mesmo sem

ter o dado da dificuldade jogada e seu acréscimo pequeno também pode ser explicado por esse motivo, já que a adição de uma única dimensão não altera tanto a distância entre os pontos. As Redes Neurais foram as que mais se beneficiaram com a adição; é provável que mantivessem sua alta acurácia caso houvessem mais tipos de perfis. Por fim, as baixas taxas de revocação e precisão podem ser explicadas pela enorme disparidade nos tipos de jogada: haviam mais de 100 jogadas no nível fácil e curto e no difícil e longo, mas apenas quatro vencedores no último. Uma variabilidade tão grande impede que precisões mais altas sejam atingidas.

Por fim, decidiu-se prever as opiniões do jogador, colhidas no pós-teste, com os dados de performance e perfil. Os mesmos métodos foram utilizados para prever a resposta dada a cada uma das seis perguntas. O método com melhor desempenho foi o de K-Próximos Vizinhos, provavelmente pelo mesmo motivo anteriormente discutido: como os jogadores não eram tão diferentes, é mais eficaz compará-los com os vizinhos imediatos ao invés de buscar grandes padrões. A acurácia foi calculada em razão da opinião prevista comparada com a coletada; caso os valores fossem idênticos, a predição foi correta, caso contrário, foi incorreta.

Tabela 4 – Acurácia da classificação para prever a respostas para cada uma das perguntas do pós teste (Tabela 2) por diferentes métodos

Método	Acurácia P1	Acurácia P2	Acurácia P3
Redes Neurais Artificiais	66%	53%	52%
K-Próximos Vizinhos	70%	71%	69%
Florestas de Decisão	67%	69%	70%
Bayesianos Ingênuos	55%	43%	50%
Método	Acurácia P4	Acurácia P5	Acurácia P6
Redes Neurais Artificiais	69%	63%	56%
K-Próximos Vizinhos	70%	71%	73%
Florestas de Decisão	68%	68%	69%
Bayesianos Ingênuos	52%	51%	53%

3.4 Dificuldades e Limitações

Apesar de 55 pessoas ser um número considerável, ainda é uma quantidade pequena se comparada às bases de dados das pesquisas de Vahlo et al. (VAHLO *et al.*, 2017) e Melhart et al. (MELHART *et al.*, 2019), o que explica a quantidade menor de agrupamentos. Devido às restrições consequentes da pandemia de SARS-CoV19, não foi possível convidar usuários desconhecidos pessoalmente, enviando o total de jogadores, além de dificultar a comunicação entre os autores desta pesquisa.

Muitos usuários também acharam as fases muito difíceis, limitando ainda mais o tamanho da base de jogadores. A grande maioria dos jogadores não passou das fases cuja dificuldade havia sido considerada média, e a taxa de jogadores que decidiram refazer uma fase que ganharam foi bastante baixa. Por esse motivo, havia um certo viés para que jogadores procurassem passar

de fase quando conseguissem, ao invés de se arriscar indo atrás de Tesouros ou tentar jogar a fase novamente e não obter sucesso, o que é um estilo de jogo comum segundo os relatos dos próprios jogadores, como mostrado na figura 2.

Como mais um fator limitante na diversidade dos estilos de jogo, mesmo incluindo novas ações possíveis, ainda não haviam dinâmicas muito diferentes para que se aflorassem jogadas muito distintas, nem uma escala grande o bastante de tempo para que o volume de dados a respeito de um único usuário fosse grande o bastante para a criação de um perfil detalhado do mesmo.

CONCLUSÃO

Neste trabalho, estudou-se todo o processo de realização de uma pesquisa acadêmica: a busca por referências e trabalhos correlatos, de forma a criar uma base sólida e atualizada na área de interesse; o planejamento e dimensionamento do tempo disponível para realização do trabalho; a criação de padrões para experimentar, medir e comprovar (ou desaprovar) a hipótese proposta.

Levando em consideração os fatores citados na seção final do capítulo 3, os resultados apresentados foram bastante promissores. Mostrou-se possível aplicar técnicas de Mineração de Dados para revelar informações a respeito da experiência de jogo que os usuários estão possuindo.

Comparando os resultados do Teste de Prova e do Teste em Larga Escala, nota-se um aumento na quantia de relações extraídas, mesmo com uma enorme redução na quantidade de usuários amostrados. Logo, o escopo pequeno dos resultados deve ser atribuído ao escopo pequeno dos dados de entrada em si. É possível que, se esta pesquisa fosse provida apenas de uma quantidade maior de usuários para teste, relações ainda mais complexas emergissem em meio às análises.

