



Universidade de Brasília

Programa de Pós-Graduação em Informática da Universidade de Brasília.

Departamento de Ciência da Computação

**Uma Abordagem Automatizada para Estimar a
Experiência do Jogador em Eventos de Jogo usando
Sinais Psicofisiológicos.**

Elton Sarmanho Siqueira

Tese apresentada como requisito parcial para
conclusão do Doutorado em Informática

Orientador

Prof. Dr. Ricardo Pezzuol Jacobi

Coorientadora

Prof.^a Dr.^a Carla Denise Castanho

Brasília
2022

Ficha catalográfica elaborada automaticamente,
com os dados fornecidos pelo(a) autor(a)

SS246a Sarmanho , Elton
Uma Abordagem Automatizada para Estimar a Experiência do Jogador em Eventos de Jogo usando Sinais Psicofisiológicos / Elton Sarmanho ; orientador Ricardo Pezzuol; co-orientador Carla Denise. -- Brasília, 2022.
140 p.

Tese(Doutorado em Informática) -- Universidade de Brasília, 2022.

1. Biometria. 2. Machine learning. 3. Experiência do Jogador. 4. psicofisiologia. I. Pezzuol, Ricardo, orient. II. Denise, Carla, co-orient. III. Título.



Universidade de Brasília

Programa de Pós-Graduação em Informática da Universidade de Brasília.

Departamento de Ciência da Computação

Uma Abordagem Automatizada para Estimar a Experiência do Jogador em Eventos de Jogo usando Sinais Psicofisiológicos.

Elton Sarmanho Siqueira

Tese apresentada como requisito parcial para
conclusão do Doutorado em Informática

Prof. Dr. Ricardo Pezzuol Jacobi (Orientador)
CIC/UnB

Prof. Dr. Esteban Walter Gonzalez Clua Prof. Dr. Daniela Gorski Trevizan
Universidade Federal Fluminense Universidade Federal Fluminense

Prof. Dr. Tiago Barros Pontes e Silva
Universidade de Brasília

Prof. Dr. Ricardo Pezzuol Jacobi
Coordenador do Programa de Pós-graduação em Informática

Brasília, 14 de Novembro de 2022

Dedicatória

Aos meus pais, Paulo e Georgina, as pessoas mais especiais deste mundo, que não mediram forças para hoje terem um filho doutor. Essa vitória é de vocês. Como foi prometido pai, agora o senhor tem um filho Doutor...

Agradecimentos

Esta tese não seria possível sem ajuda de muitas pessoas. Impossível começar esta seção de *agradecimentos* sem um muito obrigado eterno todo especial aos meus pais (Paulo Dinelli e Georgirna Sarmanho) e irmão (Emerson Sarmanho). Sem as suas palavras de consolo, apoio constante e a confiança que sempre depositaram em mim, eu não teria chegado até aqui. Na realidade, sem essas pessoas que amo muito, eu não teria chegado a lugar algum. Minha eterna gratidão !! Amo vocês ...

Falando em ensinamentos, deixo aqui os meus agradecimentos mais sinceros ao meu orientador e coorientadora, professor Ricardo Jacobi e professora Carla Castanho. Nesses quase sete anos de convivência acadêmica, vários foram as lições transmitidas a mim por essas pessoas. Além destes, vários outros professores do CIC-UnB participaram de forma direta ou indireta da minha formação. Por isso, não posso deixar de agradecê-los. Muito obrigado ao prof Li Weigang, Lamar e Genáina Nunes. Neste trabalho não cabe nem a metade de tudo que aprendi com vocês durante os meus anos de pós-graduando em nosso departamento. Agradecimentos para todos os funcionários do CIC-UnB que deixavam os laboratórios organizados para todo os dias consegui trabalhar.

Mesmo rodeado pelos membros de uma excelente família e ótimos professores, eu nada seria sem os meus amigos. Por isso meus agradecimentos verdadeiros aos companheiros de laboratório (Jeremias, Daniel Souza e Danilo Amaral). A este último, meu muito obrigado pelo papel de irmão que exerceu desde que começamos a morar juntos em Brasília. Meus companheiros de tatame da equipe Juquinha Jiu-jistu, meus agradecimentos pelos momentos de descontração e companheirismo no dia a dia. Um agradecimento especial aos amigos Jeremias e Gizele Abdon. Posso afirmar, sem receio nenhum, que, sem eles, tudo isso seria bem mais difícil.

Algumas pessoas participaram diretamente na pesquisa e se tornaram amigos, então não posso deixar de agradecer a valiosa ajuda e amizade que construímos: Marco Akira, Marcos Fleury, Tiago Mashiro e Leornado Marques da UFAL. Realmente, esses foram determinantes durante minha caminhada.

Aos amigos de longa data Henrique Leal, Tássio, Carlos Portela e Jhonathas Sousa o meu valeu pela amizade constante. Sei que, mesmo longe, vocês foram os que mais

torceram por mim.

Outro agradecimento em especial vai para as minhas ex-namoradas que de certa forma elas me ajudaram nessa caminhada, ajudando com apoio e/ou participação direta na pesquisa: Ana Carla, Camila e Rayane.

E por essas e outras pessoas que tudo isso aqui vale a pena!

A todos, muito obrigado!

Resumo

Como os jogos eletrônicos emergem como uma das maiores formas de entretenimento no mundo, ocorre a necessidade de uma melhor compreensão da experiência do jogador. Existem diversas abordagens para avaliar a experiência do jogador. Dentre elas, as avaliações tradicionais, que utilizam autorrelato, observação direta, questionário e a gravação de vídeo e outras mais sofisticadas, como os métodos psicofisiológicos que utilizam biosensores e processamento de imagens. As avaliações tradicionais geralmente utilizam amostras pequenas de participantes e alguns estudos mostram nem sempre ser possível capturar a verdadeira ou a real experiência do jogador durante uma sessão do jogo, principalmente quando a sessão é extensa. Nesse caso, o emprego das avaliações usando métodos psicofisiológicos vem reduzir alguns problemas existentes da avaliação tradicional. Desta forma, o valor do presente estudo compreende um processo que avalia a experiência do jogador adotando um modelo de predição com uso de redes neurais que utilizam um dataset afetivo derivado dos dados psicofisiológicos (EDA, BVP e expressões faciais) dos participantes do experimento. Além disso, esse estudo compara os resultados gerados pelo modelo proposto com o modelo de autorrelato do participante, com a finalidade de verificar se ambos os resultados possuem concordância e se o modelo desenvolvido viabiliza uma nova forma de avaliar a interação do jogador com jogo. Os resultados finais mostram que o modelo teve boa concordância com os dados relatados pelos participantes. No geral, essa pesquisa identifica a avaliação da experiência do jogador usando dados psicofisiológicos como uma abordagem automatizada. A metodologia empregada nesse trabalho junto com seus resultados apresentam uma nova contribuição para as pesquisas relacionadas ao processo de avaliação da experiência do jogador.

Palavras-chave: Telemetria, Emoções, Experiência do Jogador, Sinais Psicofisiológicos, Expressão Facial

Abstract

Electronic games emerge as one of the biggest forms of entertainment in the world. As a consequence, a better understanding of the player experience is necessary. There are several approaches to evaluate the player's experience. Among them, we have traditional evaluation approaches that make use of self-report, direct observation, questionnaire and video recording, as well as more sophisticated approaches, such as psychophysiological methods, which make use of biosensors and image processing. Traditional evaluation approaches make use of small numbers of participants. Due that, some studies show that it is not always possible to capture the true or real experience of the player during a game session, especially after long sessions of game play. In this case, evaluations using psychophysiological methods will reduce some problems of the traditional approaches. Thus, the present study proposes a process that evaluates the player's experience by adopting a prediction model developed using a neural network, which make use of an affective dataset derived from the psychophysiological data (EDA, BVP and facial expressions) of the participants of the experiment. In addition, this study compares the proposed model with the participant's self-report model, in order to verify whether the results of those models are in agreement and whether the developed model enables a new way of evaluating the player's interaction with the game. The final results show that the model had good agreement with the data reported by the participants. This research performs a player experience evaluation using psychophysiological data as a general and automated approach. The methodology used in this work, together with its results, present a new contribution to researches related to the process of evaluating the player's experience.

Keywords: Telemetry, Emotion, Player Experience, Psychophysiological Signals, Facial Expression

Sumário

1	Introdução	1
1.1	Contextualização	1
1.2	Motivação	2
1.3	Objetivos	4
1.4	Contribuição	5
1.5	Organização do Trabalho	6
2	Fundamentação Teórica	7
2.1	Escopo	7
2.2	Game Analytics	7
2.3	Game User Research	8
2.3.1	Métricas de Jogos	10
2.3.2	Biometria	14
2.3.3	Sinais Fisiológicos	14
2.4	Emoções em Jogos	21
2.4.1	O que é Emoção	22
2.4.2	Avaliação da Emoção	23
3	Estado da Arte	28
3.1	Escopo	28
3.2	Análise de dados de Jogos	28
3.3	Visualização dos dados de jogos	37
3.3.1	Visualização	37
3.3.2	Técnicas de Visualização em Game Analytics	37
3.4	Inferindo Emoções em Jogos	46
4	Metodologia Experimental	56
4.1	Escopo	56
4.2	Visão Geral dos Métodos Aplicados	56
4.2.1	Dados Psicofisiológicos Considerados	59

4.2.2	Avaliação das Emoções	63
4.3	Visão Geral do Experimento	64
4.3.1	Participantes	66
4.3.2	Jogo Utilizado	66
4.3.3	Procedimento Experimental	67
4.4	Criação do Dataset Afetivo	70
4.5	Análise de dados	72
4.5.1	Filtragem, Normalização e Segmentação dos dados	72
4.5.2	Extração e Seleção de Características	74
5	Modelo Proposto	77
5.1	Escopo	77
5.2	Detalhes da Arquitetura do Modelo	77
5.3	Validação do Modelo	79
6	Considerações Finais	84
6.1	Escopo	84
6.2	Discussão	84
6.3	Limitações	86
6.4	Conclusões e Trabalhos Futuros	87
6.4.1	Trabalhos Futuros	89
	Referências	91
	Apêndice	104
	A Questionário de Autoavaliação das sessões de jogo	105
	Anexo	118
	I Artigos decorrentes dessa proposta	118
	II Documento referente ao Termo de Consentimento Livre e Esclarecido	123

Lista de Figuras

2.1	Hierarquia das Métricas de jogo.	12
2.2	Sistema Nervoso Humano (Figura Editada).	15
2.3	Uso geral do Sensor EDA	17
2.4	Uso geral do Sensor EMG	18
2.5	Gráfico do ECG.	19
2.6	Forma de onda ECG.	20
2.7	Esquema do sensor EEG.	21
2.8	Um exemplo de mapa de calor de um participante durante interação com jogo por 15 segundos.	22
2.9	Seis expressões faciais das emoções de Paul Ekman.	24
2.10	Mapa das emoções por <i>Plutchik</i>	25
2.11	Roda das Emoções de Genebra	25
3.1	Um Screenshot dos dados da trajetória do jogador.	30
3.2	Comportamento baseado no SOI.	31
3.3	Utilização do algoritmo K-means.	32
3.4	Utilização do algoritmo SIVM.	33
3.5	Uso de diferentes habilidades (em porcentagem) e contagem geral.	35
3.6	Probabilidade entre duas habilidades consecutivas.	35
3.7	Os combos encontrados pelo LSA.	36
3.8	Exemplo de navegação <i>drill-down</i>	38
3.9	Gráfico de dispersão	39
3.10	Exemplo de gráfico de pizza mostrando proporção do número de torres construídas.	39
3.11	Heatmap da localização das mortes dos jogadores.	40
3.12	Exemplo de caminho de visualização com código de cores.	41
3.13	Movimento dos Jogadores entre as áreas.	42

3.14	Interface da versão atual do PLATO com área de visualização (à direita), várias funções para pesquisa, filtragem, agrupamento, bem como geração de gráfico (esquerda) e painel para simulação dependente do tempo (parte inferior).	44
3.15	Um heatmap do mapa do jogo <i>Team Fortress 2</i> mostrando as diferenças relativas do número de mortes (acumuladas em 20 rodadas).	45
3.16	Utilização dos algoritmos de clusterização.	46
3.17	Imagem do jogo Infinite Mario.	47
3.18	A proposta da visualização com linhas que mostram caminho do jogador e o estado de excitação [adaptada].	47
3.19	Uma captura de tela mostrando a coleta de dados psicofisiológicos na pesquisa feita em [116].	50
3.20	Arquitetura da rede neural convolucional usada na pesquisa feita em [82].	51
3.21	Uma captura de tela mostrando a ferramenta de anotação de emoção desenvolvida em [144].	52
3.22	Uma captura de tela mostrando a coleta de dados durante <i>gameplay</i>	53
3.23	Visão geral da arquitetura usada para capturar os dados fisiológicos.	54
3.24	Ferramenta de autorrelato para identificar as emoções durante os eventos do jogo.	55
4.1	Fluxo da aplicação do estudo. No lado esquerdo: As etapas para realização de um experimento. No centro: As etapas do processo de criação do <i>dataset</i> . No lado direito: Os passos que envolvem a análise de dados	58
4.2	Sistema de análise de expressões faciais.	60
4.3	A visualização dos dados psicofisiológicos durante uma sessão de jogo para um participante	62
4.4	Ferramenta de anotação de emoção.	64
4.5	Fases da Aplicação do Protocolo Experimental.	65
4.6	Captura de Tela do Jogo.	67
4.7	Participante durante o procedimento experimental.	69
4.8	Diagrama de bloco representando a cadeia de tratamento dos dados.	73
4.9	Distribuição das emoções prototípicas entre as sessões do jogo.	74
4.10	Scree plot mostrando a escolha do número de fatores.	76
5.1	A matriz de confusão para modelo de classificação	80
5.2	Comparação dos resultados do autorrelato com o modelo em eventos de “Colisão” (<i>Collision</i>).	81

5.3	Comparação dos resultados do autorrelato com o modelo em eventos de “Câmbio” (<i>Gear Box</i>).	82
5.4	Comparação dos resultados do autorrelato com o modelo em eventos de <i>Drifting</i>	83
I.1	<i>R. Teixeira Soares, E. Sarmanho, M. Miura, T. Barros, R. Jacobi and C. Castanho, “Biofeedback Sensors in Electronic Games: A Practical Evaluation,” 2017 16th Brazilian Symposium on Computer Games and Digital Entertainment (SBGames), 2017, pp. 56-65, doi: 10.1109/SBGames.2017.00015.</i>	119
I.2	<i>E. S. Siqueira, C. D. Castanho, G. N. Rodrigues and R. P. Jacobi, “A Data Analysis of Player in World of Warcraft Using Game Data Mining,” 2017 16th Brazilian Symposium on Computer Games and Digital Entertainment (SBGames), 2017, pp. 1-9, doi: 10.1109/SBGames.2017.00009.</i>	120
I.3	<i>E. S. Siqueira, T. A. A. Santos, C. D. Castanho and R. P. Jacobi, “Estimating Player Experience from Arousal and Valence Using Psychophysiological Signals,” 2018 17th Brazilian Symposium on Computer Games and Digital Entertainment (SBGames), 2018, pp. 107-10709, doi: 10.1109/SBGAMES.2018.00022.</i>	121
I.4	<i>“An Automated Approach to Estimate Player Experience in Game Events from Psychophysiological Data”</i>	122
II.1	Termo de Consentimento Livre e Esclarecido	124

Lista de Tabelas

4.1	Número de Participantes na Pesquisa	66
4.2	Taxa de concordância entre avaliadores com os diferentes níveis de granularidade.	71
4.3	Um exemplo de uma amostra exibindo a entrada para um intervalo de 10s, com evento de jogo, a emoção anotada pelos avaliadores, classe emocional e as <i>features</i>	71
4.4	Características extraídas a partir dos sinais coletados	76
5.1	Configurações dos Modelos de Classificação	78
5.2	As diferentes configurações da rede neural	78
6.1	Principais trabalhos na avaliação da Experiência do Jogador que utilizaram sinais psicofisiológicos.	85

Lista de Abreviaturas e Siglas

BVP Blood Volume Pulse.

DDA Dynamic Difficulty Adjustment.

ECG Electrocardiogram.

EDA Electrodermal Activity Sensor.

FPS First Person Shooter.

GSR Galvanic Skin Response.

GUR Game User Research.

HR Heart Rate.

HRV Heart Rate Variability.

IBI Interbeat Interval.

IHC Interação Homem-Computador.

KMO Kaiser-Meyer-Olkin.

LSA Lag Sequential Analysis.

MMOG Massive Multiplayer Online Games.

PX Player Experience.

SCL Skin Conductance Level.

SCR Skin Conductance Responses.

SNA Sistema Nervoso Autônomo.

SNC Sistema Nervoso Central.

SNP Sistema Nervoso Periférico.

SNS Sistema Nervoso Somático.

UnB Universidade de Brasília.

Capítulo 1

Introdução

1.1 Contextualização

Um dos princípios básicos de muitos jogos digitais é fornecer experiências apropriadas aos jogadores que estão interagindo com mundo virtual. Por exemplo, um jogo de terror deve oferecer alguns momentos de cenas de medo ou pânico aos jogadores [42, 147]. Durante o processo de desenvolvimento, o *game designer* (conhecido como projetista de jogo) elabora os cenários com a finalidade de gerar experiências apropriadas ao jogador, tais como diversão, medo, susto, entre outras. Desta maneira, é essencial que a equipe de desenvolvimento possa mensurar se essas experiências são realmente alcançadas. A indústria de jogos junto com as universidades têm tido bastante interesse sobre os aspectos emocionais e afetivos da experiência do usuário (*User Experience* - UX). Quando essa última é tratada no contexto de jogos digitais, podemos referi-la como experiência do jogador (*Player Experience* - PX), que foca nos aspectos qualitativos da interação do jogador com jogo, considerando características como satisfação, dificuldade, entre outras [106].

Em relação ao mercado, no passado, as pesquisas de usuário de jogo (*Game User Research* - GUR) não seguiam metodologias ou práticas bem definidas dentro das empresas de desenvolvimento de jogos. Por exemplo, um processo de seleção de *game tester* (participante que testa todas as funções de um jogo) não possuía um critério de seleção específico ou não existia um guia de instruções formais para aplicação do *playtest* (processo em que *game tester* e a equipe de desenvolvimento testam um jogo a fim de encontrar algum bug ou falha no game design). No dias atuais, GUR é um processo estruturado e bem definido com um conjunto de técnicas e metodologias, composto por especialistas do conhecimento (como psicólogos, cientistas de dados entre outros) e sempre buscando novos métodos para proporcionar uma melhor experiência ao jogador [29, 42]. Entretanto,

apesar do surgimento de novas técnicas, pesquisadores e desenvolvedores ainda possuem dificuldade em realizar uma avaliação efetiva da experiência do jogador [42].

As abordagens atuais para avaliação da experiência do jogador são baseadas em procedimentos que pertencem as outras áreas do conhecimento (como psicologia, sociologia, fisiologia e neurociência), adaptados no domínio do GUR [95]. Ao mesmo tempo, um fato anterior gera uma grande variedade de protocolos científicos que, na maioria das vezes, são aplicados no *playtest* de maneira diferente e, por conseguinte, impactando no processo de avaliação da experiência do jogador [113, 95].

Métodos de avaliação tradicional têm sido adotados com uma taxa de sucesso razoável durante o processo da avaliação de experiência do jogador. Nessa abordagem, os procedimentos mais comuns são de natureza subjetiva, como questionários, entrevistas e análise observacional a partir da gravação de vídeo. Contudo, os métodos de avaliação tradicional dependem exclusivamente das respostas subjetivas dos participantes e, dificilmente, capturam a verdadeira experiência do jogador enquanto ele interage com jogo [93, 42].

Métodos psicofisiológicos apresentam uma abordagem direta para avaliação da experiência do jogador por meio de medidas fisiológicas e afetivas, exigindo uso de equipamentos específicos, tais como biosensores, detectores de movimentos e câmeras. Em particular, esse método tem sido empregado em diversas pesquisas e estudos sobre o comportamento do jogador durante a interação com jogo [69]. Consequentemente, é considerado um método relevante no contexto da avaliação de jogos digitais. Porém, o uso dessa abordagem possui barreiras, como, por exemplo, o custo para aquisição dos equipamentos e a demanda por especialistas em analisar dados psicofisiológicos [133, 69].

Esta seção discutiu o contexto dessa tese de doutorado, que engloba assuntos sobre jogos, dados psicofisiológicos, métodos de avaliação da experiência do jogador entre outros assuntos. As próximas seções abordam a motivação e os objetivos desse trabalho.

1.2 Motivação

Incorporar diferentes fontes de dados no processo de avaliação de um jogo é uma tarefa complexa, mas esse processo permite uma análise mais abrangente das funcionalidades e da experiência de jogo, ampliando a busca de possíveis falhas ou irregularidades no *game design*, pois a perfeita execução de todos esses elementos é vital para o sucesso do jogo no mercado [31].

Uma série de abordagens de testes de software é usada na indústria de jogos, como testes de unidade (*unit test*) e rastreamento de *bugs*. Estes permitem a correção de falhas derivadas do processo de codificação do jogo. Quanto à verificação da jogabilidade, uma possível abordagem seria a observação direta, tal como, por exemplo, um *playtest* em que

os participantes jogam um determinado jogo e seus comportamentos estão sendo observados por vídeo ou um especialista. Essas observações são registradas e posteriormente debatidas com os *designers* do jogo para que eles possam usar essas informações para ajustar o *game design* [60]. Recentemente, os *playtests* têm sido automatizados em grandes empresas, como é o caso da *Microsoft Game Studios*, que desenvolveu um sistema chamado TRUE (*Tracking Real-time User Experience*), o qual combina análise e coleta de dados da interação jogador-jogo e incorpora métodos de IHC (interação Homem-Computador) para avaliação de jogos [67]. No entanto, este sistema não incorpora um procedimento de coleta e análise de dados fisiológicos, os quais poderiam fornecer dados potencialmente importantes para o processo de avaliação [85].