Portanto, a investigação de perfis de jogadores é sim realizável, mesmo em escalas pequenas, e seu grande potencial ainda há de ser completamente investigado. Isso abre possibilidade para, num trabalho futuro, se desenvolver um jogo que, munido de dados coletados durante o jogo e em uma pesquisa de opinião, gere conteúdo planejado para melhor agradar o jogador em específico. Como o ProCoG é capaz de gerar fases e inimigos proceduralmente com parâmetros ajustáveis, esta ideia se torna ainda mais atraente. Outras possibilidades de expansão futura se dá pela adição de mecânicas diferentes ao jogo, permitindo a manifestação de mais estilos de jogo, como se almejou com a adição dos tesouros, combo e tela de pontuação.

REFERÊNCIAS

ARTIFICIAL Intelligence for Citizen Services and Government. 2017. Disponível em: <<https://ash.harvard.edu/publications/artificial-intelligence-citizen-services-and-government>>. Citado na página 26.

AZADVAR, A.; CANOSSA, A. Upeq: Ubisoft perceived experience questionnaire: A self-determination evaluation tool for video games. In: **Proceedings of the 13th International Conference on the Foundations of Digital Games**. New York, NY, USA: ACM, 2018. (FDG '18), p. 5:1–5:7. ISBN 978-1-4503-6571-0. Disponível em: <<http://doi.acm.org/10.1145/3235765.3235780>>. Citado na página 34.

BARTLE, R. Designing virtual worlds. In: _____. [S.l.: s.n.], 2003. p. –768. ISBN 0131018167. Citado na página 32.

BICHO, F.; MARTINHO, C. Multi-dimensional player skill progression modelling for procedural content generation. In: **Proceedings of the 13th International Conference on the Foundations of Digital Games**. New York, NY, USA: ACM, 2018. (FDG '18), p. 1:1–1:10. ISBN 978-1-4503-6571-0. Disponível em: <<http://doi.acm.org/10.1145/3235765.3235774>>. Citado na página 22.

CIOS, K. J.; KURGAN, L. A. Trends in data mining and knowledge discovery. **Advanced Information and Knowledge Processing Advanced Techniques in Knowledge Discovery and Data Mining**, p. 1–26. Citado na página 26.

EARNINGS & Sales. 2020. Disponível em: <https://www.ubisoft.com/en-us/company/investor_center/earnings_sales.aspx>. Citado na página 33.

Esfahlani, S. S.; Cirstea, S.; Sanaei, A.; Wilson, G. An adaptive self-organizing fuzzy logic controller in a serious game for motor impairment rehabilitation. In: **2017 IEEE 26th International Symposium on Industrial Electronics (ISIE)**. [S.l.: s.n.], 2017. p. 1311–1318. Citado na página 22.

HEIJNE, N. **Investigating the Relationship between FFM, Game Literacy, Content Generation and Game-play Preference**. Dissertação (Mestrado) — University of Amsterdam, 2016. Disponível em: <<https://esc.fnwi.uva.nl/thesis/centraal/files/f840179296.pdf>>. Citado 3 vezes nas páginas 29, 33 e 34.

HOOSHYAR, D.; YOUSEFI, M.; LIM, H. A procedural content generation-based framework for educational games: Toward a tailored data-driven game for developing early english reading skills. **Journal of Educational Computing Research**, v. 56, n. 2, p. 293–310, 2018. Disponível em: <<https://doi.org/10.1177/0735633117706909>>. Citado na página 22.

HOW much did modern warfare 2 cost to make? | the escapist. 2009. Disponível em: <<https://v1.escapistmagazine.com/news/view/96227-How-Much-Did-Modern-Warfare-2-Cost-to-Make>>. Citado na página 22.

Kern, F.; Winter, C.; Gall, D.; Käthner, I.; Pauli, P.; Latoschik, M. E. Immersive virtual reality and gamification within procedurally generated environments to increase motivation during gait rehabilitation. In: **2019 IEEE Conference on Virtual Reality and 3D User Interfaces (VR)**. [S.l.: s.n.], 2019. p. 500–509. Citado na página 22.

MELHART, D.; AZADVAR, A.; CANOSSA, A.; LIAPIS, A.; YANNAKAKIS, G. N. Your gameplay says it all: Modelling motivation in tom clancy's the division. **CoRR**, abs/1902.00040, 2019. Disponível em: <<http://arxiv.org/abs/1902.00040>>. Citado 5 vezes nas páginas 22, 32, 33, 34 e 45.

NEWZOO Global Games Market Report 2020: Light Version. 2020. Disponível em: <<https://newzoo.com/insights/trend-reports/newzoo-global-games-market-report-2020-light-version/>>. Citado 2 vezes nas páginas 21 e 22.

OPENAI; BERNER, C.; BROCKMAN, G.; CHAN, B.; CHEUNG, V.; DEBIAK, P.; ...; ZHANG, S. **Dota 2 with Large Scale Deep Reinforcement Learning**. 2019. Citado na página 22.

PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V.; VANDERPLAS, J.; PASSOS, A.; COURNAPEAU, D.; BRUCHER, M.; PERROT, M.; DUCHESNAY, E. Scikit-learn: Machine learning in Python. **Journal of Machine Learning Research**, v. 12, p. 2825–2830, 2011. Citado 3 vezes nas páginas 26, 43 e 44.

PEREIRA, L. T. **Procedural Generation of Dungeon Maps, Missions and Rooms**. Dissertação (Mestrado) — Universidade de São Paulo, 2018. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/55/55134/tde-25032019-144917/en.php>>. Citado 6 vezes nas páginas 23, 25, 27, 28, 31 e 34.

RIVERA-VILLICANA, J.; ZAMBETTA, F.; HARLAND, J.; BERRY, M. Informing a bdi player model for an interactive narrative. In: **Proceedings of the 2018 Annual Symposium on Computer-Human Interaction in Play**. New York, NY, USA: ACM, 2018. (CHI PLAY '18), p. 417–428. ISBN 978-1-4503-5624-4. Disponível em: <<http://doi.acm.org/10.1145/3242671.3242700>>. Citado 2 vezes nas páginas 29 e 33.

RODRIGUES, L.; BRANCHER, J. Procedurally generating a digital math game's levels: Does it impact players' in-game behavior? **Entertainment Computing**, v. 32, p. 100325, 2019. ISSN 1875-9521. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1875952119300308>>. Citado na página 22.

SERBAN, I. V.; SANKAR, C.; GERMAIN, M.; ZHANG, S.; LIN, Z.; SUBRAMANIAN, S.; KIM, T.; PIEPER, M.; CHANDAR, S.; KE, N. R.; AL. et. **A Deep Reinforcement Learning Chatbot**. 2017. Disponível em: <<https://arxiv.org/abs/1709.02349>>. Citado na página 21.

VAHLO, J.; KAAKINEN, J.; HOLM, S.; KOPONEN, A. Digital game dynamics preferences and player types: Preferences in game dynamics. **Journal of Computer-Mediated Communication**, 02 2017. Citado 3 vezes nas páginas 32, 34 e 45.


VILLAPAZ, L. **'GTA 5' Costs \$265 Million To Develop And Market, Making It The Most Expensive Video Game Ever Produced: Report**. 2013. Disponível em: <<https://www.ibtimes.com/gta-5-costs-265-million-develop-market-making-it-most-expensive-video-game-ever-produced-report>>. Citado na página 22.

VINYALS, O.; BABUSCHKIN, I.; CHUNG, J.; MATHIEU, M.; JADERBERG, M.; CZARNECKI, W.; ...; SILVER, D. **AlphaStar: Mastering the Real-Time Strategy Game StarCraft II**. 2019. <<https://deepmind.com/blog/alphastar-mastering-real-time-strategy-game-starcraft-ii/>>. Citado na página 22.


YADAV, P.; STEINBACH, M.; KUMAR, V.; SIMON, G. Mining electronic health records: A survey (<https://dl.acm.org/citation.cfm?id=3127881>). **ACM Computing Surveys**, v. 50, 02 2017. Citado na página 26.

DADOS EXTRAS SOBRE OS NÍVEIS

A Figura 7 contém duas imagens da tela do protótipo de jogo ProCoG, que foi usado para coletar dados dos jogadores para esse experimento. À direita é possível ver diversos inimigos atacando o jogador. Na Figura 8 é possível ver a tela de um dos formulários que os jogadores responderam durante o experimento.