Em um contexto de captura de dados, os métodos tradicionais fornecem medidas de autorrelato (*self-report*) que são usualmente utilizadas no processo de análise e avaliação de jogos e são aplicadas de diferentes formas, normalmente durante uma sessão (questionários) e/ou no final de uma sessão (entrevistas ou questionários). Todavia, a capacidade do autorrelato em identificar as respostas aos eventos do jogo é limitada, pois não é garantido que, no final da sessão, o jogador terá condições de lembrar exatamente todas as experiências que vivenciou nela. Isso é tanto mais difícil quanto mais longa for a sessão. Por outro lado, interromper uma sessão para que o jogador possa expressar o que está sentido poderá causar uma quebra na sua concentração, afetando diretamente a experiência de jogo [129]. Com isso, as medidas de autorrelato tornam-se um recurso (dependendo do contexto da avaliação do jogo) que apresenta significativas limitações para este objetivo. Ainda, a presença de um especialista durante procedimento de observação pode influenciar os resultados da avaliação, pois a percepção do usuário de que está sendo observado pode alterar o seu comportamento durante a sessão [61].

Diante dessas limitações no uso de medidas de autorrelato, as medidas psicofisiológicas vêm se tornando uma nova alternativa para contorná-las [90, 69] e ainda há a possibilidade de fornecer informações sobre como o jogador está reagindo ao jogo [62, 110]. O sistema biológico oferece a vantagem de uma leitura contínua da experiência momentânea do jogador, no que diz respeito à tensão, ao esforço e à excitação, assim fornecendo informações valiosas para avaliar a qualidade dos elementos do jogo. Percebe-se que, nos últimos 10 anos, houve um aumento do número de trabalhos publicados nesse campo, bem como suas aplicações em empresas de desenvolvimento de jogos [156, 121, 69, 133].

Na mesma linha, o uso de câmeras para capturar expressões faciais e extrair dados sobre as variações emocionais do jogador durante as sessões de jogo parece ser uma alternativa promissora, pois a face é um canal importante para a expressão da emoção [71]. A utilização desse recurso, no atual estado tecnológico e financeiro, propicia seu uso e, ainda, no contexto dos jogos digitais, a atenção do jogador é constantemente focada na

tela do jogo. Pesquisas em [72] apontam que os participantes do *playtest* ficam a maior parte do tempo concentrados na tela do jogo. Deste modo, o uso dessa tecnologia pode vir a amenizar os problemas ou limitações derivadas do autorrelato.

Esses métodos citados anteriormente são um subconjunto de abordagens que focam em descrever o comportamento da interação do jogador com jogo. Normalmente, os estudos sobre emoções e jogos envolvem diferentes campos, como psicologia, fisiologia, ciência da computação, estatística, entre outras. Diante disso, a computação afetiva (do inglês *Affective Computing*) tenta unir esses campos, de modo que a sua principal proposta é automatizar o processo de reconhecimento de emoções humanas por meio de algoritmos [140]. Ainda, as principais pesquisas da computação afetiva, no contexto da indústria de jogos, exploram o reconhecimento de emoção durante o desenvolvimento do jogo.

Diante dos expostos citados nos parágrafos anteriores, as principais contribuições dessa tese são: i) criação de um protocolo experimental capaz de adquirir um conjunto de dados afetivos; ii) criação de um dataset afetivo, usando um jogo de corrida como estímulo, para entender quais as condições fisiológicas podem ser as mais relevantes para determinar as emoções dos jogadores; iii) um modelo de predição para prever a emoção vivenciada do jogador durante um evento de jogo.

A fim de validar este trabalho, foi empregada uma comparação com o método tradicional, aplicando ambos os métodos em um jogo de corrida com diferentes configurações e uma amostra representativa de jogadores, o que permite uma comparação útil entre ambos os métodos no que diz respeito à qualidade da experiência resultante da interação do jogador com jogo. A metodologia de pesquisa e a interpretação de resultados foram guiadas pelas principais referências nos campos da ciência de dados, psicologia, psicofisiologia e GUR, seguindo um rigoroso método científico, desde a coleta de dados até a interpretação destes.

A proposta em si, dentro de um contexto de experiência emotiva que é muito mais objetiva do que os aspectos de satisfação de utilidade do jogo (geradas da observação, entrevistas ou questionários), desenvolve um processo que usa as abordagens de computação afetiva para entender e revelar as emoções dos jogadores durante a interação com o jogo, possibilitando, de certa forma, identificar aspectos obscuros do *game design* [131].

1.3 Objetivos

O objetivo geral deste trabalho é propor uma abordagem que realize uma avaliação automatizada da experiência do jogador, estruturada em emoções discretas, usando dados psicofisiológicos. Os objetivos secundários desse trabalho são:

- Estabelecer um processo robusto e flexível, desde a seleção dos participantes (*game tester*) até o armazenamento e tratamento correto dos dados coletados;
- Criar um dataset afetivo que contém as informações psicofisiológicas dos participantes do experimento e as emoções vivenciadas durante as sessões de jogo;
- Analisar os dados para identificar padrões de emoções do jogador durante as sessões de jogo;
- Comparar as respostas emitidas pelo autorrelato dos participantes com as respostas do modelo de predição, de modo a verificar a viabilidade e precisão do modelo.
- Verificar a efetividade do uso de uma avaliação automatizada da experiência do jogador a partir dos dados psicofisiológicos.

1.4 Contribuição

A pesquisa relatada nesta tese investiga especificamente como os dados psicofisiológicos podem representar uma medida direta na qualidade da interação do jogador com jogo. Esperam-se que as metodologias desta pesquisa e os seus resultados representem uma nova contribuição no campo da pesquisa de usuários de jogos e na avaliação da experiência de jogo.

Em especial, uma avaliação utilizando dados psicofisiológicos pode fornecer aos *game researchers* uma melhor compreensão das experiências de jogo pelo usuário. Essa abordagem pode auxiliar em outras pesquisas que incorporam dados psicofisiológicos, como é o caso do ajuste dinâmico de dificuldade (DDA - *Dynamic Difficulty Adjustment*) [25, 141]. Como estes dados não são exclusivos do contexto de jogos digitais, os resultados relatados aqui podem ser utilizados em outras mídias de entretenimento e outros campos de pesquisa, como é caso dos algoritmos de recomendação [49]. Além disso, essa tese fornecerá outras contribuições acadêmicas, como a criação de um dataset afetivo usando jogo como estímulo [50, 159]. Ele será disponível para toda comunidade científica e conterà os dados psicofisiológicos e emocionais (autorrelato) dos jogadores adquiridos durante as sessões.

Outra contribuição pontual é o desenvolvimento de um conjunto de ferramentas *open-source*, em que a primeira é capaz de visualizar os dados psicofisiológicos, enquanto a segunda tem a finalidade de autorrelatar as emoções dos jogadores por meio do processo de anotação.

Por fim, almejam-se reduzir os custos associados à avaliação da experiência do jogador, de forma que pequenas empresas envolvidas no segmento de desenvolvimento de jogos possam se beneficiar com sua utilização.

1.5 Organização do Trabalho

Este documento é apresentado como requisito para grau de doutor do curso de ciência da computação da Universidade de Brasília (UnB). O texto está organizado da seguinte maneira: o capítulo 2 apresenta a fundamentação teórica, que consiste em uma revisão da literatura que apresenta os conceitos sobre *game analytics*, aborda o contexto da análise e avaliação de jogos, informando as principais métricas, métodos subjetivos e psicofisiológicos, uso de sensores e reconhecimento de faces. O capítulo 3 apresenta o estado da arte dessa pesquisa, abrangendo os trabalhos mais relevantes no contexto da avaliação da experiência de jogo e coleta de dados psicofisiológicos. O capítulo 4 apresenta o plano de trabalho, que abrange metodologia para realização dessa pesquisa. O capítulo 5 apresenta os detalhes do modelo proposto e os resultados gerados pelo modelo. Por último, o capítulo 6 apresenta as conclusões e as discussões relacionadas a essa pesquisa.

Capítulo 2

Fundamentação Teórica

2.1 Escopo

O objetivo desse capítulo é estabelecer o melhor entendimento sobre campo de estudo de *Game Analytics*, abrangendo os conceitos sobre telemetria, *player experience* e métricas de jogos, entre outros elementos pertinentes a esta pesquisa de doutorado. Além disso, este capítulo apresenta os principais métodos e instrumentos de avaliação da experiência do jogador, dando maior enfoque nas técnicas que utilizam biometria. Por fim, serão apresentados alguns conceitos intrínsecos da psicologia emocional que englobam os modelos de emoções.

O presente capítulo inicia uma ampla exploração sobre o principal entendimento do campo de estudo de *Game Analytics* e *Player Experience*. Segue, ainda, abordando os principais conceitos de telemetria, explorando os diversos instrumentos e métodos biométricos no contexto da GUR. Em resumo, esse capítulo debate pontos fortes e fracos sobre os métodos de avaliação de *Player Experience*, esclarecendo a principal contribuição desta pesquisa neste contexto.

2.2 Game Analytics

O desenvolvimento de jogos lucrativos e condicionados a funcionarem corretamente no mercado atual é um desafio. Centenas de jogos são publicados anualmente, por meio de várias plataformas de hardware e canais de comunicação, todos disputando o tempo e a atenção do jogador, mostrando como a indústria de jogos é altamente competitiva.

Com propósito de desenvolver jogos eficientes, uma variedade de ferramentas e técnicas tem sido desenvolvidas na indústria de jogos, sendo adotadas e adaptadas a partir de outros setores da tecnologia da informação. Um desses métodos é a análise dos jogos, ou

Analytics, que, nos últimos anos, tem impactado na indústria de jogos e no ambiente de pesquisa.

Conforme El-Nasr et al. [42], *Analytics* é um processo de descoberta e comunicação de padrões nos dados com o objetivo de solucionar problemas nos negócios e/ou realizar previsões para dar suporte à tomada de decisões precisas e corretas. As metodologias para *Analytics* são estatística, mineração de dados (*data mining*) e visualização de dados com o objetivo de transpor ideias e/ou aprendizado para os *stakeholders*. Vale ressaltar que *Analytics* não é somente relatório de BI (*Business Intelligence*) e consulta de dados, mas também atua na análise estatística, modelo de predição e outros.

Existem diversos ramos ou domínios da *Analytics*, tal qual *marketing analytics*, *risk analytics*, *web analytics* e, como destaque nesse projeto de doutorado, tem-se *game analytics*. Este último é um domínio de prática específica aplicado ao contexto de desenvolvimento de jogos e *game research*. O benefício direto de adotar o *game analytics* é promover o suporte à tomada de decisões em todos os níveis e áreas da organização (design, arte, programação, *marketing* e *user research*). Segundo Nacke [104], *game analytics* é direcionado para análise do jogo como produto, no entendimento, se o jogo fornece uma boa experiência ao usuário, e jogo como projeto, no processo de desenvolvimento do jogo, adicionando comparação com outros jogos (*benchmarking*).

Game analytics está relacionado com todas as formas de dados que pertencem ao *game business* ou *game research* e, não exclusivamente sobre o comportamento do usuário ou teste de usuário. Dessa forma, o estudo de todos esses campos tem sido importante para evolução do *Game Analytics* na última década, tornando-se uma análise de negócio adaptada ao contexto específico de jogos [42]. Uma das principais áreas de aplicação atual de *game analytics* é a *Game User Research* (GUR), que será o tema abordado na próxima subseção.

2.3 Game User Research

A *Game User Research* (GUR) ou Pesquisa de Usuário de Jogos consiste na aplicação de várias técnicas e metodologias da psicologia experimental, inteligência computacional, aprendizado de máquina e interação homem-computador para avaliar como as pessoas jogam e a qualidade da interação entre o jogador e o jogo [33]. Além disso, a GUR é um campo interdisciplinar de prática e pesquisa, preocupado em garantir a qualidade ideal de usabilidade e experiência do usuário (UX) em jogos digitais. Isso significa que a GUR envolve qualquer aspecto de um jogo com o qual os jogadores interagem de forma direta e indiretamente, como controles, menus, áudio, arte, infraestrutura, bem como marca, suporte ao cliente e muito mais. Essencialmente, a GUR tem como propósito criar

métodos, técnicas e ferramentas para coletar dados e avaliar a experiência do jogador, informando à equipe de desenvolvimento possíveis falhas ou desbalanceamentos no projeto do jogo que possam afetar diretamente a experiência final.

Muitos aspectos da GUR baseiam-se no conhecimento acumulado no campo de IHC. No entanto, muitas das medidas e das ferramentas usadas na IHC tradicional visam avaliar os aplicativos de produtividade com o intuito de maximizar o desempenho do usuário. Conseqüentemente, muitas técnicas tradicionais de IHC não se encaixam bem no contexto da GUR, porque o valor de entretenimento ou experiência positiva decorrente de um jogo não é meramente uma questão de eficiência do usuário ou facilidade objetiva de interação. Em outras palavras, medidas comuns de experiência do usuário, como eficiência da tarefa ou taxa de erros, não podem ser aplicadas aos jogos da mesma maneira. Além disso, a jogabilidade introduz novos aspectos da experiência do usuário que são inerentes ao jogo, mas são inconcebíveis no contexto de um software de produtividade. Embora um erro de qualquer tipo seja considerado inquestionavelmente negativo em sistemas de informação gerencial, o fracasso repetido que precede o domínio de um desafio é um paradigma comumente aceito em jogos, servindo para estimular o desejo de vencer do jogador contra o sistema, nesse caso, o jogo.

O jogo é uma forma dinâmica de interação, que pode levar a uma variedade de sensações em um curto espaço de tempo. O objetivo da GUR é encontrar maneiras de avaliar a experiência do jogador ao longo do tempo e com uma quantidade razoável de precisão. Segundo Nacke et al. [108], existem alguns métodos usados para obter a experiência individual do jogador:

Entrevistas, Observação e questionários - Pesquisas para avaliar a percepção do jogador sobre as várias dimensões da experiência de jogo.

Biometria - Medidas controladas de experiência de jogo com o uso de sensores biométricos para avaliar as reações do usuário.

Rastreamento de faces - Medição que permite detectar e reconhecer emoções básicas por intermédio de câmeras.

Rastreamento ocular - Medição da fixação do olho e o foco da atenção para inferir detalhes dos processos cognitivos.

Métricas do jogo - Registro de cada ação que o jogador realiza durante o jogo para análise posterior.

Modelagem de jogadores - Modelos baseados em IA que reagem ao comportamento do jogador e adaptam conforme as suas reações.

A avaliação da experiência do jogador por meio do questionário pós-sessão, observação ou entrevistas são as abordagens mais fáceis e menos onerosas financeiramente, entretanto existem algumas desvantagens [108]:

- Por depender da memória do jogador, as informações podem ser perdidas no intervalo entre a ação (jogabilidade) e a lembrança (entrevista ou questionário);
- Em sessões de jogos longas, não existe a garantia de que o jogador se lembre de todas as ações relevantes;
- Esses mecanismos sofrem com as limitações no processo de coleta de dados, como a dificuldade em relatar o comportamento do jogador em momentos específicos do jogo, ou a inibição de experiências reais de jogo. Neste caso, os jogadores podem não se sentir confortáveis quando alguém está assistindo-os ou questionando-os.

O uso de métodos capazes de detectar as emoções e ações dos jogadores em tempo real permite que o pesquisador capture um conjunto mais rico de informações, porém essas técnicas exigem mais trabalho, experiência e geralmente são mais onerosas financeiramente. Por esse motivo, a GUR frequentemente depende de métodos híbridos que combinam dados de pesquisas ou entrevistas autorrelatadas com medidas psicofisiológicas. Essa abordagem combinada possibilita ao pesquisador equilibrar as vantagens e desvantagens de cada método para obter um resultado claro e robusto.

Dos métodos comumente usados em GUR, as medidas psicofisiológicas são a inovação mais recente. Questionários, entrevistas e observação são técnicas usadas no GUR baseadas nos estudos da psicologia e fatores de IHC, enquanto as métricas de jogos se baseiam em registros de ações (*logging*) do jogo. Medidas psicofisiológicas somente foram utilizadas na avaliação na última década [86], o que significa que muitas das inovações foram relativamente recentes. Devido ao vasto conteúdo sobre medidas psicofisiológicas e ao escopo desse trabalho, apresentamos os conceitos de biometria e de emoções em jogos que ajudam no entendimento do processo de avaliação da experiência do jogador realizado nesse trabalho. Na próxima seção, serão abordados tópicos relacionados com as métricas de jogos.

2.3.1 Métricas de Jogos

Mellon [97] categorizou as métricas de jogos (conhecida na literatura como *game metrics*) em três classes principais, a saber:

Métricas de Usuário rotulada na literatura como *User Metrics* ou *Player Metrics* são métricas relacionadas aos usuários que utilizam jogos, tendo duas perspectivas, uma

como **cliente**, que abrange as receitas geradas pelo jogo e a outra como **jogador**, que se restringe particularmente à interação com jogo. A primeira perspectiva é usada quando se pretende calcular métricas relacionadas à receita do jogo, por exemplo, a receita média por usuário (conhecida como *average revenue per user (ARPU)*), usuários ativos por dia (*daily active users (DAU)*), análises de transações financeiras entre outras. A segunda perspectiva é usada para investigar como as pessoas interagem com jogo, seus componentes e outros jogadores, isto é, analisar o comportamento do sistema formado pelo jogo-usuário. Como exemplos de métricas, podemos citar o tempo total de jogo dispendido pelo jogador (*total player time per player*) e a quantidade de perdas por jogador (*damage dealt per player*). No escopo da análise, pode-se incluir ainda a trajetória do jogador e interação com redes sociais (*social networks analysis*) entre outras. Vale atentar que os dados usados para essa métrica são originados da telemetria, notavelmente a partir da instalação de um *game client* ou derivado de arquivo de um *log*, por exemplo;

Métricas de Desempenho Essas métricas são relacionadas ao desempenho da infraestrutura técnica por trás do jogo, especialmente relevante para jogos online. As métricas de desempenho mais comum são a taxa de quadros exibidos por segundo (*frames per second*) de um jogo que executa na plataforma do usuário e, em outros casos, aspectos relativos ao servidor, como estabilidade, latência e ainda medidas do número de erros de codificação encontradas (*bugs*) no jogo (por hora, dia, semana ou em outra linha de tempo). Tais indicadores são amplamente usados no controle de qualidade, (*Quality Assurance*) de forma a monitorar o processo de desenvolvimento do jogo;

Métrica de Processo Essas métricas estão relacionadas ao processo de desenvolvimento de jogos (*Game development*), de tal modo que seria algo similar às áreas de desenvolvimento de sistemas no contexto da TI, como, por exemplo, utilização de metodologias ágeis.

Para o presente trabalho, as métricas que são objeto de estudo são as **métricas de usuário**, que serão abordadas com mais detalhes a seguir.

Métricas de Usuário

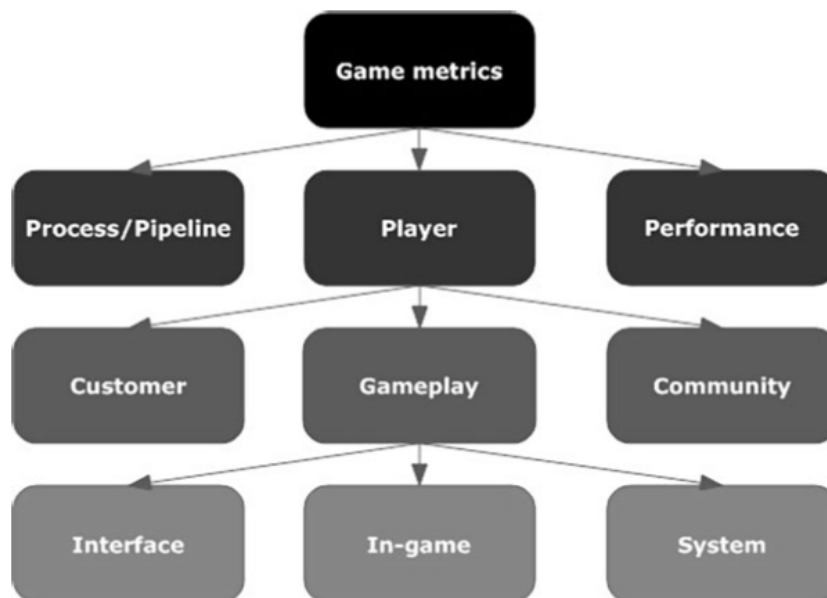
Métricas de usuários é uma fonte comum de *business intelligence* em vários setores, inclusive para o segmento da pesquisa em jogos. A maioria do conhecimento publicado nos últimos 10 anos sobre *game analytics* é baseado sobre métricas de usuário, especialmente na telemetria de dados comportamentais do jogador [42]. Isso é decorrente do fato de os

jogos serem produtos que se concentram em proporcionar uma boa experiência ao usuário [104]. Assim, justifica-se essa atenção especial dessa métrica nessa seção.

Uma característica chave dos jogos digitais é que eles são máquinas de estados, quer dizer, significa que, durante o jogo, um usuário cria ações e respostas que resultam em alterações no estado do jogo [125]. O jogo envolve o usuário por meio de diversos passos, mantendo-o envolvido ao longo de um período de tempo, assim, implicando geração de dados relacionados ao comportamento do usuário e do jogo (mais do que aplicações comuns), proporcionando aquisição de dados na escala de *terabytes* facilmente acumulada em breve período de tempo [157].

As métricas de usuário derivadas a partir de jogos têm sido classificadas por suas aplicabilidades dentro dos jogos considerando três níveis de aplicabilidade: *generic metrics* que são aplicadas em todos os jogos digitais (*playtime* total por jogador ou número de sessões iniciadas); *genre specific metrics* que são aplicadas em gêneros específicos, como, por exemplo, *Role-Playing Games (RPG)* (medir progresso do personagem, número de missões completadas entre outras) e *game specific metrics*, que são específicos para jogos, tal qual medir as características únicas, como a média de mortes da tarântulas brancas no jogo *Tomb Raider: Underworld* [98]. Este sistema de classificação é útil, entretanto, para fins de pesquisa e para uma visão orientada ao desenvolvimento, há outra classificação a qual esse trabalho irá adotar (Figura 2.1), focando-se exclusivamente em *Gameplay Metrics*, que será detalhada na próxima seção.

Figura 2.1: Hierarquia das Métricas de jogo.



Fonte: El-Nasr et al. [42].

Gameplay Metrics

Esta subcategoria de métrica de usuário talvez seja a mais utilizada na indústria de jogos. *Gameplay metrics* são medidas do comportamento do *player* no jogo, tal qual a navegação, o uso de itens e de habilidades, os saltos, a compra de item, isto é, tudo o que os jogadores realmente fazem dentro do ambiente virtual de um jogo. Dessa forma, *gameplay 0 metrics* são particularmente úteis para a *Game User Research* e ao *game design*, pois fornecem a oportunidade de abordar questões-chave como “se as áreas ou cenários do jogo estão subutilizadas”, “se os jogadores usam as características do jogo como pretendido pelo game design”, ou “se há quaisquer barreiras que dificultam a progressão do jogador” [63][32]. Esse tipo de métrica pode ser registrada durante todas as fases do desenvolvimento do jogo.

Como *player*, os usuários podem gerar centenas de medidas comportamentais ao longo de uma sessão de apenas um jogo. Assim, medidas das atividades do *player* podem incluir milhares de ações que podem ser mensuradas por tempo (segundos, minutos, horas ou dias). Considerando o exemplo do jogo *World of Warcraft* [16], medidas do usuário podem envolver registro da localização (nesse caso o personagem do mundo virtual), *health*, *stamina*, suas ações (correr, pular e outras), seu modo (combate, explorador entre outros), equipamento, nível, entre tantas outras. Todos esses pedaços de informações são transmitidos do cliente para base de dados do servidor.

A partir de uma perspectiva prática, pode ser útil subdividir *gameplay metrics* dentro das seguintes categorias [42]:

In-game: converge em todas as ações internas ao jogo e comportamento do jogador, incluindo navegação, interação com ativos do jogo (arma, armadura, roupas e outras entidades). Na maioria das pesquisas e trabalhos sobre *game analytics*, os dados analisados pertencem a essa categoria;

Interface: inclui todas as interações do usuário com interface do jogo (*game interface*) e menus. Isto inclui variáveis de configuração do jogo, tais como sensibilidade do mouse, brilho do monitor e outras;

System: métricas de sistema que convergem em ações da *game engines* e seus subsistemas (sistema de inteligência artificial, ações *non-player character* e etc.) que respondem as ações realizadas pelo jogador. Por exemplo, progressão do jogador ao próximo nível após satisfazer um conjunto de pré-condições.

2.3.2 Biometria

Embora as métricas do jogo (por exemplo, tarefas realizadas, inimigos mortos ou número de moedas capturadas) forneçam muitos dados úteis para avaliar o comportamento do jogador dentro do mundo virtual, elas não dizem muito sobre as emoções vividas por um jogador durante o jogo.

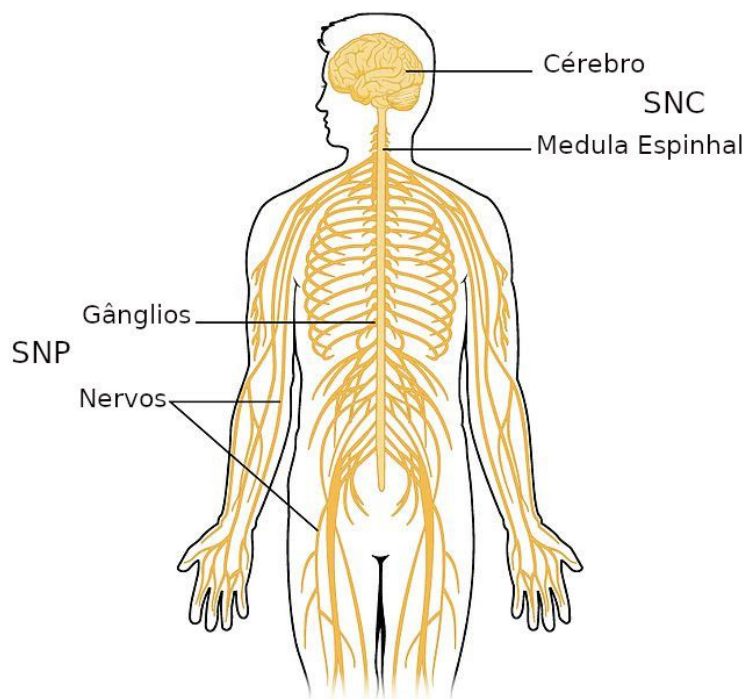
As alterações do comportamento do jogador podem ser observadas por meio dos sinais emocionais derivados das expressões faciais, da postura corporal e das mudanças fisiológicas no corpo do jogador. Expressões faciais e posturas podem ser gravadas com equipamento de vídeo, enquanto muitos dados biométricos requerem gravação por meio de dispositivos diferentes do olho humano, como sensores. As métricas fisiológicas consistem em dados que representam os sinais que o nosso corpo produz quando está em diversos estados de excitação e mental. Com os equipamentos adequados, é possível medir diversos fenômenos, entre eles a condutância da pele. Os métodos incluem eletroencefalografia (EEG), eletromiografia (EMG), EDA (atividade eletrodérmica), entre outros. A próxima subseção apresenta alguns conceitos sobre sinais fisiológicos e as demais subseções detalharão os principais métodos de coleta de dados fisiológicos utilizados nesse trabalho.

2.3.3 Sinais Fisiológicos

Os sinais fisiológicos são pequenas medidas de energia coletadas da superfície do corpo, embora possam ser medidas de processos corporais mais internos, como frequência cardíaca ou atividade cerebral [103]. Conforme Betts et al. [12], em um nível macro, as operações do corpo são controladas pelo sistema nervoso, o qual pode ser anatomicamente dividido em dois elementos, Sistema Nervoso Central (SNC) e o Sistema Nervoso Periférico (SNP), como visto na Figura 2.2.

O SNC gerencia todos os dados sensoriais do corpo. Este é composto pelo cérebro e pela medula espinhal. Sendo extremamente delicado, esse sistema é protegido pelo crânio e pelos ossos da coluna. O SNP, por sua vez, inclui todos os nervos fora do SNC e tem a função de coletar informações sensoriais e transmiti-las ao cérebro por meio do SNC. As terminações nervosas que compreendem o SNP são amplamente encontradas na pele do corpo, o que expõe os sinais do SNP a medições relativamente fáceis. O próprio SNP é subdividido em Sistema Nervoso Somático (SNS) e Sistema Nervoso Autônomo (SNA) [12]. O primeiro regula a atividade corporal que está sob controle consciente, enquanto o SNA controla as respostas inconscientes (incluindo os reflexos). O SNA tem dois atores distintos: o sistema nervoso simpático, que prepara o organismo para reagir a situações emergenciais, como medo, stress e excitação, e o sistema nervoso parassimpático, que regula o relaxamento, o repouso e a digestão.

Figura 2.2: Sistema Nervoso Humano (Figura Editada).



Fonte: Betts et al. [12].

Nas próximas subseções, será descrita uma série de medidas fisiológicas do SNA relevantes para as avaliações de Player Experience (PX) e que fazem parte do escopo desta pesquisa. Todas as medidas apresentadas serão acompanhadas pela sua importância no contexto do GUR, a forma como é medida e outras considerações especiais para seu uso no contexto da avaliação do jogador.

Sensor de Atividade Eletrodérmica (EDA)

O sensor de atividade eletrodérmica (conhecido na literatura como *Electrodermal Activity Sensor* - EDA) mede as variações das características elétricas da pele, usualmente relacionadas com algum tipo de reação parassimpática, indicando uma mudança no nível de excitação. Ela é uma das medidas mais comuns nas pesquisas de usuários de jogos [17].

No contexto de jogos, EDA é usado para identificar a variação do excitação causado por algum evento durante a sessão de jogo (*play session*) [89]. Ainda, diferentes tipos de pele podem gerar características eletrodérmicas distintas [5], entretanto os estudos como Tan et al. [138] apontam que EDA é um recurso de fácil implantação e corresponde bem as dimensões emocionais de excitação. Conforme Lang [75], EDA está fortemente correlacionado à excitação e reflete tanto em respostas emocionais quanto em atividades cognitivas. Além disso, ele tem sido usado extensivamente como um indicador de estresse e é considerado o recurso mais sensível usado na detecção de mentira [18].

O EDA pode ser dividido em dois componentes: tônico e fásico. O componente tônico é o nível de base da condutância da pele (*Skin Conductance Level* - SCL), cuja tendência difere de pessoa para pessoa e depende do estado fisiológico do paciente e da regulação autonômica. Além disso, o SCL descreve a atividade tônica que varia lentamente e as variações desse componente são da ordem de minutos [8]. Enquanto o segundo componente conhecido como Resposta da Condutância da Pele (*Skin Conductance Responses* - SCR) caracteriza a atividade fásica de variação rápida que pode refletir uma resposta específica ao estímulo ou um evento externo [8]. A comunidade científica aceitou considerar o EDA como um indicador indireto do sistema nervoso simpático.

Com relação ao sensor responsável pela captura de dados, normalmente este é composto de eletrodos que detectam alterações na condutividade da pele, exigindo alguns fios e plugues na mão do usuário (Figura 2.3b). Para o presente projeto, utilizamos Empatica E4 *wristband* (Figura 2.3c) que é um novo sensor fisiológico com tecnologia avançada que pode ser usado no pulso do usuário, como um relógio. Em outro momento do projeto, foi usado *kit* BITalino (Figura 2.3a) por ser uma plataforma de baixo custo, entretanto foram detectadas algumas limitações durante seu uso, que fizeram com que os envolvidos da pesquisa optassem pelo Empatica E4. Mais detalhes sobre tais limitações podem ser encontradas na seção 6.2.


Eletromiografia (EMG)

Eletromiografia (conhecido como *Electromiography*) é um processo de monitoramento de sinais elétricos gerados pelas membranas excitáveis das células musculares [2]. O sinal é gerado quando os músculos flexionam ou relaxam e são detectados pelos eletrodos colocados na pele do usuário (Figura 2.4a). Ressalta-se que os eletrodos colocados corretamente possibilitam identificar o movimento do corpo decorrente de um músculo específico. A Figura 2.4c apresenta um exemplo da disposição dos eletrodos nos músculos da face que são usados para detectar emoções. Para obter uma medida completa de certa região do corpo, os eletrodos são colocados e cada um é responsável por coletar os sinais elétricos gerados a partir de um músculo da região (Figura 2.4b). Pela captura desses sinais, torna-se possível realizar a análise do movimento de uma parte do corpo específico.

Na área da saúde, o EMG é amplamente usado no tratamento de reabilitação, podendo ser usado para analisar a progressão do paciente e a resposta durante as sessões de exercício [26][134]. Na indústria de jogos, o EMG está sendo usado como um tipo de *input* de jogos, de modo a controlar o movimento do personagem [115] e também como maneira de adquirir informações sobre a valência emocional do usuário (reações positivas e negativas) durante certos momentos do jogo. Entretanto, dependendo do usuário, é possível que os eletrodos posicionados na face causem certo desconforto durante a sessão de jogo

Figura 2.3: Uso geral do Sensor EDA

- (a) Sensor EDA do BITalino Revolution. (b) Disposição do sensor no usuário.



Fonte: [122].



Fonte: [100].

- (c) E4 wristband.



Fonte: Empatica [58].

[109]. Outra desvantagem para o contexto da pesquisa de jogos é o perigo de introduzir uma quantidade elevada de ruídos associada aos movimentos musculares de risos, fala e mastigação. Ao trabalhar com dados derivados do EMG, é necessário preparar os dados para interpretação por meio de uma normalização usando log ou um *Butterworth low-pass filter* [103].


Medidas Cardiovasculares

Existem diversas medidas cardiovasculares disponíveis para avaliação fisiológica e todas elas se relacionam com a frequência cardíaca, suas alterações e como isso influencia o estado fisiológico humano. As medidas mais comuns são:

- Eletrocardiografia (do inglês *Electrocardiogram* - ECG)
- Frequência Cardíaca (do inglês *Heart Rate* - HR)
- Intervalo entre batimentos (do inglês *Interbeat Interval* - IBI)


Figura 2.4: Uso geral do Sensor EMG

(a) Sensor EMG do BITalino Revolution.



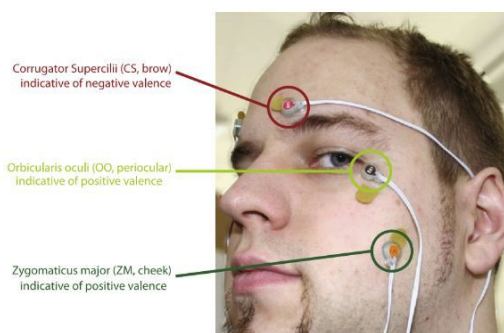
Fonte: [123].

(b) Típico dados brutos obtidos do EMG.



Fonte: [123].

(c) Exemplo do uso do sensor EMG na face.



Fonte: Nacke et al. [109].

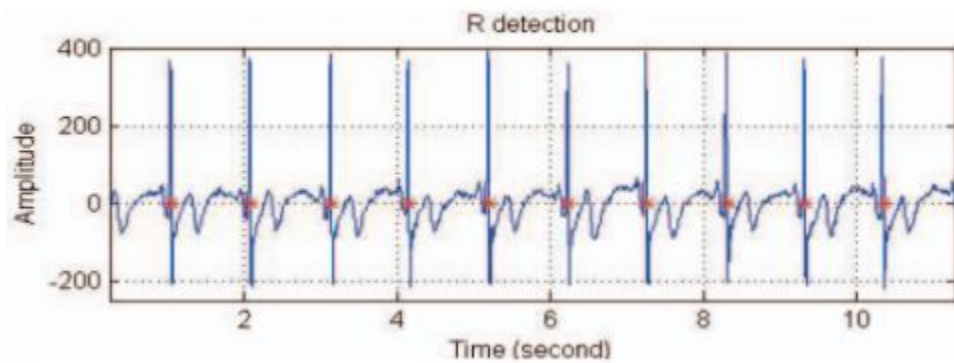
- Variação da Frequência Cardíaca (do inglês *Heart Rate Variability* - HRV)
- Fluxo de Volume Sanguíneo (do inglês *Blood Volume Pulse* - BVP)

O ECG é a análise do registro gráfico das oscilações elétricas relacionadas com a atividade do coração (Figura 2.5)[47]. Este recurso possibilita diversas maneiras de analisar a resposta cardíaca aos estímulos.

A atividade elétrica do coração é obtida a partir dos eletrodos colocados sobre peito do usuário. O padrão de dados coletados é projetado em um gráfico, representando pulsos elétricos do coração durante uma sessão. Cada pico e vale representam pulsos diferentes da rotina de batimento cardíaco (Figura 2.6)[57].

A partir do ECG, existem muitos indicadores de excitação ou tédio que podem ser obtidos a partir da frequência cardíaca e da amplitude da onda. No entanto, é possível extrair mais informações, aplicando algum processamento de sinal no resultado gerado. A intensidade das atividades simpáticas e parassimpáticas, por exemplo, pode ser derivada conforme as ondas emitidas pelo ECG [136]. No contexto da telemetria de jogos, ECG é considerado um **sensor invasivo** devido aos eletrodos estarem localizados no peito do

Figura 2.5: Gráfico do ECG.



Fonte: Subahni et al.[136].

usuário. Dessa forma, ele pode interferir na experiência de jogo durante o processo de aquisição de dados [133]. Outra desvantagem é que os sinais gerados exigem alguma manipulação antes de iniciar a análise propriamente dita, impondo, assim, algumas limitações nos experimentos que exigem resposta em tempo real.


Uma medida cardíaca relevante no contexto da avaliação de jogos é o Heart Rate (HR), que indica o número de contrações feitas pelo coração a cada minuto e é afetada pela idade, postura, nível de condicionamento físico e frequência respiratória [135]. O HR tem sido usado para diferenciar emoções positivas e negativas e para diferenciar entre raiva e medo [20]. Existe outra medida que pode ser extraída usando os sinais cardíacos, o Heart Rate Variability (HRV), que é a oscilação entre os batimentos cardíacos consecutivos e é um sinal biométrico interessante para avaliação da experiência do jogador [86]. No presente trabalho, usamos o Blood Volume Pulse (BVP), que é a mudança física no volume sanguíneo a cada batimento cardíaco, para obter HR e HRV através do Interbeat Interval (IBI) por meio do Empatica E4 *wristband*.

Eletroencefalografia (EEG)

A Eletroencefalografia é um procedimento que registra as atividades elétricas do cérebro [111]. Vários eletrodos são colocados sobre couro cabeludo do usuário, os quais detectam variações da voltagem elétrica gerada pelos neurônios do cérebro. Cada grupo de eletrodos é responsável por medir os sinais oriundos de diferentes regiões do cérebro, tal como controle de movimento, emoção ou memória. Usualmente, os sensores EEG são acoplados a um boné, que é colocado na cabeça do usuário. Os dados são coletados e mapeados para representar diferentes setores do cérebro (Figura 2.7)

O principal uso do EEG em jogos é na área da *Affective Gaming* de modo a obter uma estimativa do estado afetivo do usuário baseado nas atividades cerebrais [109][92] e

Figura 2.6: Forma de onda ECG.



Fonte: Hurst [57].

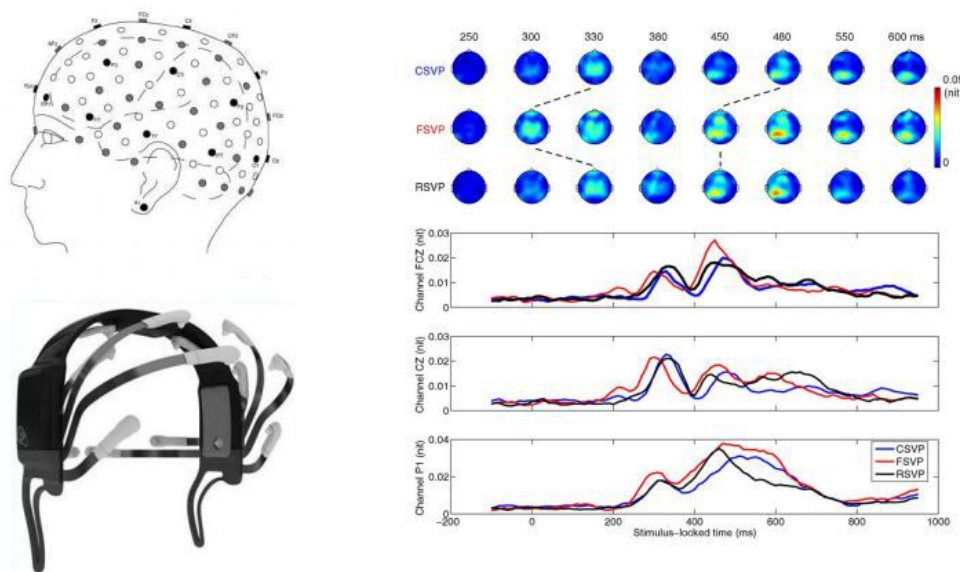
também como *input*, servindo como controle (*game controller*) [80].

O ECG é um sensor muito útil para análise dados de jogos, podendo fornecer uma visão sobre diferentes aspectos, como excitação do comportamento humano, por exemplo. Entretanto, é um equipamento com custo elevado e sujeito a uma elevada quantidade de ruídos. Existem relativamente poucos trabalhos que utilizam esse sensor nesse contexto devido a essa adversidade, pois seu nível de sensibilidade é relativamente alto no que diz respeito à captura dos sinais elétricos gerados por neurônios [5].

Rastreamento Ocular

Existem várias outras medidas biométricas que podem ser de interesse para avaliar a experiência do jogador com jogos digitais, como o rastreamento ocular (do inglês *Gaze Tracking* ou *Eye Tracking*), que é usado isoladamente ou em combinação com outras medidas [36]. O rastreamento ocular pode ser aplicado como uma ferramenta para estudar os movimentos dos olhos. Há muitas áreas de execução para o uso do rastreamento ocular, como a psicologia, neurociência e a interação humano-computador. Os dispositivos de rastreamento ocular eram intrusivos e complicados de se usar no início, mas os avanços recentes na tecnologia de rastreamento ocular tornaram possível usá-los sem esforço, sem distrair os usuários. Embora as soluções de baixo custo tenham surgido, sistemas de rastreamento ocular mais robustos e precisos ainda são muito caros. No entanto, mesmo com a tecnologia de hoje, o processo de rastreamento ocular ainda possui limitações que afetam

Figura 2.7: Esquema do sensor EEG.



Fonte: Ambinder [5].

a precisão [54]. Alguns desses problemas estão relacionados ao processo de calibração, a capacidade de rastrear diferentes usuários, o fato de o olho nunca estar completamente parado e a extração e interpretação dos movimentos oculares. Além disso, essa medida biométrica possui outras desvantagens retratadas pela alteração da luminância da tela, cor e padrões espaciais, acarretando alguns ruídos.