(a) Tela do jogo com o jogador ao centro.



(b) Tela do jogo com o jogador sendo atacados por diversos inimigos

Figura 7 – Telas do jogo ProCoG

Antes de começar, gostaríamos de saber um pouco mais sobre você.
Por favor, responda as perguntas abaixo!

Sou um(a) jogador(a) experiente

1 = Discordo Fortemente <-> 5 = Concordo Fortemente

1 2 3 4 5

Sou um(a) jogador(a) experiente no gênero ação-aventura

1 = Discordo Fortemente <-> 5 = Concordo Fortemente

1 2 3 4 5

Qual é dificuldade na qual geralmente você costuma jogar seus jogos?
(existem diversas nomenclaturas nos jogos. Tente escolher a que para você é a mais adequada na escala usada)

1 = Muito Fácil <-> 5 = Muito Difícil (Impossível, etc.)

1 2 3 4 5

Quando jogo, eu normalmente exploro todos os lugares, elementos e personagens do mundo virtual

1 = Discordo Fortemente <-> 5 = Concordo Fortemente

1 2 3 4 5

Quando jogo, eu normalmente completo todas as missões, incluindo aquelas que não são necessárias para terminar o jogo (por exemplo, missões secundárias).

1 = Discordo Fortemente <-> 5 = Concordo Fortemente


1 2 3 4 5

Quando jogo, eu normalmente apenas faço o necessário para passar de um nível (ou de uma fase) ou para completar uma missão.

Figura 8 – Tela de um dos questionários dentro do jogo ProCoG


Neste anexo também estão alguns dados sobre o experimento que não foram capazes de levar a conclusões significativas e não respeitariam o limite de páginas, mas que são interessantes o suficiente para serem mostrados para aqueles com curiosidade de conhecer melhor os dados coletados.

As Figuras 9 e 10 apresentam os dados do pós teste por perfil dos 4 níveis que não possuíam respondentes o suficiente para terem relevância estatística. Porém, neles é possível ainda observar algumas das tendências observadas no Capítulo 3: os veteranos tendem a achar os níveis, em todas as perspectivas, mais fáceis (com exceção da exploração no mapa H-R14-K3-L3-L1.21 e no H-R22-K4-L4-L1.63).



(a) Pós teste por perfil do nível M-R22-K4-L4-L1.21. (b) Pós teste por perfil do nível H-R14-K3-L3-L1.21.

Figura 9 – Pós teste por perfil do maior nível médio e do menor difícil



(a) Pós teste por perfil do nível H-R18-K4-L4-L1.51. (b) Pós teste por perfil do nível H-R22-K4-L4-L1.63.

Figura 10 – Pós teste por perfil dos dois maiores níveis difíceis

A Figura 11 mostra a taxa de vitória de cada perfil em cada mapa. De modo geral, os perfis diferentes do *baseline* tiveram uma taxa de vitória consideravelmente maior. Em especial, os jogadores veteranos tiveram um desempenho notavelmente melhor que os outros perfis nos 3 níveis mais à esquerda da figura, que também são os com maior número de jogadores.

Por fim, a Figura 12 apresenta dados da exploração dos mapas por cada perfil. Não foram observadas muitas mudanças tanto no número de salas visitadas (contando retornos à mesma sala) quanto na porcentagem do total de salas diferentes visitadas. É possível que isso tenha ocorrido pela falha em motivar suficientemente o jogador a explorar outras áreas. Sua recompensa era um tesouro sem efeitos dentro do jogo a não ser uma pontuação maior. Esta pontuação não era mostrada no servidor do jogo para que jogadores competissem entre si, nem

Taxa de Vitória por Perfil e Nível






Figura 11 – Taxa de vitória em cada mapa por perfil

usada para comprar melhoras ou desbloquear algum conteúdo extra. Portanto, é provável que os jogadores não foram compelidos a explorar mais e coletar itens nestas salas extras, afetando a qualidade dos dados.

Média Salas Visitadas por Perfil e Nível (Apenas Vitórias)



Média Porcentagem de Exploração por Perfil e Nível (Apenas Vitórias)



- (a) Média de salas visitadas por perfil e nível (apenas jogadores que venceram) (b) Porcentagem de exploração do mapa por perfil e nível (apenas jogadores que venceram).

Figura 12 – Dados de exploração de cada mapa por perfil e nível