Quando um rastreador ocular é usado para estudar o comportamento do jogador durante interação com jogo, os dados de saída são essencialmente uma sequência de pontos de olhar definidos por uma posição 2D na tela de exibição junto a marcação de tempo [137]. Com essas informações, é possível estabelecer onde o olhar foi implantado no espaço da tela ao longo do tempo. Uma representação útil dos dados derivados do rastreamento são as distribuições de densidade do ponto do olhar, que podem quantificar a quantidade de atenção em cada região na tela (Figura 2.8)

2.4 Emoções em Jogos

Alguns dos momentos mais memoráveis em jogos, como algum susto repentino, algum objeto raríssimo conquistado ou derrotar o inimigo mais poderoso do jogo causam forte impacto emocional no jogador. É natural que *game designers* e especialistas em jogos estejam procurando métodos para entender melhor a variação desses estados emocionais que o jogador apresenta durante o jogo. Enquanto *game metrics* fornecem medidas para inferir o comportamento da interação do jogador com o mundo virtual, estas não podem mostrar os sinais das emoções do jogador. Estes indícios emocionais são mudanças obser-

Figura 2.8: Um exemplo de mapa de calor de um participante durante interação com jogo por 15 segundos.



Fonte: Sundstedt et al. [137].

váveis no estado do jogador (humano), tais como expressões faciais, postura do corpo ou alterações fisiológicas no corpo do jogador. Assim, existem técnicas que utilizam recursos tecnológicos capazes de avaliar esses sinais, de modo a apresentar qual emoção o jogador demonstra durante certos momentos do jogo.

Esta seção abordará conceitos básicos de emoção e discute alguns tópicos em torno do processo de avaliação desta, enfatizando os teorias, as técnicas e as limitações.

2.4.1 O que é Emoção

O termo **emoção** está associado a um componente genérico de estados afetivos, na qual é expressada de forma voluntária ou involuntária [65]. Apesar de não se encontrar uma taxonomia precisa para emoções, estas podem ser classificadas de diversas maneiras diferentes. Além disso, existe uma diferença clara na literatura sobre emoção e o sentimento. A primeira é uma reação imediata a um estímulo, é algo que altera o comportamento, mas não envolve pensamento, enquanto o segundo envolve um alto grau de componente cognitivo, de percepção e de avaliação de algo.

Uma delas é usando a teoria das emoções de *James-Lange*, em que os estímulos produzem mudanças corporais (como palpitações, falta de ar, angústia, etc) que, por sua vez,

geram emoções. Portanto, essa teoria sugere que os estímulos estão primeiramente vinculados às respostas físicas, que somente depois serão interpretadas como emoção [64][76].

A segunda teoria é *Cannon-Bard* [21] (primeira a desafiar a teoria de *James-Lange*), em que um estímulo é recebido pelo córtex, reconhecido como produtor de emoção e enviado para ativar os centros encefálicos mais baixos, no hipotálamo e no sistema límbico. Dessa maneira, desta região do encéfalo, os sinais são enviados simultaneamente aos músculos externos e órgãos internos e retornam ao córtex. Os músculos e órgãos fazem as reações fisiológicas para a emoção, enquanto o córtex percebe o sinal como emoção. Em resumo, a teoria propõe que as reações fisiológicas e psicológicas ocorrem ao mesmo tempo.

Outro conceito sobre emoção é a teoria dos dois fatores por *Stanley Schachter* e *Jerome Singer* [128], na qual a emoção tem dois componentes: excitação física e o rótulo cognitivo. Eles perceberam que um estado de agitação pode ser interpretado como uma determinada emoção, dependendo da maneira que ela foi detectada. Desta forma, considera-se que o processamento mental possui uma grande influência sobre a nossa interpretação individual das reações de nosso corpo a um evento que as causou. Ainda, os processos cognitivos fornecem a estrutura na qual os sentimentos individuais são processados e rotulados, dando ao estado de excitação fisiológica valores positivos ou negativos, de acordo com a situação e as experiências passadas [127].

Para resumir, a maioria das teorias de emoção possuem dois conceitos básicos: (1) estados emocionais discretos e (2) teorias dimensionais. Os estados emocionais discretos remontam às ideias iniciais do filósofo francês *René Descartes* [81], que descreveu as emoções básicas, tais como alegria, admiração, amor, desejo, ódio e tristeza. Posteriormente, *Ekman* [37] descreveu a aparência da face em seis emoções distintas: raiva, desgosto, medo, felicidade, tristeza e surpresa (Figura 2.9). Uma lista que ele estendeu mais tarde e que pode ser vista em [38][39].


Outro estudo notável sobre os estados de emoções discretas é o realizado por *Plutchik* [119], que descreve modelo estrutural de emoções em oito emoções básicas, mais oito avançadas e que resultam em oito sentimentos (Figura 2.10)

A próxima seção apresenta as técnicas e os procedimentos sobre como medir a emoção, bem como os principais trabalhos na literatura.

2.4.2 Avaliação da Emoção

Os aspectos emocionais têm sido mensurados mediante questionários (*self-reports*), existindo de fato um vasto número de ferramentas para esse propósito. Dois importantes questionários são *PANAS-X* (*Positive Affect Negative Affect Scale*) [155] e *SAM* (*Self-Assessment Manikin*) [19]. O *PANAS-X* é uma evolução do questionário *PANAS* [154] que é composto de adjetivos que detalham cada sentimento. Cada palavra deste questio-

Figura 2.9: Seis expressões faciais das emoções de Paul Ekman.




Fonte: Retirada de http://www.frontiersin.org/files/Articles/145042/fpsyg-06-00761-HTML/image_m/fpsyg-06-00761-g001.jpg

nário é então classificada conforme o sentimento correspondente, em uma escala de 1 a 5, de acordo com o que entrevistado está sentindo. Dessa forma, o *PANAS-X* é uma versão que mede onze afetos específicos: medo, tristeza, culpa, hostilidade, timidez, fadiga, surpresa, jovialidade, auto-confiança, serenidade e atenção. O *SAM* constitui de três escalas pictóricas e cada uma delas está formada por uma sequência de cinco ou nove desenhos de figuras humanóides, graduadas em intensidade, que representam distintos níveis de valência, ativação (ou excitação) e domínio, que vão a partir de um extremo de máximo desagrado, relaxamento ou de sentir-se dominado, até outro extremo de máximo agrado, de excitação/ativação ou de sentir-se dominado [19].

Outra abordagem é a Roda das Emoções de Genebra (*Geneva Emotion Wheel*) [130], que tem o objetivo de medir as reações emocionais a objetos, a situações e a eventos. As emoções são representadas como um conjunto de círculos com circunferência crescente (Figura 2.11). O objetivo da Roda das Emoções é: 1 - checar a pertinência de modo a situar as categorias de emoção em um ambiente de duas dimensões subjacentes de


Figura 2.10: Mapa das emoções por *Plutchik*



Fonte: Retirada de <https://commons.wikimedia.org/wiki/File:Plutchik-wheel.svg>

controle e valência; 2 - verificar se os adjetivos se encaixam nas categorias postuladas; 3 - checar o postulado da crescente intensidade para os quatro adjetivos em cada categoria.

Figura 2.11: Roda das Emoções de Geneva



Fonte: Retirado de <https://bambusekd.files.wordpress.com/2014/03/gew2.png>

Partindo para outra perspectiva de avaliação de emoções, temos os processos automatizados, os quais exigem avaliar todos os componentes de processamento humano, incluindo a representação mental subjetiva do sentimento. Como isso é algo improvável de ser alcançado, não há outra maneira de se saber o estado emocional de uma pessoa do que pedir ao indivíduo para relatar a natureza de seus sentimentos [130]. No entanto, é possível inferir o estado emocional a partir das apresentações corporais dos padrões das respostas fisiológicas e dos comportamentos expressivos que acompanham a experiência das emoções [130], utilizando como base os padrões das expressões faciais e vocais [94], comumente acessados por meio de dispositivos de gravação (como áudio e vídeo) ou atividade muscular (eletromiografia) [102].

As expressões vocais são medidas em termos de amplitude de som (*loudness*) e frequência (*tom*, do inglês *pitch*). A excitação e a frequência estão diretamente associados, de tal forma que as emoções com níveis superiores de excitação (medo, alegria e raiva) estão ligadas às amostras vocais mais agudas [94]. Entretanto, não existe uma relação da amplitude ou frequência com a valência e, portanto, é muito difícil diferenciar as emoções que estão mais próximas na excitação, no entanto afastadas da valência, como a raiva da alegria, apenas utilizando a expressão vocal [94].

As expressões faciais são mensuradas em termos de ativação dos músculos esqueléticos ou inspeção visual do movimento de características permanentes (olhos, sobrancelhas e lábios) e as alterações de textura em características transitórias (linhas e rugas) [102][11]. Conforme Mauss e Michael [94], acredita-se que as expressões faciais são as mais intimamente ligadas ao comportamento do organismo e que as seis emoções básicas (felicidade, raiva, tristeza, medo, desgosto e surpresa) são universais (existem algumas diferenças culturais a serem consideradas) [41]. A região da boca e dos olhos e, de maior importância, as sobrancelhas e os cantos da boca, são os componentes faciais mais relevantes para mensurar a expressão das emoções [94], sendo possível indicar, de forma confiável, a valência do estado emocional de uma pessoa, a fim de a fornecer uma boa precisão sobre a inferência do estado emocional [11].

Há muitos trabalhos de pesquisa sobre avaliação de emoções. Um deles é o feito por Tan et al. [139], em que os autores investigaram as expressões faciais durante a interação entre jogo e o jogador, e se essas expressões podem ser capturadas para ajudar a avaliar os estados emocionais dos jogadores. Foram realizados testes com voluntários submetendo-os a dois jogos comerciais. Os pesquisadores rastrearam as faces em gravações de vídeos usando um algoritmo de ajuste de um modelo deformável (*deformable model fitting - DMF*) e classificaram as emoções utilizando uma rede neural artificial. Após os voluntários jogarem os dois jogos, foram submetidos a um questionário (*Game Experience Questionnaire*) e entrevistados de modo a responderem as perguntas com o intuito de

verificar se a câmera ou outros aspectos do experimento estavam afetando sua interação com jogo. As cenas divertidas (ou cômicas) tiveram uma precisão elevada com relação à emoção de felicidade, e o sentimento de raiva também aumentou ao longo do tempo em função da frustração sobre as atividades de quebra-cabeça. Ainda, os participantes não foram instruídos sobre como se comportar na frente da câmera, de tal modo que houve falhas no rastreamento da face e no processo de detecção de emoção por conta de eventuais movimentos da cabeça e obstrução com a mão em certos momentos de interação com jogo.

O trabalho feito por Kobayashi e Hara [70] realiza reconhecimento de emoções humanas pela classificação (utilizando redes neurais) das expressões faciais. Os autores usaram as seis expressões básicas de emoção (citadas em [41]) como categorias de expressões emocionais. A rede neural (classificador) utilizou algoritmo *back propagation* e foi treinada empregando imagens coletadas de participantes que tiveram suas expressões faciais gravadas (principais pontos rastreados foram sobrancelhas, olhos e boca) para realizar a identificação das emoções básicas ditas anteriormente.

A pesquisa feita por Oliveira e Jaques [112] apresenta um sistema que infere emoções básicas por meio de imagens de faces capturadas pela *webcam*. Esse método submete medidas antropomórficas a um conjunto de regras, que define a ocorrência de códigos FACS ¹(*Facial Action Coding System*), os quais servem de entrada para a árvore de decisão que executa a inferência de emoções. De início, o sistema obtém um grupo de imagens (640x480 pixels de resolução) e utiliza um classificador *Haar-like features* [148] para detecção de faces. As imagens contendo a face são isoladas e, com base em um modelo que possui um conjunto de pontos em uma face, são demarcados (manualmente) os pontos coincidentes sobre a imagem da face. Das coordenadas desses pontos demarcados, são obtidos parâmetros que fornecem informações sobre os estados das características faciais. Esses critérios são avaliados por um conjunto de regras que podem fornecer indícios de ocorrência de um ou mais códigos FACS manifestados em uma face. Os códigos FACS obtidos são submetidos a uma árvore de decisão que foi construída para indicar a emoção correspondente. Como resultado, o sistema foi capaz de reconhecer, em média, 60% das emoções, atingindo até 90% de sucesso no reconhecimento das emoções de alegria e tristeza.

¹Modelo psicológico de classificação facial que categoriza em códigos todas as aparências faciais causadas por contrações musculares, representando todas as expressões faciais possíveis, detalhes em [40]

Capítulo 3

Estado da Arte

3.1 Escopo

O objetivo deste capítulo é mapear os principais trabalhos que permeiam esta tese de doutorado. Em particular, a seção 3.2 descreve os estudos que abordam a análise de dados do comportamento do jogador dentro do mundo virtual. A seção 3.3 foca em descrever as pesquisas relacionadas à visualização de dados em jogos. Ao final, a seção 3.4 apresenta os estudos que abordam a compreensão das emoções durante as interações do jogador com jogo, dando ênfase no uso de dados psicofisiológicos.

3.2 Análise de dados de Jogos

Durante os últimos anos, houve um aumento exponencial na disponibilidade de dados em diversos campos da indústria e pesquisa científica, tais como bioinformática, análise de redes sociais, visão computacional e, principalmente, na área de jogos digitais. Além disso, muitos desses dados estão disponíveis para serem manipulados diretamente, entre eles dados de transações de negócios, imagens por satélites e dados de telemetria.

A maioria dos jogos digitais modernos possuem características de sistemas de informação sofisticados. Todavia, para todos, há a necessidade de manter o rastreamento das ações do jogador e processar essas informações. Nos últimos anos, o rastreamento e registro destas informações em termos de telemetria de dados (bem como os dados de desempenho da *game engine*) tornou-se um processo de suma importância na indústria de jogos, levando a uma riqueza de informações detalhadas sobre interação do jogador com jogo [31][68]. Dessa forma, aplicar de forma correta o processo de telemetria de dados em jogos é primordial para que essa técnica torne-se uma poderosa ferramenta para o ciclo de desenvolvimento de jogos [68], pois ela possibilita uma análise detalhada do comportamento do jogador, permitindo descobrir/corrigir problemas no *game design*, sendo um

bom guia nas estratégias relacionadas à tomada de decisão, apoio ao cliente e marketing [42][67].

Diversos trabalhos no campo acadêmico e na indústria têm focado na análise dos dados relativos ao **comportamento** do jogador durante a interação com o jogo, visando obter respostas sobre perguntas fundamentais como: “*As pessoas estão jogando o jogo como foi pretendido pelos game designers ?*” e “*Por que houve um aumento do número de jogadores que abandonaram o jogo?*”, entre outros questionamentos dentro desse contexto.

Surtem informações valiosas durante o processo de telemetria de dados, mas que nem sempre estão disponíveis à primeira vista. Além disso, na maioria dos casos, o volume de dados rastreados e armazenados na base de dados é muito elevado (*Big Data*), não dando subsídios necessários para uma análise minuciosa por meio de consultas simples. Um dos desafios, nesse contexto, é extrair informações relevantes dos dados da telemetria de jogos, o que implica trabalhar com grande massa de dados. Simplesmente reter informações a partir da base de dados (independentemente do campo de aplicação) não é suficiente para uma tomada de decisão adequada. Dessa forma, novos métodos têm se destacado para auxiliar o analista e os tomadores de decisões a obter informações mais precisas, que são necessárias para uma melhor tomada de decisão. Estes procedimentos são referenciados conjuntamente como *data mining* ou mineração de dados, possibilitando uma análise rápida e efetiva, bem como os resultados são apresentados de forma intuitiva e acessível para não especialistas.

Usando esses métodos de mineração de dados no contexto da telemetria em jogos (conhecida na literatura como *game data mining* [42]), podemos realizar as seguintes tarefas:

- Detectar pontos fracos ou problemas no *Game Design* [68] [48];
- Representar como jogadores gastam seu tempo quando jogam [30];
- Explorar como jogadores utilizam e se comportam em um determinado jogo [3];
- Como eles gastam seu tempo jogando [158];
- Predizer quando eles param de jogar [7].

Nas próximas subseções, o enfoque será em mostrar os trabalhos mais atuais e relevantes que utilizam mineração de dados no contexto de jogos digitais e que auxiliaram no desenvolvimento deste trabalho de doutorado.

Automatic player behavior analysis system using trajectory data in a massive multiplayer online game

O trabalho desenvolvido por Kang et al. [66] apresenta um sistema de análise comportamental automatizado usando o método de clusterização dos dados da trajetória do jogador para jogos do gênero *Massive Multiplayer Online Games* (MMOG). A descrição do comportamento do jogador (combate, movimento, ocioso e comportamento social) é uma informação útil no desenvolvimento do MMOG, no entanto o processo de monitoramento e a avaliação do comportamento do jogador possuem alto custo. À vista disso, um dos objetivos do trabalho foi a redução do custo desse processo.

Figura 3.1: Um Screenshot dos dados da trajetória do jogador.

Player ID	B_0	B_1	B_2	B_3	B_{\dots}	Player evaluation
000001	Log-in (12:00)	Monster hunting at zone No. 48 (12:00–13:17)	Moving (13:17–13:30)	Monster hunting at zone No. 45 (13:30–15:00)	Combat-oriented player
000002	Log-in (20:45)	Chatting at zone No. 15 (20:45–21:15)	Log-out (21:15)	Social-oriented player
....
010213	Log-in (15:30)	Gathering at zone No. 21 (15:30–14:15)	Moving (14:15–14:30)	Selling at zone No. 22 (14:30–15:30)	Commerce-oriented player


Fonte: Kang et al. [66].

O sistema utilizou um algoritmo de particionamento com objetivo de classificar os dados e, em seguida, aplicou um algoritmo de clusterização baseado em densidade (*DBSCAN*) para realizar a análise do comportamento do jogador com base nos dados coletados da trajetória realizada (Figura 3.1). O sistema em si foca na definição de *Segment Of Interest* (SOI), que representa o comportamento do jogador baseado na maneira em que a trajetória sua desenvolvida no jogo (Figura 3.2). Os autores consideram que cada percurso inclui detalhes na forma de segmentos com diversas ações, possibilitando uma análise detalhada do comportamento do jogador, enquanto, em uma visão macro, é possível sumarizar um comportamento geral de forma aproximada, agrupando esses segmentos de trajetória.

Guns, Swords and Data: Clustering of Player Behavior in Computer Games in the Wild

O trabalho desenvolvido por Drachen et al.[30] utilizou o jogo de FPS (*First Person Shooter*) chamado *Battlefield 2: Bad Company* (BF2BC2) da empresa *Electronic Arts*.

Figura 3.2: Comportamento baseado no SOI.



Fonte: Kang et al. [66].

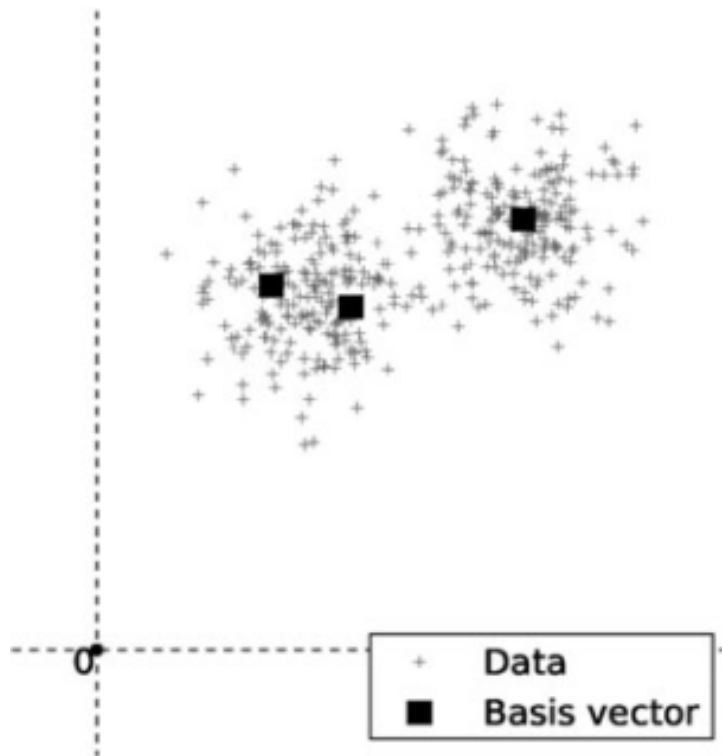
Outro detalhe importante é que, usualmente, o jogo pode ser utilizado de dois modos: *online Multiplayer* e *off-line Single-Player*. No modo *multiplayer*, existem vários tipos de classes (com finalidades diferentes dentro do jogo), as quais jogador pode escolher: *Assault*, *Demolition*, *Specialist*, *Recon* e *Support*. Cada uma delas fornece diferentes equipamentos. Além disso, os jogadores podem ganhar prêmios e níveis conforme seu progresso no jogo.

Os autores usaram telemetria de dados de 10.000 jogadores (todos jogando em PC), coletando dados de 11 variáveis para análise. Ainda nesse trabalho, foi adotado que a análise dos *clusters* do comportamento do jogador deveria focar sobre comportamento relacionado à mecânica central do jogo, selecionando características que envolvem desempenho do jogador (*score*, *skill level*, *accuracy*, *Kill/Death rate*, *Score per minute*, *Deaths per minute/kills per minute* e *rounds played*), uso de ativos do jogo (armas e veículos) e *playtime*.

Seguindo o pré-processamento e normalização de dados, dois algoritmos foram aplicados para estes dados: *K-means*, que produz centróides (Figura 3.3) e *Simplex Volume Maximization* (SIVM) (Figura 3.4), que é uma variante do *Archetype Analysis* para grande volume de dados (Mais detalhes sobre os dois algoritmos podem ser encontrados em [34]). O resultado do primeiro algoritmo identificou os perfis dos jogadores que residem nas regiões densas, enquanto O segundo algoritmo reconhece os perfis que se encontram nas regiões periféricas.

Os dois algoritmos resultaram em 7 *clusters*, contudo os perfis comportamentais extraídos variavam um pouco. Isto era esperado, dadas as diferentes naturezas dos algoritmos. Ambos os algoritmos são úteis e com diferentes propostas quando se trata de análise comportamental em jogos digitais. O *k-means* é útil para obter informações sobre a distribuição geral dos comportamentos na população de um jogo, enquanto SIVM serve para identificar jogadores com comportamentos extremos. O primeiro é particularmente eficiente para verificar o uso de ativos e o balanço do jogo. Por exemplo, quando *k-means* identifica *clusters* de jogadores que não utilizam elementos específicos do jogo, é um indicador de que esses são subutilizados e de que o recurso de desenvolvimento é desperdiçado. Da mesma forma, a identificação de *clusters* de jogadores com baixo desempenho, tipica-

Figura 3.3: Utilização do algoritmo K-means.



Fonte: El-Nasr et al. [42].


mente aqueles que estão em risco de deixar o jogo, assim como a identificação do que está causando o baixo desempenho, podem contribuir a elaborar estratégias para aumentar a permanência desse no jogo. Por outro lado, o SIVM possibilita detectar comportamentos extremos e também ajuda identificar jogadores com características atrativas em torno de uma amostra significativa.

Neste trabalho, os resultados utilizando o SIVM foram mais significativos (devido ao alto grau de diferença entre os grupos), enquanto que, ao utilizar *k-means*, os resultados foram muitos similares (baixo grau de diferenciação). Os perfis comportamentais identificados pelo SIVM foram:

Assassins: caracterizados pela alta taxa de assassinato e taxa de assassinato por minuto, mas com baixo *playtime*. Essa categoria de jogadores são letais no jogo e são altamente especializados.

Veterans: são jogadores de elite em que apresentam altos valores em todas as variáveis comportamentais mensuradas e costumam ter valores altos de *playtime*, indicando que esses jogadores são estáveis. Eles representam uma pequena fração da amostra de jogadores.

Figura 3.4: Utilização do algoritmo SVM.



Fonte: El-Nasr et al. [42].

Target dummies: eles são o oposto dos *Veterans*, com baixos valores nas variáveis comportamentais mensuradas, representando 1/4 da amostra de jogadores. Eles não utilizam jogo por muito tempo, possuem baixa taxa de assassinato e seu *score* por minuto é o menor de todos os perfis encontrados.

Assault-Recon: esses jogadores apresentam alta taxa de assassinatos e mortes (pois eles são linha de frente, tendo alta probabilidade de serem atingidos). Possuem baixa precisão, fato este relacionado ao uso de armas rápidas.

Medic-Engineer: esses jogadores possuem altos níveis de habilidades e precisão, alto *score* (perdendo somente para os *Veterans*) e usam bastante os veículos. Representam uma classe altamente especializada.

Assault "specialist": são jogadores que utilizam a classe *assault* e possuem muito *play-time* de jogo, mas com baixo nível de habilidade, taxa de assassinato e precisão. Eles representam tipicamente jogadores novatos.

Driver Engineers: jogadores que utilizam bastante veículos (quatro vezes mais do que os outros perfis). Por exemplo, eles gastam muito tempo dirigindo, velejando e

pilotando vários tipos de veículos (tanque, carro, avião e lancha). Eles possuem alto *playtime*, *scores* e precisão. Além disso, morrem e matam muito pouco.

Sequential Analysis of Player Behavior

O trabalho feito por Wallner [149] teve como objetivo realizar uma análise sequencial do *log* de dados das ações do jogador por forma a obter um melhor entendimento dos aspectos dinâmicos do comportamento do jogador. Fora disso, ele utilizou o método de mineração de padrões sequenciais baseado em frequências, chamado *Lag Sequential Analysis (LSA)* [44] e, para dar maior confiabilidade nos resultados, incrementou modelos estatísticos que determinam os padrões sequenciais significativos.

Para avaliar a utilidade do LSA no contexto do *game analytics*, o autor aplicou o algoritmo em duas bases de dados distintas: (1) base de dados de um jogo de *Multiplayer Online Battle Arena* (MOBA), cujo nome é *Heroes of Newerth*, para entender como os jogadores realizam o encadeamento das habilidades dos seus personagens; (2) banco de dados de *replays* do *Starcraft 2: Heart of the Swarm* para minerar o processo de construção de artefatos do jogo.


O jogo *Heroes of Newerth* consiste em uma batalha entre duas equipes, cada uma podendo ser formada por no máximo 5 jogadores. Cada integrante pode controlar somente um personagem (*hero*) durante toda sessão. Cada *hero* possui diferentes atributos e quatro distintas habilidades, que podem ser usadas durante a batalha (o jogo oferece venda de habilidades especiais). Ainda, as técnicas podem ser aplicadas em sequência, assim, formando *combo*, com a finalidade de aumentar a eficiência do personagem.

Para análise do primeiro jogo, o autor usou a base de dados do *Game Analytics Workshops*¹ de 2013, que possui dados de eventos de seis diferentes *hero* no total de 40.000 partidas. Foram selecionadas três classes de *hero* (*Thunderbringer*, *Magmus* e *Swiftblade*), para as quais houve eventos correspondentes de ativação de habilidades que foram extraídas da base e ordenados cronologicamente, dessa forma, resultando em um total de 868 sequências para *Thunderbringer*, 690 sequências para *Magmus* e 1547 sequências para *Swiftblade*. Esta análise considera somente habilidades ativas dos personagens e também a habilidade chamada *Taunt* (habilidade vendida e disponível para todos os personagens).

A Figura 3.5 mostra o uso das diferentes habilidades ativas junto com o número total de habilidades usadas para cada um dos três heróis sob investigação. Independentemente do *hero*, a habilidade *Taunt* é raramente usada se comparada com outras habilidades. Isto não é surpresa, uma vez que esta habilidade precisa ser comprada para ser utilizada. Ainda, as Figuras 3.6a, 3.6b e 3.6c apresentam a probabilidade entre duas habilidades

¹<http://www.northeastern.edu/games/game-analytics-workshop-the-grand-data-challenge/>

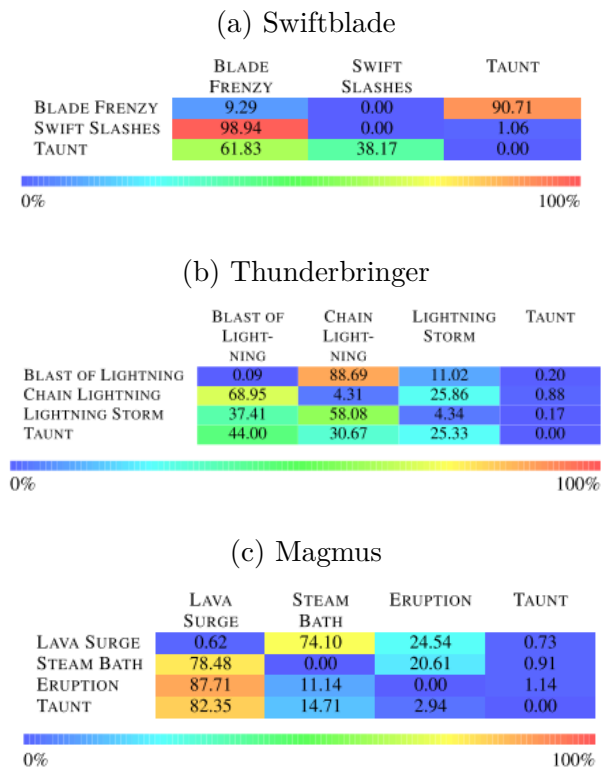
Figura 3.5: Uso de diferentes habilidades (em porcentagem) e contagem geral.



Fonte: Wallner [149].

consecutivas em porcentagem de cada classe. Assim, esses valores fornecem um meio de avaliar a probabilidade de uma habilidade ser usada após outra habilidade.

Figura 3.6: Probabilidade entre duas habilidades consecutivas.



Fonte: Wallner [149].

Por fim, a Figura 3.7 apresenta as sequências significativas identificadas pelo LSA, além de mostrar o z -score das sequências, bem como a frequência da ocorrência e um $rank$. Analisando resumidamente cada resultado com base na classe temos:

- Em *Swiftblade*: em termos de frequência, os jogadores dessa classe usam principalmente *Blade Frenzy* seguida pela habilidade *Swift Slashes* primeiramente. Com a matriz de probabilidade da Figura 3.6a, pode-se prever que o uso da *Blade Frenzy* estará provavelmente acompanhado com *Swift Slashes* durante combo de duas ou três habilidades.
- Em *Magnus*: temos que *Lava Surge* é frequentemente usada e, nesse caso, podemos prever que, ao usar essa habilidade, existe grande chance do jogador usar *Steam Bath* e *Eruption* durante a realização do combo que inicia com *Lava Surge*.
- Em *Thunderbringer*: temos *Chain Lightning* e *Blast Of Lightning* foram as habilidades repetidamente usadas. Novamente, a habilidade *Taunt* foi raramente usada, entretanto, em comparação com as classes anteriores, foi utilizada com mais frequência na referida classe.

Figura 3.7: Os combos encontrados pelo LSA.

sequence	z -score	freq.	rank
Swiftblade			
BLADE FRENZY → TAUNT	$z_1 = 43.45$	205	2
SWIFT SLASHES → BLADE FRENZY	$z_1 = 37.99$	1967	1
TAUNT → SWIFT SLASHES	$z_1 = 29.38$	50	4
TAUNT → SWIFT SLASHES → BLADE FRENZY	$z_2 = 2.93$	9	6
SWIFT SLASHES → BLADE FRENZY → TAUNT	$z_2 = 2.36$	9	6
Magnus			
ERUPTION → LAVA SURGE	$z_1 = 42.19$	307	3
STEAM BATH → LAVA SURGE	$z_1 = 35.78$	259	4
LAVA SURGE → STEAM BATH	$z_1 = 34.62$	2850	1
TAUNT → LAVA SURGE	$z_1 = 11.76$	28	9
LAVA SURGE → ERUPTION	$z_1 = 8.78$	944	2
ERUPTION → LAVA SURGE → STEAM BATH	$z_2 = 8.38$	77	5
STEAM BATH → LAVA SURGE → ERUPTION	$z_2 = 4.11$	7	12
Thunderbringer			
BLAST OF LIGHTNING → CHAIN LIGHTNING	$z_1 = 101.01$	10026	1
CHAIN LIGHTNING → BLAST OF LIGHTNING	$z_1 = 95.47$	4002	2
CHAIN LIGHTNING → LIGHTNING STORM	$z_1 = 26.89$	1501	3
LIGHTNING STORM → BLAST OF LIGHTNING	$z_1 = 10.71$	440	8
CHAIN LIGHTNING → TAUNT	$z_1 = 6.67$	51	19
TAUNT → BLAST OF LIGHTNING	$z_1 = 3.95$	33	21
TAUNT → LIGHTNING STORM	$z_1 = 2.41$	19	25
BLAST OF LIGHTNING → CHAIN LIGHTNING → LIGHTNING STORM	$z_2 = 35.40$	1164	5
CHAIN LIGHTNING → BLAST OF LIGHTNING → CHAIN LIGHTNING	$z_2 = 26.68$	990	6
LIGHTNING STORM → BLAST OF LIGHTNING → CHAIN LIGHTNING	$z_2 = 6.55$	236	12
BLAST OF LIGHTNING → CHAIN LIGHTNING → TAUNT	$z_2 = 5.54$	36	20
CHAIN LIGHTNING → BLAST OF LIGHTNING → CHAIN LIGHTNING → LIGHTNING STORM	$z_3 = 2.08$	18	26

Fonte: Wallner [149].

3.3 Visualização dos dados de jogos

Esta seção apresentará conceitos introdutórios, métodos e trabalhos correlatos acerca da visualização de dados do *gameplay*. Vale enfatizar que a visualização auxilia aos desenvolvedores e aos jogadores a entenderem, analisarem e explorarem os dados, além de contribuir para a descoberta de caminhos e de comportamentos inesperados do jogador, possibilitando assim identificar problemas no *design*, balanceamento, tendências e anomalias potencialmente interessantes não previstas durante desenvolvimento do jogo [150].

3.3.1 Visualização

É o processo que produz representações visuais de dados para tornar mais simples a compreensão e uso de informações [6]. Em diversos casos, é muito frequente usar a representação visual em vez da textual, pois a visualização tem poder de amplificar cognição humana, podendo ajudar, por exemplo, a representar, a simplificar e a organizar grande massa de dados de forma adequada e acessível [22]. A visualização possibilita aos usuários realizar a exploração e aprender sobre os dados, possibilitando gerar novas descobertas (detectar padrões e anomalias). Além disso, a visualização é útil no controle de qualidade dos dados, pois esta torna os problemas imediatamente visíveis [153].

No contexto da análise de dados de jogos, houve um aumento no interesse do uso e o desenvolvimento de técnicas de visualização nos últimos anos pela indústria e pela academia. A representação visual dos dados de jogos pode dar apoio aos desenvolvedores e aos *designers* para analisar os registros do comportamento do jogador e identificar interações ou problemas de *design* [42]. Apesar disso, os desenvolvedores e os *designers* não são os únicos que se beneficiam da visualização, pois existe uma tendência de que os jogadores também façam uso da visualização para analisar o histórico de jogo ou comparar seu comportamento com outros jogadores. Por exemplo, em jogos *multiplayer*, a visualização dos dados pode ser interessante aos jogadores para ajudá-los a otimizar suas estratégias ou melhorar sua equipe [96].

3.3.2 Técnicas de Visualização em Game Analytics

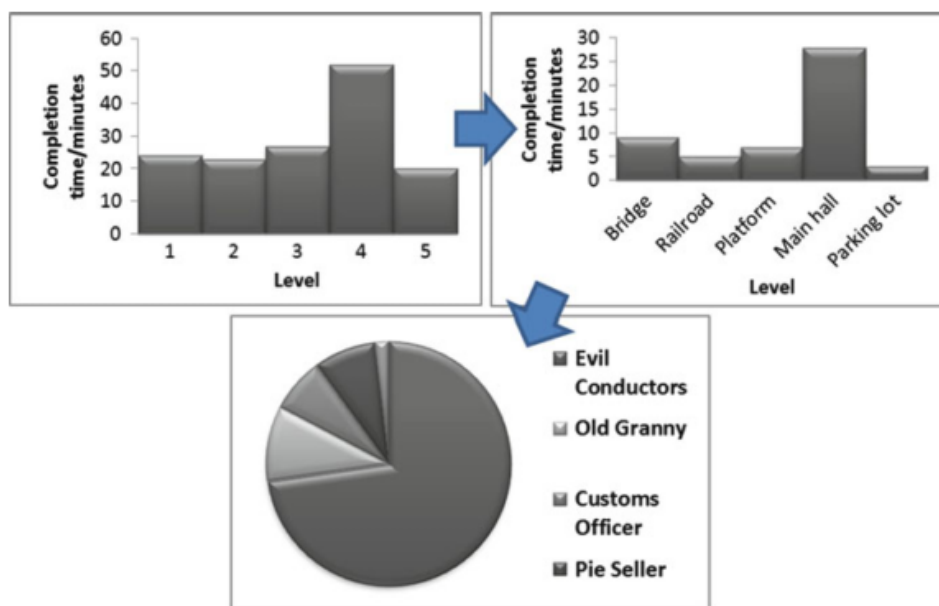
Nesta seção, iremos abordar as principais técnicas de visualizações utilizadas na análise de dados em jogos, em particular: gráficos, *heatmap*, visualização de movimento e representação *node-link*. Para cada tipo de visualização, será feita uma descrição geral com exemplos, dando uma visão macro de como as diferentes visualizações podem ser utilizadas no contexto do *game analytics*.

Gráficos

Representações gráficas de informações podem ser exibidas de diversas formas, como gráfico de barra (*bar chars*), gráfico de pizza (*pie charts*), gráfico de dispersão (*scatter plot*) entre outros, cada um com suas vantagens e desvantagens. Os gráficos podem ser usados para diversas finalidades, como mostrar os relacionamentos entre variáveis, ilustrar a distribuição de valores ou visualizar as tendências ao longo do tempo.

O trabalho desenvolvido por De Rosa [27] usa gráfico de barra para visualizar quanto tempo os jogadores do jogo *Mass effect* gastam em diferentes atividades (criação de personagem, por exemplo). Além disso, os gráficos (pizza, linha e outros) podem ser usados para visualizar diferentes níveis de detalhes, ou seja, permite a navegação entre as informações disponíveis, procedimento conhecido como navegação *drill-down* [42] (Figura 3.8).

Figura 3.8: Exemplo de navegação *drill-down*.




Fonte: El-Nasr et al. [42].

O trabalho realizado por Phillips [117] usou o gráfico de dispersão para apresentar o relacionamento entre a porcentagem dos jogadores que obtiveram uma conquista no jogo e o tempo médio que os jogadores levaram para obtê-la (Figura 3.9). Cada ponto do gráfico representa uma conquista específica, ajudando os designers a terem entendimento da progressão dos jogadores.

O trabalho desenvolvido por Kriglstein et al. [74] usa o gráfico de pizza sobreposto a um mapa aéreo do ambiente (visão de cima para baixo) do jogo para transmitir a distribuição percentual de diferentes variáveis em certas regiões do mapa. Esta representação


Figura 3.9: Gráfico de dispersão



Fonte: Phillips [117].

é um modo de colocar gráficos diretamente sobre a fonte de dados. A Figura 3.10 exemplifica o uso de uma visualização com gráfico de pizza que representa os tipos de torres que foram construídas em terrenos distintos.

Figura 3.10: Exemplo de gráfico de pizza mostrando proporção do número de torres construídas.




Fonte: Wallner e Kriglstein [152].

Heatmap

Heatmaps são mapas bidimensionais que usam cores para indicar a frequência de ocorrência de uma variável por meio do mapa (por exemplo, número de mortes com base na localização) [152]. Essa representação funciona como um gradiente de temperatura de cor em que os tons iguais ou próximos do azul representam uma baixa taxa de frequência, enquanto os tons iguais ou próximos do vermelho representam altas taxas de frequência. Os *heatmaps* possuem vantagens de serem fáceis de criar, são bem adaptados para reconhecer padrões de comportamento e fornecem uma visão geral das densidades relativas de dados em uma única imagem. Porém, representações contínuas de cores podem dificultar o julgamento das quantidades reais e a comparação de áreas com densidade semelhante. A Figura 3.11 apresenta um *heatmap* que mostra as localizações das ocorrências da morte dos jogadores que utilizaram o jogo *Team Fortress 2*. A figura demonstra que existe uma área letal localizada no canto inferior direito do mapa, onde os jogadores passam por um túnel estreito, conforme o cenário do jogo.

Figura 3.11: Heatmap da localização das mortes dos jogadores.




Fonte: Wallner e Kriglstein [152].

Visualização de Movimento

Diversos jogos exigem que o jogador navegue com o personagem por meio do ambiente virtual. O entendimento de como os jogadores se movem em torno do jogo pode então fornecer informações valiosas a respeito do *design*. Por exemplo, se os jogadores se comportam de forma diferente do esperado, seria interessante descobrir as causas desta disparidade. Dessa forma, para rastrear o movimento do jogador, é necessário registrar as posições em intervalos de tempo regulares. Todavia, rastrear os movimentos de diversos jogadores pode levar a um grande volume de dados. Neste caso, a visualização pode ser proveitosa para analisar e extrair informações significativas a partir dos dados acumulados. As visualizações do movimento dos jogadores podem ser úteis para detectar caminhos não intencionais tomados por eles [152].

A visualização de movimento mais comum é o **segmento de linha** (*line segment*) [42], em que as propriedades visuais de cor ou tamanho podem ser usadas para melhorar o contexto das informações. Parâmetro **cor** pode ser usado para refletir uma ampla variedade de parâmetros (por exemplo, a morte do personagem). Enquanto **tamanho** pode representar a frequência de eventos ou acontecimentos durante a sessão do jogo. A Figura 3.12 apresenta movimento do jogador utilizando *Infinite Mario* (versão de domínio público do famoso jogo *Super Mario Bros* da Nintendo) [151]. Na respectiva figura, os círculos amarelos refletem a frequência com que as moedas foram coletadas pelos jogadores e, ainda, as diferentes cores representam os níveis dos jogadores (de uma escala de 1 - iniciantes até 4 - profissionais), sendo que as cores são turquesa (nível 1), azul (nível 2), roxa (nível 3) e vermelho (nível 4). Essa representação visual promove o entendimento de como jogadores de diferentes níveis de especialização se comportam de forma diferente em um jogo.

Figura 3.12: Exemplo de caminho de visualização com código de cores.



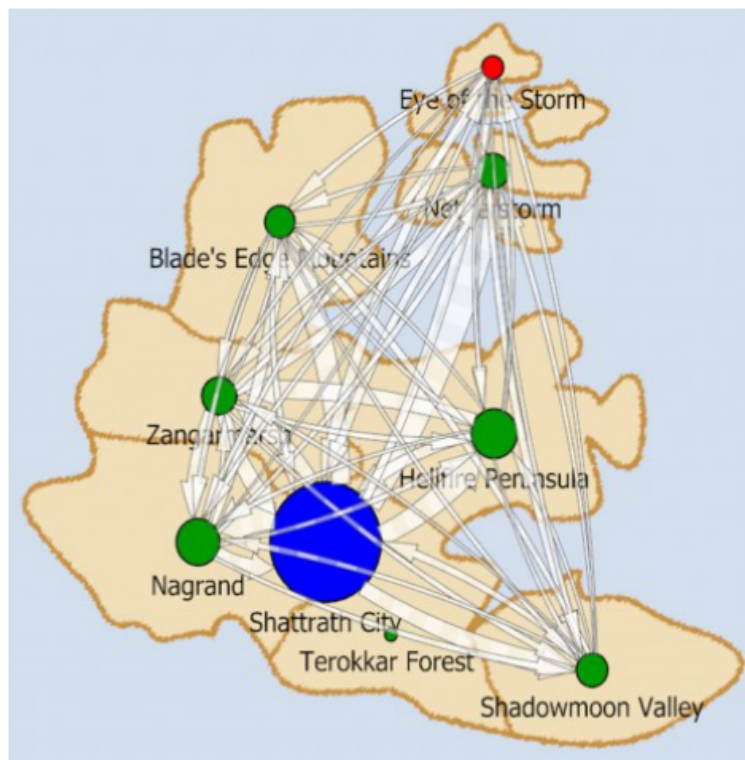
Fonte: Wallner e Kriglstein [151].

Representação *Node-Link*

Node-link é uma abordagem que fornece uma maneira intuitiva de visualizar o relacionamento dos dados. Os nodos (*nodes*) representam os próprios objetos de dados e as ligações (*links*) mostram os relacionamentos entre eles [152]. Além disso, os nodos podem ser visualizados em diferentes formatos (círculos ou retângulos) e ligações podem ser representadas por arcos, curvas, linhas e outros. Essa abordagem é muito eficaz quando se deseja uma visão abstrata dos dados.

Na Figura 3.13, temos um caso em que a base de dados possui dados espaciais que pode ser usada diretamente para posicionar os nodos. A respectiva figura apresenta os movimentos dos jogadores sobre os continentes do jogo *World of Warcraft* de uma amostra de dados de um dia [78]. Os continentes do *World of Warcraft* são discriminados em diferentes áreas que são representadas pelos nodos, as quais possuem código de cor, isto é, as regiões são representadas por verde, as cidades por azul e os campos de batalha por vermelho. As setas apresentam o movimento entre as áreas. Nesse exemplo, a espessura da seta indica número de jogadores que estão se movimentando de uma área para outra. Esse fato é justamente para evitar poluição visual.

Figura 3.13: Movimento dos Jogadores entre as áreas.



Fonte: Kriglstein, et al. [78].

Nas próximas seções, serão apresentados alguns trabalhos relevantes na área de visualização de dados de jogos que utilizaram as técnicas citadas anteriormente.

PLATO: A visual analytics system for gameplay data

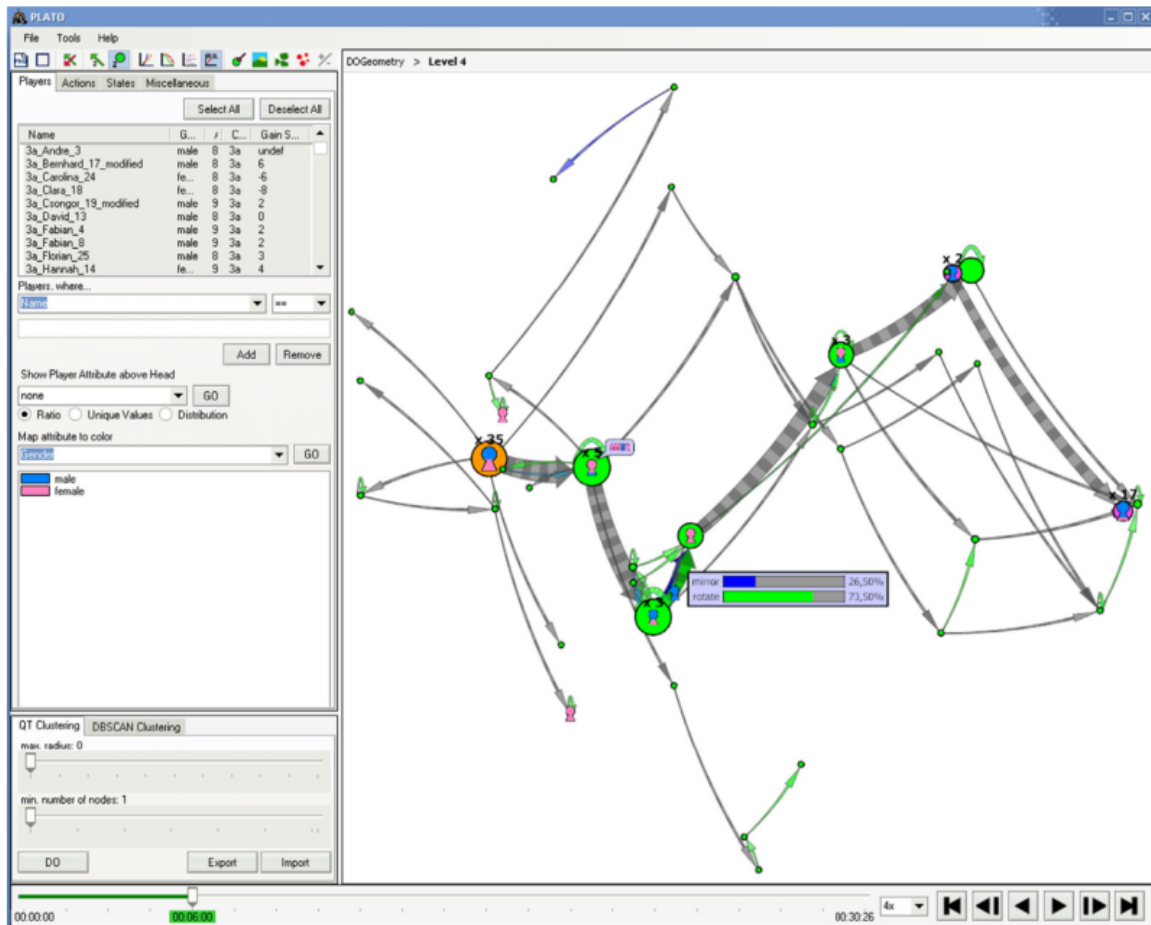
O trabalho feito por Wallner e Kriglstein [151] apresenta um sistema de visualização de dados de jogos (*gameplay*) multidimensionais e dependente do tempo (*time-dependent*) chamado PLATO (*Playgraph Analysis Tool*). Esses dados são formalmente representados como um grafo, dando a vantagem de uma representação geral e tornando-se uma ferramenta aplicável para uma ampla variedade de jogos, de modo que utiliza o mesmo conceito da representação *node-link* visto anteriormente. Os estados das entidades do jogo são representados como nodos e o tamanho do nodo indica a proporção do número de jogadores naquele estado e as ações/eventos são representadas pelas arestas. Para melhorar o aspecto visual (evitar poluição visual), tanto nodos quanto arestas são mesclados conforme a frequência das ocorrências (Figura 3.14).

Devido a essa representação em forma de grafos, o sistema utiliza alguns algoritmos de grafos (*subgraph matching* e *pathfinding*) e disponibiliza outras funcionalidades, como comparação de dados (utiliza diferença de grafos), *heatmap* (Figura 3.15) e algoritmos de clusterização.

Um detalhe importante a ser citado é com relação as análises feitas em grande massa de dados, pois a representação de grafos pode não ser uma alternativa viável. Desta forma, a ferramenta possibilita a utilização de algoritmos de clusterização para reduzir a complexidade visual. A atual versão do PLATO disponibiliza o uso dos algoritmos: *Threshold (QT) clustering* [56] e *DBSCAN clustering* [43]. A Figura 3.16 mostra a comparação *QT clustering* e *DBSCAN clustering* através do jogo *Team Fortress 2*. Os pontos cinzas representam as mortes e os pontos amarelos representam o agressor.

A Figura 3.16a representa o resultado do algoritmo *QT clustering*, ocorrendo a configuração do parâmetro do algoritmo chamado de **diâmetro** de duas formas: mínimo valor (lado esquerdo, justificando maior número de agrupamentos) e máximo valor (lado direito, justificando menor número de agrupamentos). A Figura 3.16b mostra o resultado do algoritmo *DBSCAN clustering*. Assim como no anterior, deve-se configurá-lo para seu funcionamento por meio de dois parâmetros: ε e *minPts*. O primeiro é o raio de vizinhança para cada ponto da amostra de dados, em que dado esse parâmetro, o algoritmo verifica a quantidade de pontos contidos no raio ε para cada ponto da amostra, e, se essa quantidade exceder um certo número, um cluster é formado. O segundo parâmetro é o que especifica o número mínimo de pontos, no dado raio de ε -vizinhança, que um ponto precisa possuir para ser considerado um ponto central e, portanto, de acordo com as definições de *cluster* baseadas em densidade, inicia-se a formação de um *cluster*.

Figura 3.14: Interface da versão atual do PLATO com área de visualização (à direita), várias funções para pesquisa, filtragem, agrupamento, bem como geração de gráfico (esquerda) e painel para simulação dependente do tempo (parte inferior).



Fonte: Wallner e Kriglstein [151].


Unified visualization of quantitative and qualitative playtesting data

O trabalho em progresso proposto por Mirza-Babaei et al. [99] apresenta uma nova abordagem de visualização que combina dados qualitativos (uso de questionário e observação) e quantitativos (medidas fisiológicas e movimento do jogador) para fins de análise do comportamento e experiência do jogador. Este domínio de pesquisa é importante para os *stakeholders* do jogo, pois estes necessitam conhecer o conjunto de dados que pode fornecer informações significativas para a melhoria do projeto do jogo.

Para efeitos de teste, os autores utilizaram o jogo *Infinite Mario* (Figura 3.17²). Os testes (*playtest*) conduzidos contaram com seis participantes jogando algumas fases do jogo. Para cada sessão, dados observacionais foram coletados com comentários verbais

²Detalhes em <http://www.mojang.com/notch/mario/>

Figura 3.15: Um heatmap do mapa do jogo *Team Fortress 2* mostrando as diferenças relativas do número de mortes (acumuladas em 20 rodadas).



Fonte: Wallner e Kriglstein [151].

dos jogadores, além de medidas fisiológicas e os movimentos do jogador que estavam sendo registrados em paralelo.


A aquisição de dados ocorreu da seguinte forma: dados dos movimentos do jogador foram obtidos em intervalos de tempo regulares, usando métodos de telemetria e armazenados em arquivos de texto. Os comentários foram adquiridos por gravações de vídeos (gravados durante sessão do jogo) por meio de entrevistas ao longo da sessão e foram exportados para arquivos de texto. Os dados fisiológicos foram capturados mediante resposta galvânica da pele (*Galvanic Skin Response* ou GSR) [87] por meio do EDA com objetivo de medir estado de excitação do jogador. Um importante ponto que deve ser destacado é a **sincronização** das diferentes fontes de dados. Nesse caso, uma referência de tempo foi adotada: **tempo de jogo**, que era apresentada na tela.

A Figura 3.18 apresenta a proposta da visualização de dados, triangulando as três fontes citadas anteriormente. Como pode ser observado na figura, temos as linhas que representam os movimentos dos jogadores. A coloração destas representa o estado de excitação do usuário. Quanto mais próximo do vermelho significa que foi detectado alto nível de excitação. Em contrapartida, quanto mais se aproxima do amarelo, significa

Figura 3.16: Utilização dos algoritmos de clusterização.

(a) Uso do *Threshold (QT) clustering*.

(b) Uso do *DBSCAN clustering*.



Fonte: Wallner e Kriglstein [149].

menor nível de excitação. As bolhas de texto localizadas na parte superior da tela do jogo significam comentário verbal do jogador. Desta forma, as três fontes de dados estão integradas.

Uma interpretação possível da Figura 3.18 é na área **A** os caminhos possuem código de cor amarelo, mostrando que é uma área segura com poucos ou nenhum inimigo e sem nenhum buraco (*gap*) que possa levar a morte do personagem de forma imediata. Na área, **B** existem muitas linhas vermelhas (indicando nível de excitação alto), provavelmente devido ao jogador ter que atravessar dois buracos que levam a morte do personagem de forma imediata no caso em que ele pula de forma incorreta e, ao mesmo tempo, ter de enfrentar um inimigo localizado na plataforma (entre os dois buracos).

3.4 Inferindo Emoções em Jogos

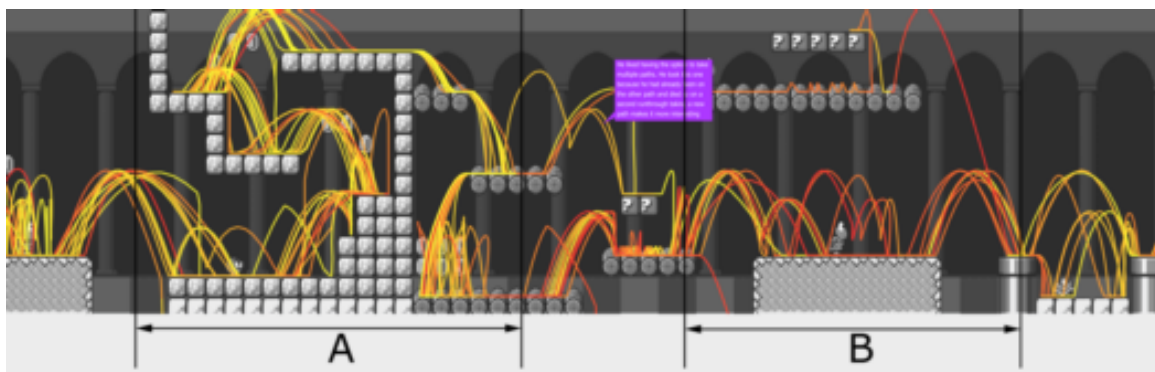
Um dos principais argumentos das pesquisas da computação afetiva é sugerir que a máquina possa ter a capacidade de expressar e reconhecer as emoções dos seres humanos [140]. No contexto de jogos digitais, a computação afetiva é relevante em diversos aspectos, entretanto, nessa tese de doutorado, direciona-se principalmente no **reconhecimento das emoções dos jogadores** por meio dos eventos dos jogos que ocorrem durante a inte-

Figura 3.17: Imagem do jogo Infinite Mario.



Fonte: Mirza-Babaei et al. [99].

Figura 3.18: A proposta da visualização com linhas que mostram caminho do jogador e o estado de excitação [adaptada].



Fonte: Mirza-Babaei et al. [99].

ração do usuário com jogo. Para a pesquisa dos trabalhos desta subseção, foram adotados alguns critérios:

- Adoção de biosensores no procedimento experimental;
- O uso de técnicas de inteligências artificial no processo de identificação e reconhecimento de emoção;

- Utilização de dataset afetivos derivados de sinais psicofisiológicos;
- A pesquisa ser vinculada ao contexto de jogos;
- Trabalhos publicados em revistas ou conferências com alto fator de impacto na área da computação.

As possibilidades de reconhecer emoções por meio de dados psicofisiológicos durante o desenvolvimento ou fase de *playtest* permitem que os desenvolvedores e pesquisadores investiguem quais os tipos de eventos de jogo podem gerar uma emoção específica e, conseqüentemente, estabelecendo atualizações no *game design* a fim de fornecer a melhor experiência possível ao jogador. Uma maneira comum de inferir as emoções dos jogadores é considerar os dados do *gameplay* (dentro do jogo) e seus dados psicofisiológicos. Este último pode ser usado para identificar emoções dos usuários [46] e fornecer *input* para algum dispositivo ou próprio jogo [45].

O *gameplay* considera o comportamento do jogador dentro do mundo virtual, o qual fornece um conjunto de entradas e decisões com base em sua expertise dentro do jogo. Todo esse processo cognitivo pode alterar as suas emoções e influenciar a interação com jogo [51]. Essa abordagem pode usar diferentes tipos de medidas, como as descritas na seção 2.3.1, como exemplo, tempo gasto para realizar uma determinada missão. Essas decisões por parte dos jogadores fornecem aos pesquisadores uma maneira de inferir as emoções destes em diferentes estágios do jogo [160]. Contudo, esse tipo de métrica é muito sensível devido à grande variedade de jogadores existentes, fazendo com que cada jogador possa apresentar diferentes interpretações para um mesmo evento de jogo. Diferentemente, os dados psicofisiológicos podem fornecer um feedback mais confiável, uma vez que o processamento e a análise destes geram respostas que podem ser usadas diretamente para relacionar com a *player experience* [126, 79, 91]. A seguir, serão apresentados diferentes estudos de caso, considerando o entendimento das emoções dos jogadores usando dados psicofisiológicos.

O trabalho feito por Tognetti et al. [143] usou um jogo de corrida *open-source* para entender as preferências dos jogadores sobre as diferentes configurações. Eles realizaram diferentes experimentos com um conjunto de participantes, registrando os seguintes sinais psicofisiológicos: ECG, GSR, respiração e temperatura. A configuração do experimento se deu da seguinte maneira: os participantes jogaram o mesmo jogo seis vezes, sendo duas vezes para cada configuração customizada do oponente:

- **Modo W:** oponente mantém uma distância de acima de 100 metros do jogador;
- **Modo C:** o oponente com habilidade similar ao jogador;
- **Modo L:** oponente mantém uma distância de menos de 100 metros do jogador.

Todos os participantes jogaram as sessões de jogo seguindo uma ordem específica (CL-WLCW), e, após cada nível, eles forneceram informações sobre a preferência entre nível atual e o anterior. Dessa forma, os autores classificaram os dados usando o algoritmo *Linear Discriminant Analysis* e alcançaram uma precisão de 74% com relação a preferência de jogo. Uma extensão do trabalho anterior pode ser encontrada em [142], em que os autores usaram o mesmo jogo de corrida para classificar e reconhecer o nível de satisfação do usuário a partir dos dados psicofisiológicos. Nesse trabalho, foram definidas três classes de satisfação para viabilizar o processo de classificação e estas foram derivadas das comparações de diferentes corridas. Nesse experimento, houve a participação de 75 participantes e os sinais psicofisiológicos utilizados foram: BVP, ECG, GSR, respiração e temperatura. O algoritmo de classificação adotado foi KNN (*K Nearest Neighbor*) e teve como o melhor resultado alcançado, de modo a ser capaz de classificar corretamente os três níveis de satisfação, em 57% de precisão. A vantagem desse trabalho foi a diversidade dos sinais, porém a principal desvantagem foi a grande quantidade de ruídos proporcionada pelos sensores, afetando qualidade do modelo.

A pesquisa feita por Mirza-babei et al. [116] comparou dois métodos usados nas pesquisas no GUR, com intuito de fornecer um feedback direto aos desenvolvedores. Nesse caso, os autores utilizaram uma técnica baseada na observação e em dados psicofisiológicos. Nessa pesquisa, os autores selecionaram dois jogos do tipo FPS (*First Person Shooter*) com diferentes características, *Call of Duty: Modern Warfare 2* e *Haze*. Para esse experimento, foram selecionados seis participantes sem experiência prévia sobre jogos desse gênero e os dados psicofisiológicos capturados foram do GSR. Desta forma, os participantes jogaram ambos os jogos e, durante as sessões de jogo, foram aplicados ambos métodos propostos. Na abordagem, utilizando dados psicofisiológicos, foram registrados *logs* dos eventos do jogo simultaneamente com dados GSR (Veja Figura 3.19). Enquanto, na abordagem por observação, envolveu-se a participação de dois especialistas para avaliar o *gameplay*. A conclusão desse estudo foi que a abordagem baseada em observação pode identificar problemas relacionados à usabilidade do *game design*. Já na outra abordagem, é possível identificar questões relacionadas à experiência emocional do jogador. A desvantagem desse trabalho foi usar somente um sinal para avaliar a experiência emocional do jogador.

O trabalho feito por Maier et al. [82] utiliza a teoria do *flow* junto às medidas de dados psicofisiológicos para estimar a experiência do usuário durante a interação com o jogo customizado do Tetris para ambiente *mobile*. Nessa pesquisa, foram adotados os três estados comportamentais que sustentam a teoria do *flow*: Tédio (*Boredom*), *Flow* (estado de satisfação) e Estresse (*Stress*). O experimento foi conduzido com 72 participantes utilizando o dispositivo *Empatica E4 wristworn* [59] de forma a capturar os dados do

Figura 3.19: Uma captura de tela mostrando a coleta de dados psicofisiológicos na pesquisa feita em [116].

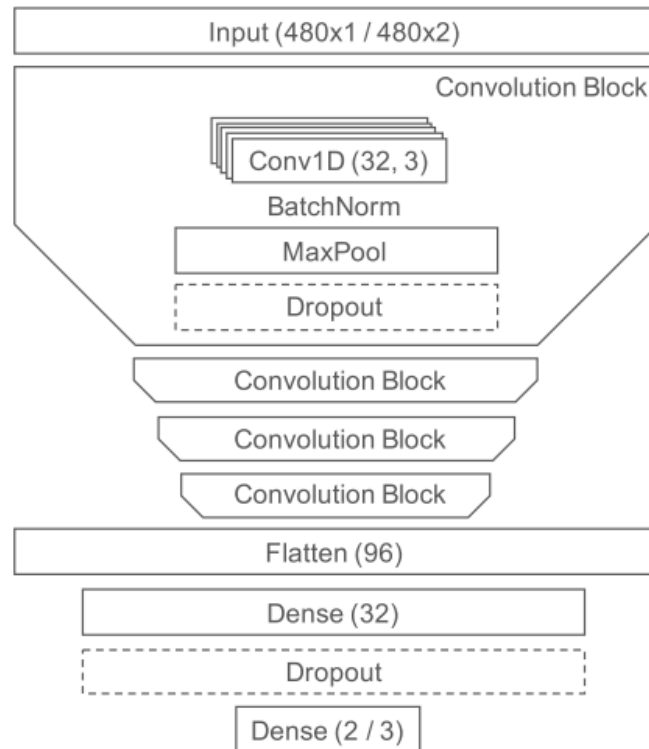


Fonte: Mirza-babei et al. [116].

EDA e BVP, totalizando 72 sessões com 36 horas de duração. Além disso, o referente jogo possuía três níveis de dificuldade (*Easy*, *Medium* e *Hard*) e se baseava na velocidade e na rotação das pedras (conhecidas como *tetromino*). Após cada nível completado do jogo, o participante era convidado a preencher um questionário de experiência de jogo (GEQ - *Game Experience Questionnaire*). Tal instrumento foi desenvolvido para medir o estado de *flow* dos participantes [1]. Este trabalho utilizou, para tarefa de classificação, o modelo de rede neural convolucional (*CNN - Convolutional Neural Network*), que pode ser visto na Figura 3.20. Esta arquitetura obteve 49% de precisão de ser capaz de classificar corretamente os três níveis de estados afetivos definidos pelos autores. A vantagem desse trabalho foi utilizar ambiente pouco intrusivo em comparação com os demais trabalhos desta seção, porém sua desvantagem foi devido a baixa variabilidade emocional que o jogo proporcionava e *dataset* desbalanceado, contribuindo para a baixa acurácia do modelo.

Outro trabalho feito pelos autores Vachiratamporn et al. [144] analisou os efeitos emocionais sobre os participantes a partir de um jogo de terror chamado *Slender: The Eight Pages*. O experimento estudou 11 participantes e os autores coletaram dados psicofisiológicos do EEG e ECG, com os dados do *gameplay*, como inputs do teclado e mouse. Além disso, os autores desenvolveram uma ferramenta de autorrelato, que apresenta o vídeo do *gameplay* e a face do participante durante o experimento, em que ele deve marcar a

Figura 3.20: Arquitetura da rede neural convolucional usada na pesquisa feita em [82].

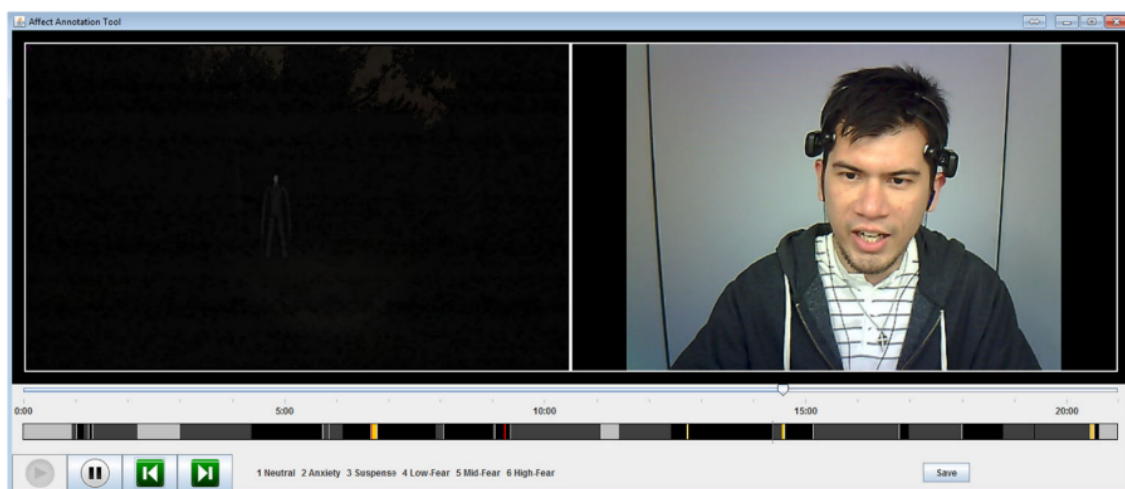


Fonte: Maier et al. [82].

emoção vivenciada (por meio de um conjunto de emoções discretas pré-definidas: neutro, ansiedade, suspense, pouco medo, medo moderado e muito medo) em momentos pontuais do jogo (Veja Figura 3.21). Essa pesquisa utilizou uma árvore de decisão como modelo de classificação, tendo como precisão média em torno de 80%. As conclusões desse estudo mostraram que os jogadores tendem ficar mais tensos ou assustados quando estão em uma cena de suspense e a frequência cardíaca é um ótimo indicador para detectar estados emocionais de medo ou tensão. A desvantagem deste trabalho foi o alto nível de invasão dos sensores, proporcionando certo nível de desconforto.

Existem alguns trabalhos que realizaram experimentos similares aos desta pesquisa, os quais criaram um *dataset* afetivo com dados psicofisiológicos via estímulos induzidos por meio de jogos. O trabalho feito por Yang et al. [159] avalia as respostas psicofisiológicas relacionadas aos eventos de jogos. Especificamente, os autores apresentaram um *dataset* multimodal que contém sinais fisiológicos (ECG, EDA, Respiração, EMG e temperatura), acelerômetro, registro da face do jogador e do *gameplay*, bem como os autorrelatos dos jogadores com respeito às avaliações emocionais durante o jogo, ainda, eles realizaram a investigação dos processos de detecção e reconhecimento de emoção em eventos de jogos usando técnicas de *machine learning* a partir dos dados psicofisiológicos. Além disso, esse trabalho analisou as diferentes janelas de tempo (*time window*) para avaliar a precisão

Figura 3.21: Uma captura de tela mostrando a ferramenta de anotação de emoção desenvolvida em [144].



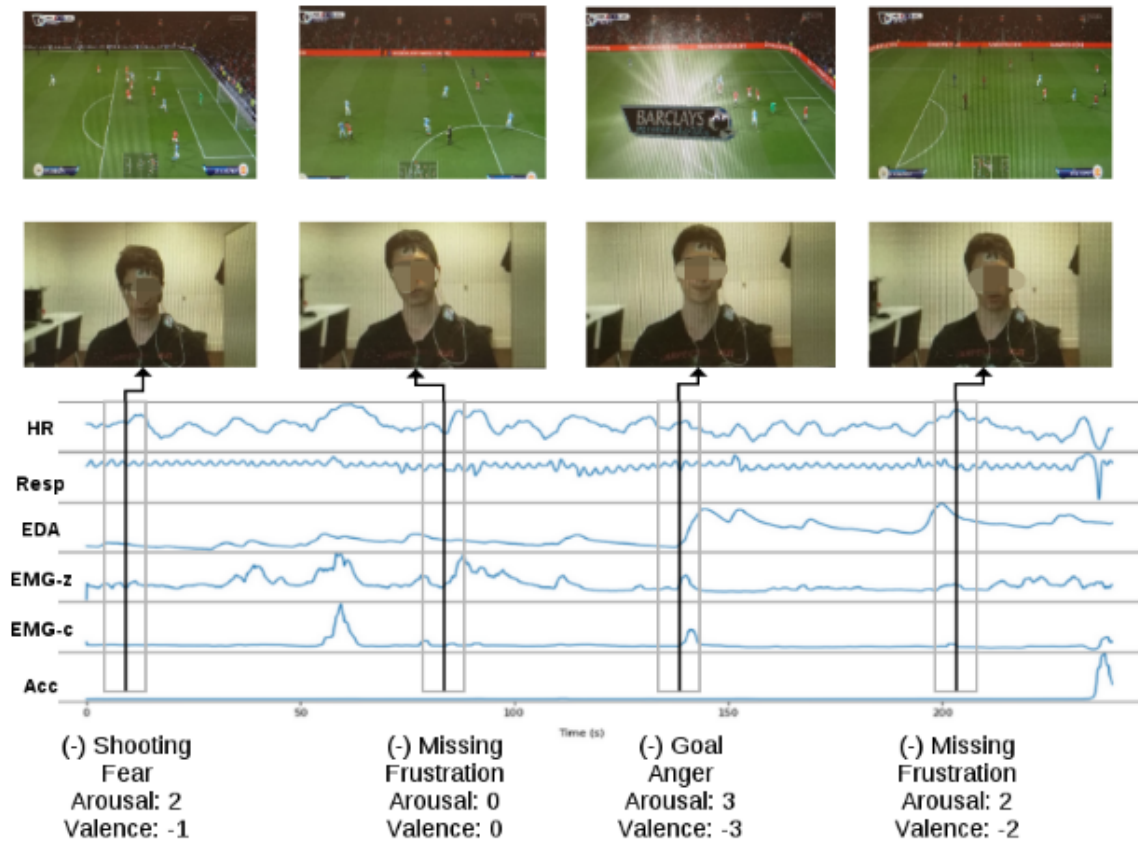
Fonte: Vachiratamporn et al. [144].

desses processos e teve como os melhores resultados as janelas mais curtas, de 14 e 20 segundos. Com relação ao protocolo experimental:

- O trabalho teve 58 participantes de diferentes níveis de habilidades e usou um jogo do gênero esportivo, FIFA 2016 (Veja Figura 3.22);
- Cada experimento foi composto por 4 fases (1 de treinamento e 3 partidas);
- Após cada metade de uma partida, o participante preenchia um questionário de *game experience*;
- No final de cada partida, o participante realizava autorrelato da sua partida. Conforme gravação do *gameplay*, anotando as emoções, de acordo com evento relevante do jogo (pênalti, impedimento, gol, falta, escanteio e cobrança de falta).

O *dataset* foi formado usando os dados psicofisiológicos dos participantes junto aos rótulos das emoções anotadas pelos eventos relevantes durante o jogo. O treinamento do modelo foi feito usando SVM (*Support Vector Machine*) e o reconhecimento de emoção foi feito por uma classificação binária de excitação (*arousal*) e valência (*valence*) com precisão de 60% e 57%, respectivamente. Outro ponto importante é com relação janela de tempo. A revisão sistemática sobre os estudos de dados psicofisiológicos feita por Kreibig [73] mostra que as janelas de tempo mais usadas são 60, 30 e 10 segundos. Um ponto negativo deste trabalho foi o alto nível de invasão dos sensores, proporcionando certo nível de desconforto ao usuário, mas um ponto positivo foi a variabilidade das diferentes janelas de tempo, mostrando que esse fator impacta diretamente na qualidade do modelo.

Figura 3.22: Uma captura de tela mostrando a coleta de dados durante *gameplay*.




Fonte: Yang et al. [159].

Outro trabalho na mesma linha do anterior, feito por Granato et al [52], propõe uma arquitetura para armazenamento de dados fisiológicos (Veja a Figura 3.23) e uma ferramenta de autorrelato para capturar os estados emocionais dos participantes durante as sessões de jogo em que acontece algum evento importante. Os autores utilizaram, para a captura de dados fisiológicos, ECG, EMG sobre músculos da face, EDA e a taxa de respiração. Esse estudo utilizou 33 participantes para validação e treinamento do modelo. Com os dados do autorrelato e dos dados fisiológicos, houve a criação de um *dataset* baseado nas respostas emocionais dos jogadores, ou seja, *dataset* que utiliza um jogo como estímulo. Vale ressaltar que a ferramenta de autorrelato possibilita ao avaliador definir o estado emocional com relação ao evento do jogo por meio dos valores de valência (*valence*) e excitação (*arousal*), como visto na parte inferior da Figura 3.24. Para validação da pesquisa, no final de cada sessão, um grupo de participantes foi designado em preencher um questionário para avaliar a experiência de jogo em termos de *valence* e *arousal* e comparar os dados do questionário com os dados usados na ferramenta de auto-avaliação em termos de correspondência. A pesquisa mostra que a média dos valores de *valence* e *arousal*


entre ferramenta de autorrelato e o questionário são similares, embora as respostas do questionário sejam ligeiramente superestimadas pelos autores. Um ponto negativo deste trabalho foi a complexidade do processo de avaliação do autorrelato pelos participantes, uma vez que eles não tinham uma referência do quanto as emoções vivenciadas refletiam nos valores *valence* e *arousal*.

Figura 3.23: Visão geral da arquitetura usada para capturar os dados fisiológicos.



Fonte: Granato et al [52].

Figura 3.24: Ferramenta de autorrelato para identificar as emoções durante os eventos do jogo.



Fonte: Granato et al [52].

Capítulo 4

Metodologia Experimental

4.1 Escopo

O principal objetivo dessa pesquisa é estimar as emoções vivenciadas pelos jogadores durante a interação com o jogo por meio das mudanças fisiológicas geradas pelo seu organismo. Para alcançar este objetivo, concebemos um protocolo experimental que fornece o suporte necessário para inferir as emoções dos jogadores.

Este capítulo, inicialmente, apresenta uma visão geral da metodologia aplicada nos experimentos. Em particular, serão abordado os sinais psicofisiológicos que foram considerados relevantes para estimar as emoções dos jogadores e as diferentes tipologias de identificação de emoções. A partir da seção 4.3, serão apresentados detalhes metodológicos do experimento, como número de participantes, jogo utilizado, aquisição dos dados psicofisiológicos e o procedimento de criação do *dataset*. Na seção 4.4, serão apresentados os detalhes com relação à criação do *dataset*. Na seção 4.5, será abordado processo de tratamento e pré-processamento de dados.

4.2 Visão Geral dos Métodos Aplicados

Estimar a emoção durante a interação com jogo é um assunto muito explorado na computação afetiva. Normalmente, durante as sessões experimentais, os pesquisadores consideram analisar os estímulos curtos por estarem relacionados à capacidade de produzir emoções específicas. Além disso, os jogos digitais, por serem ambientes interativos, podem estimular um conjunto de emoções aos jogadores. Há diferentes características de jogos capazes de produzir emoções (veja seção 3.4). Considerando a mecânica do jogo, por exemplo, a ação “pular”, em diferentes condições, pode gerar uma variedade de emoções, como no jogo do *Super Mario Bros.*, em que pular em uma plataforma ou na cabeça do inimigo produz emoções diferentes. Outro ponto a ser destacado: efeitos audiovi-

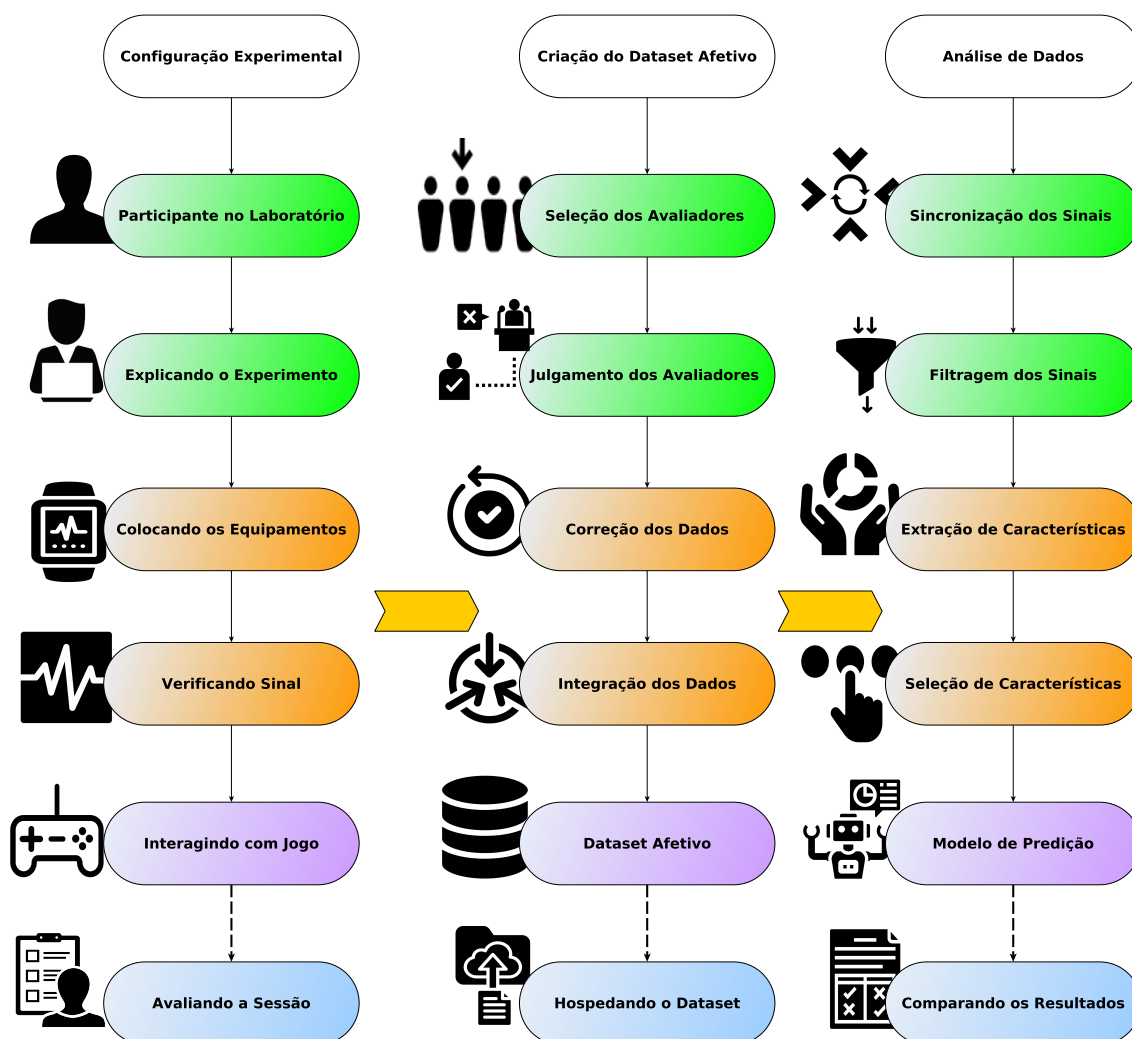
suais em jogos são elementos fundamentais para tentar reproduzir emoções específicas. Por exemplo, no jogo *Resident Evil*, em algumas cenas, ocorre a entrada de uma música de suspense, gerando, em grande parte, tensão ao jogador. O jogo selecionado para o presente experimento maximiza os aspectos mecânicos e audiovisuais, que podem ser encontrados com uma boa aproximação na maioria dos jogos da atualidade. No entanto, esse jogo minimiza outros aspectos, como fatores sociais (encontrados em jogos *on-line*) e criação de uma narrativa que impacta nas emoções dos jogadores. De modo a obter um grande número de participantes, o jogo selecionado não requer habilidades específicas para ser utilizado, logo ele foi projetado e customizado para pessoas entre 18 e 50 anos de idade, envolvendo uma mecânica intuitiva de direção automobilística. Isso garante consistência durante os experimentos, como consequência, a capacidade do jogo de produzir emoções nos jogadores. O protocolo experimental garante o compromisso da replicação dos métodos em qualquer jogo, ou seja, a generalização da aplicação dos procedimentos em qualquer jogo, com pequenas adaptações por parte do pesquisador.

A presente abordagem experimental visa obter as alterações fisiológicas dos participantes durante a interação com jogo. Além disso, os participantes foram convidados a relatar suas experiências emocionais vivenciadas durante o experimento por meio de uma ferramenta de autorrelato desenvolvida pelo autor. Dessa forma, acredita-se que exista uma relação entre os dados psicofisiológicos e os relatados pelos participantes. A partir disso, foi projetado um protocolo que pudesse guiar os desenvolvedores e pesquisadores desde a coleta de dados até o fornecimento dos resultados, com algumas adaptações, que podem ser usados para analisar os estados emocionais em diferentes momentos do jogo.

De modo a coletar os dados psicofisiológicos, foi realizado um levantamento bibliográfico sobre as diferentes técnicas e ferramentas, considerando trabalhos no mesmo contexto. Assim, a partir dos dispositivos e softwares utilizados na literatura, foi adotado primeiramente o dispositivo *BITalino Board Kit* [13] por ser um hardware de baixo custo e atendia, no primeiro momento, os requisitos iniciais do estudo. Posteriormente, de acordo com o aumento da complexidade da configuração experimental e os novos requisitos dos experimentos, junto ao aumento de ruídos gerados pelo hardware, foi adotado um novo dispositivo, o *Empatica E4*. Uma explicação detalhada desse hardware é apresentada na seção 4.2.1.

Como o protocolo experimental é constituído por etapas independentes (Figura 4.1), este foi projetado para apresentar os detalhes em como executar um experimento, na criação de *dataset* e, durante a análise dos dados, apresentar como as diferentes técnicas baseadas em *machine learning* e estatística podem ser aplicadas. Consequentemente, todos os aspectos da análise (por exemplo, o procedimento de *feature extraction* dos sinais fisiológicos) foram projetados para funcionar sem qualquer operação externa.

Figura 4.1: Fluxo da aplicação do estudo. **No lado esquerdo:** As etapas para realização de um experimento. **No centro:** As etapas do processo de criação do *dataset*. **No lado direito:** Os passos que envolvem a análise de dados



Fonte: Autor.

O protocolo experimental foi projetado com duas finalidades: propor um ambiente de pesquisa válido à disposição da comunidade científica e desenvolver uma ferramenta para os *game designers* que desejam verificar se aquela *game feature* está gerando a experiência esperada por eles.

A pesquisa foi estruturada da seguinte maneira:

- Projetar as características do protocolo experimental e implementar as ferramentas necessárias para conduzir os experimentos. Ainda, realizar um conjunto preliminar de experimentos para validar o protocolo e destacar os aspectos críticos e adquirir dados com um número significativo de participantes;

- Com os dados coletados e as ferramentas disponíveis, foram selecionados alguns avaliadores da área da psicologia para realizar análise/julgamento dos vídeos das faces dos participantes. Essa etapa foi importante para construção do *dataset* afetivo, uma vez que foram rotuladas as emoções conforme a janela de tempo definida (10 segundos);
- Uma terceira etapa foi selecionar um novo conjunto de participantes para validação da pesquisa, em que estes, além de jogarem, também eram designados a realizar autorrelato da sua experiência de jogo.

As informações dos participantes foram tornadas anônimas e, a cada participante, foi atribuído um identificador. Os dados audiovisuais não são fornecidos à comunidade científica, como os vídeos, a fim de garantir o anonimato dos participantes. No entanto, os participantes assinaram um termo de consentimento livre e esclarecido, que permite o uso das informações de áudio/vídeo para fins de divulgação científica. Para a reprodução da pesquisa, os dados em formato .csv podem ser encontrados em <https://github.com/eltonsarmanho/PGD-Ex>

4.2.1 Dados Psicofisiológicos Considerados

Para aquisição de dados, a presente pesquisa usou a abordagem baseada na **psicofisiologia**, que consiste em um conjunto de métodos empregados para derivar estados psicológicos a partir de medidas fisiológicas [69, 132]. As métricas mais comuns são rastreamento ocular, eletromiografia (EMG), eletroencefalografia (EEG), eletrocardiograma (ECG) e resposta galvânica da pele (GSR), temperatura corporal e fotopletismografia (em inglês, *photoplethysmography* – (PPG)). Caso o leitor tenha maior interesse sobre a aplicação dessas medidas em outros contextos, veja os estudos em [69, 105].

Normalmente, as medidas fisiológicas são capturadas por biosensores especializados que são colocados no corpo humano e conectados a um sistema computacional para processamento. Diferentes tecnologias são utilizadas de acordo com o tipo de sinal que está sendo monitorado. O biosensor utilizado no presente estudo foi E4 *wristband*, desenvolvido pela Empatica (Figura 2.3c). Esse é um dispositivo projetado para a captura de dados contínuos em tempo real, sendo capaz de medir diferentes respostas fisiológicas do corpo. Em particular, o E4 tem 4 sensores: sensor PPG, sensor EDA, 3-axis *accelerometer* e o sensor de temperatura. O foco da presente pesquisa foi a condutância da pele e a frequência cardíaca, que foram medidos pelo sensor EDA e pelo sensor PPG. Assim, o sensor PPG mediu o BVP, do qual IBI e HR foram derivados, enquanto o sensor EDA mediu o nível de excitação do sistema nervoso simpático. Além disso, E4 possui uma fun-

ção que inclui marcadores de tempo, a qual muito utilizada para marcar início e término das sessões de jogo.

A escolha desses sinais seguiu os seguintes critérios:

- Facilidade da captura do sinal;
- Disponibilidade de bibliotecas para processamento dos biosinais;
- Facilidade na interpretações dos sinais;

Alguns trabalhos consideram as expressões faciais como uma medida psicofisiológica que podem ser usadas para inferir estados afetivos [138, 146]. A presente pesquisa utilizou um *framework* desenvolvido na Universidade de São Paulo que detecta e reconhece sete emoções básicas [146], como mostrado na Figura 4.2.

Figura 4.2: Sistema de análise de expressões faciais.



Fonte: Autor.

Esta metodologia de aplicar um sistema de análise de expressões faciais junto ao dispositivo E4 configurou um ambiente menos invasivo, se comparado com os trabalhos desenvolvidos na seção 3.4, que utilizam sensores na região dos pés, face e/ou no peito.

A presente pesquisa desenvolveu uma ferramenta *open source* chamada PGD_EX (*Project Game Data Explorer*) para exibir os dados coletados dos participantes durante a sessão de jogo, que pode ser vista na Figura 4.3. Essa ferramenta consiste em três painéis principais: Painel Gráfico, Painel de Vídeo e Painel Controle de Vídeo. O primeiro compõe os gráficos que exibem os dados do GSR, da frequência cardíaca (gerada das transformações do BVP) e das emoções prototípicas derivadas do processamento da imagem do vídeo produzido da face do participante. O segundo contém a exibição do vídeo do *gameplay* (Parte Superior) e a face do participante (Parte Inferior). O terceiro painel abrange o controle do *playback*, em que usuário pode manipular ações (adiantar, voltar ou até mesmo restringir um trecho) da sessão pelo *slider*, que pode manusear o progresso do vídeo. Um ponto importante é que a ferramenta não precisa de todos os dados para funcionar. Caso o usuário queira somente ver os vídeos e analisar comportamento do jogador com *gameplay* basta carregar os vídeos no formato mp4, no entanto, se quiser somente ver os dados psicofisiológicos, é só carregar os dados desejados. Como a ferramenta é *open source*, qualquer desenvolvedor pode acessar o repositório ¹, alterar o software e fazer as adaptações necessárias.

Por fim, caso seja do interesse do leitor ver a interação com a ferramenta, veja o vídeo em <https://www.youtube.com/watch?v=frf6FinjXvQ&t=5s>.

¹Código está hospedado no github: <https://github.com/eltonsarmanho/PGD-Ex>

Figura 4.3: A visualização dos dados psicofisiológicos durante uma sessão de jogo para um participante



Fonte: Autor.

4.2.2 Avaliação das Emoções

Durante os experimentos, foi necessário saber as informações sobre a experiência emocional dos participantes. Segundo a Figura 4.5, houve dois momentos de avaliação da emoção, na fase 2 (realizado pelos especialistas em análise de expressões faciais) e a terceira fase (em que um novo conjunto de participantes relatou seus estados emocionais após sessão de jogo).

Uma importante decisão foi tomada com relação ao conjunto de emoções que deveriam ser aplicadas durante a avaliação, pois não poderia ser uma quantidade pequena (geraria o problema de selecionar uma emoção por exclusão, não refletindo de fato a experiência emocional) ou extensa (tornaria uma atividade cansativa e custosa). Desta forma, o estudo feito por Harmon-Jones et al. [55] considerou utilizar um conjunto de emoções discretas para avaliar diversos ambientes de entretenimento, incluindo jogos digitais. A partir do estudo anterior e tendo como base a pesquisa feita por Drioli e Foresti [35], foi implementada uma ferramenta de anotação (Figura 4.4) para realizar o julgamento das expressões faciais, determinando quais emoções estão sendo vivenciadas durante o *gameplay*. Além disso, a ferramenta permite visualizar o vídeo do *gameplay* e registrar os eventos do jogo. Considerando o aspecto temporal, os valores produzidos pela ferramenta são todos configurados utilizando tempos discretos, pois essa configuração fornece uma maior quantidade de dados para prever os estados emocionais, possibilitando um maior sucesso na precisão do modelo de *machine learning*.

Como mostrado na Figura 4.4, a interface da ferramenta de anotação é estruturada da seguinte forma:

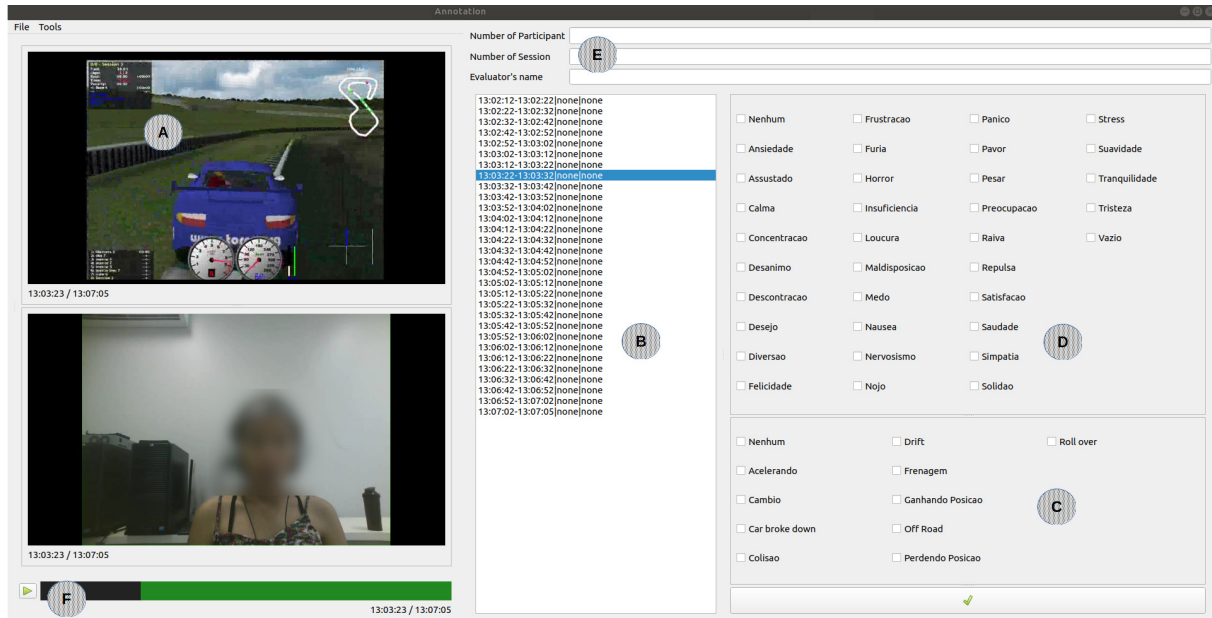
- A) O display dos vídeos (face do participante e do *gameplay*); B) C) D)
- B) Janela de Tempo;
- C) Opções de seleção com relação aos eventos do jogo;
- D) Opções de seleção com relação as emoções vivenciadas durante o jogo;
- E) Caixa de texto para identificar o participante, a sessão e o avaliador;
- F) Barra de controle do vídeo.

Com relação às opções de emoções e os eventos do jogo, são apresentadas a seguir:

Lista de emoções: frustração, pânico, stress, ansiedade, fúria, pavor, suavidade, assustado, horror, pesar, tranquilidade, calma, insuficiência, preocupação, tristeza, concentração, loucura, raiva, vazio, desânimo, mal disposição, repulsa, descontração, medo, satisfação, desejo, náusea, saudade, diversão, nervosismo, simpatia, felicidade, nojo, solidão.

lista de eventos de jogo: *Drift*, *Roll over*, acelerando, frenagem, câmbio, ganhando Posição, perdendo posição, *Car broke down*, *Off road* e Colisão.

Figura 4.4: Ferramenta de anotação de emoção.



Fonte: Autor.

Um ponto importante a ser destacado é a lista de emoções. Para o jogo utilizado nessa pesquisa, não foram utilizadas todas emoções. Além disso, no decorrer do experimento, algumas opções foram renomeadas para se adequar à linguagem natural do local. O objetivo da construção de uma ferramenta aberta e gratuita é fornecer suporte aos estudos sobre avaliação de emoção durante o *gameplay* ou a produção do jogo. A ferramenta utiliza emoções discretas e essa configuração viabiliza a comparação de emoções entre abordagens diferentes, o que foi o caso da presente pesquisa, que compara abordagem de autorrelato com o modelo de predição. Ainda, pensando no aspecto de flexibilidade, caso outros pesquisadores desejem utilizar a ferramenta, é possível aumentar ou reduzir o espectro de emoções/eventos, de acordo com a caracterização do experimento.

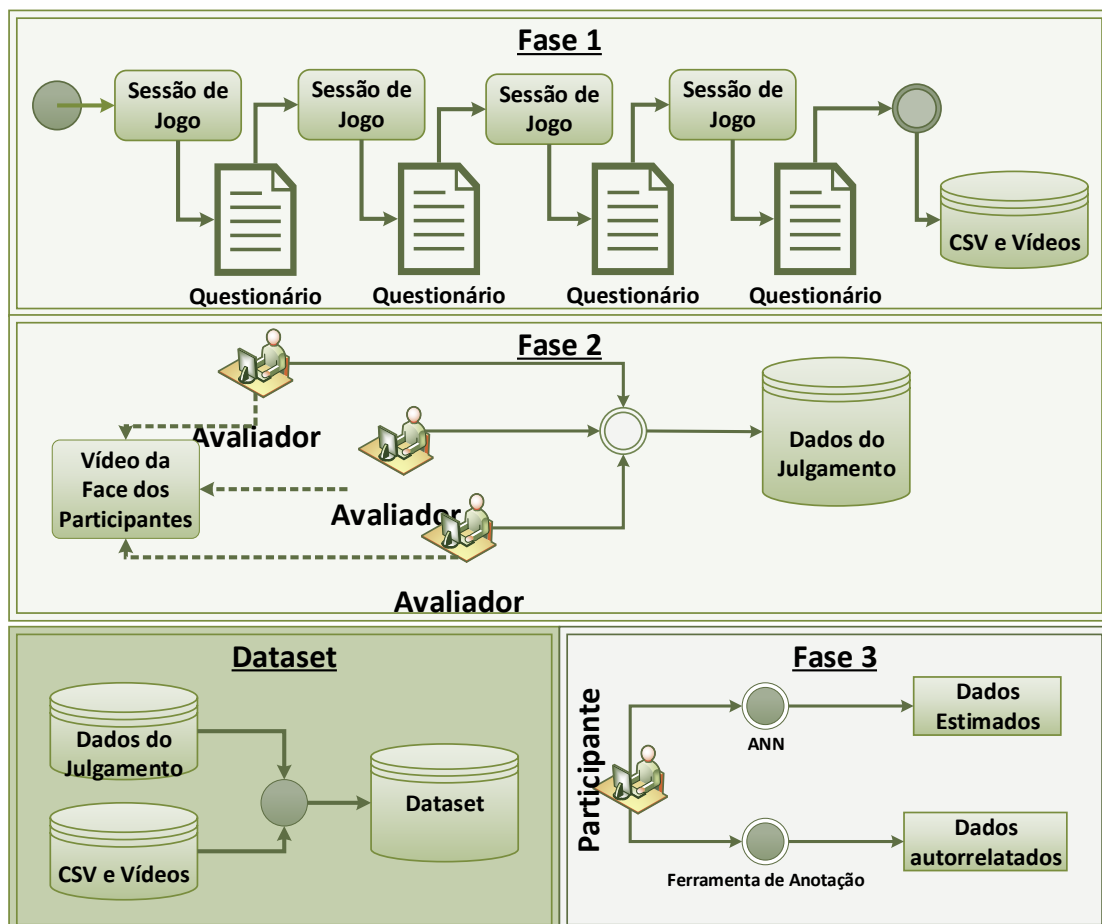
4.3 Visão Geral do Experimento

Para estimar a experiência emocional dos participantes durante a interação com jogo, foi realizado um conjunto de experimentos com dois grupos de participantes. Para manter a uniformidade do experimento, todos os participantes jogaram sobre as mesmas condições. A pesquisa foi dividida em três fases, como indicada na Figura 4.5. Na primeira, os dados psicofisiológicos foram coletados junto aos vídeos da face e do *gameplay*. Na segunda etapa

da pesquisa, um grupo de avaliadores da área da psicologia foi recrutado para analisar e julgar os vídeos da face dos participantes. Com base nas respostas dos avaliadores e dos dados psicofisiológicos, foi aplicado um conjunto de procedimentos para criar o *dataset* (detalhes na seção 4.4). Na terceira parte do estudo, foi possível aplicar e validar o modelo de predição que estima a emoção dos jogadores. Ainda, na terceira fase, novos participantes foram convidados a jogarem o jogo, porém, entre as sessões de jogo, fo-lhes solicitado realizar autorrelato da sessão, usando a ferramenta de anotação de emoção junto ao questionário de experiência de jogo.

Com os dados coletados da terceira fase, foi possível realizar a comparação do modelo de predição desenvolvido com os dados obtidos pelo autorrelato e verificar se existe ou não diferença nos resultados obtidos utilizando as duas abordagens distintas (detalhes no capítulo 5).

Figura 4.5: Fases da Aplicação do Protocolo Experimental.



Fonte: Autor.

4.3.1 Participantes

O grupo de participantes do experimento foi composto por adultos (entre 18 a 32 anos, com média de 23.25 anos e desvio padrão de 3.36) voluntários que foram recrutados a partir de uma lista de e-mails e divulgação em redes sociais. Além disso, as características gerais dos participantes eram universitários e desenvolvedores de jogos, porém nem todos tinham experiência com jogos de corrida. Para melhor entendimento sobre a distribuição dos participantes em cada fase da pesquisa, veja a Tabela 4.1. Em especial, na segunda etapa da pesquisa, dezesseis estudantes de psicologia e dois psicólogos foram recrutados para analisar e julgar os vídeos das faces dos participantes.

Para cada participante da primeira e terceira etapa, foram atribuídos identificadores e os dados adquiridos foram tornados anônimos. Infelizmente, devido a problemas técnicos, a coleta de cinco participantes foram perdidas do estudo e seus dados foram descartados. Todos os participantes eram voluntários e não haviam recebido nenhuma contribuição monetária ou acadêmica para o experimento.

Tabela 4.1: Número de Participantes na Pesquisa

Fases do Experimento	Total (N+E)	N	Excluídos (E)	Masculino/Feminino
1	35	30	5	20/10
2	18	18	0	4/14
3	20	20	0	18/2

4.3.2 Jogo Utilizado

A presente pesquisa considerou a criação de um *dataset* afetivo a partir de um conjunto de dados fisiológicos baseado em um jogo digital. Focando somente na influência da mecânica do jogo e, evitando o efeito emocional de elementos narrativos (como, por exemplo, sequências cinematográficas), foi considerado um jogo do gênero de corrida (veja a Figura 4.6), chamado *The Open Racing Car Simulator* (TORCS)² [10]. Nesse tipo de jogos, os usuários partem de um ponto X e devem chegar a um ponto Y, geralmente dirigindo veículos, no menor tempo possível ou superando os adversários. Os jogos de corrida costumam ter um conjunto de eventos bem definidos, que podem despertar as emoções dos jogadores. De fato, os jogadores estão envolvidos em corridas de alta velocidade, nas quais normalmente podem ocorrer acidentes, ultrapassagens, curvas de alta velocidade etc. Sendo assim, hipotetizamos uma alta variabilidade das emoções dos jogadores durante um jogo

²<http://torcs.sourceforge.net/>

de corrida e, como consequência, um maior espectro de emoções discretas para construir o *dataset*. Outro ponto a ser considerado na escolha do jogo foi a facilidade em alcançar uma alta repetibilidade e um alto nível de envolvimento entre os participantes. Por fim, outros aspectos no contexto da jogabilidade foram considerados na seleção do jogo:

- Ele possui uma mecânica de jogabilidade rica, que proporciona situações emocionalmente diferentes aos participantes;
- Este jogo é um projeto *open source*, logo, foi possível implementar algumas mudanças no jogo, como obter registros gerais (*log*) do jogo;
- Um jogo utilizado em diversas pesquisas acadêmicas e com validação científica;
- O jogo é intuitivo, portanto a experiência do jogo pode ser mantida a mais homogênea possível entre os sujeitos envolvidos no experimento.

Figura 4.6: Captura de Tela do Jogo.



Fonte: Torcs [10].

4.3.3 Procedimento Experimental

Primeiramente, os participantes eram convidados a sentar em uma cadeira e colocar a pulseira *Empatica E4* no braço não dominante. Eles eram informados sobre a pesquisa e o experimento e, logo após, eram convidados a ler e assinar um Termo de Consentimento Livre e Esclarecido (TCLE) (Anexo 2), além da permissão de liberação de uso de vídeos e imagens registradas das sessões para fins de pesquisa acadêmica. Os dados adquiridos foram coletados anonimamente, e cada participante tinha um identificador para facilitar o processo de reconhecimento durante a análise de dados.

A configuração experimental consiste em quatro estágios (vistos na Figura 4.1):

- Preparar o participante;
- Ajustar os equipamentos para a captura de dados;
- Interagir com jogo;
- Realizar o autorrelato da sessão.

Antes de começar as sessões de jogo, os participantes jogavam uma sessão teste para conhecer os comandos e o ambiente do jogo. Terminando essa apresentação, eles eram instruídos a relaxar por quatro minutos, enquanto a linha base com relação às medidas fisiológicas era registrada. Além disso, com intuito de atenuar o efeito do observador [124], em cada fase do experimento, os pesquisadores envolvidos eram posicionados em uma área pré-definida fora do campo de visão do participante. Eles também evitaram qualquer tipo de interação ou observação durante as diferentes fases experimentais. Foi solicitado ao participante que reduzisse o contato com a equipe de pesquisadores e relatasse apenas problemas técnicos.

O experimento consistiu em quatro sessões de jogo, tendo, cada uma delas, em média, aproximadamente, cinco minutos de duração. De modo a reduzir os potenciais efeitos de transmissão que afetam a coleta de dados, foi avisado aos participantes que evitassem levantar da cadeira ou movimentos bruscos com braço em que pulseira estava posicionada. Ainda, as sessões possuíam configurações diferentes, desde câmbio, *drift* e formato das pistas, como descrito abaixo:

Sessão 1 Pista oval com *drift* desabilitado e com câmbio automático

Sessão 2 Pista com poucas curvas com *drift* habilitado e com câmbio automático

Sessão 3 Pista com poucas curvas com *drift* habilitado e com câmbio manual

Sessão 4 Pista com muitas curvas com *drift* desabilitado e com câmbio manual

Vale ressaltar que o número de oponentes e o nível de dificuldade do jogo foram constantes em todas sessões. O modelo do carro foi o mesmo para todos os participantes. É importante notar que a ordem das sessões foram aleatorizadas para cada participante com o objetivo de reduzir os efeitos da aprendizagem durante o experimento, conforme feito em Guardini e Maninett [118].

Uma vez que a pulseira é colocada no participante para medir as atividades fisiológicas, era solicitado pôr o fone de ouvido para garantir uma melhor experiência pelo som produzido pelo jogo (Veja Figura 4.7). Após essa primeira etapa de preparação, os vídeos

(da face e da tela do jogo) e os sinais fisiológicos eram gravados durante a sessão de jogo. O protocolo experimental foi gerenciado por um *script* executado no computador, que iniciava cada sessão de jogo e sincronizava todas as fontes de dados. No final de cada sessão, os dados eram exportados em um arquivo CSV.

Figura 4.7: Participante durante o procedimento experimental.



Fonte: Autor.

Os dados psicofisiológicos foram registrados durante as sessões de jogo em todos os participantes incluídos na fase 1 e 3 da pesquisa. Adicionalmente, no final de cada sessão, o participante realizava o preenchimento de um questionário de experiência de jogo (Apêndice A). Porém, somente na fase 3, após cada procedimento, o participante era designado a realizar o autorrelato da sua experiência de jogo usando uma ferramenta de anotação (veja Figura 4.4). Apesar de informativo, alguns experimentos tiveram problemas logísticos: i) uso incorreto do sensor; ii) Alguns participantes (cinco na fase 1) pararam o experimento, conseqüentemente, foram excluídos da etapa da análise de dados devido ao ruído de dados gerados.

O tempo total de um experimento completo era em torno de 20 minutos, dividido em quatro sessões de cinco minutos na fase 1, enquanto na fase 3, o experimento durava em torno de 120 minutos, 20 minutos das quatro sessões e 100 minutos dos quatro autorrelatos (25 minutos em média cada um).

4.4 Criação do Dataset Afetivo

Esta seção descreve a segunda fase da pesquisa, que corresponde o fluxo da Figura 4.1 (No centro). Durante essa fase, foram convocados 18 avaliadores (2 psicólogos e 16 estudantes de psicologia), que visualizaram os registros das sessões e anotaram as emoções induzidas a partir dos eventos significativos durante a interação com jogo. Além disso, nessa fase, foi necessário desenvolver uma ferramenta de anotação de emoção (veja Figura 4.4), que permite o julgamento das emoções a partir do vídeo da face dos participantes e registra os eventos do jogo. A ferramenta é intuitiva e pode ser usada em qualquer sistema operacional e teve como base o trabalho feito por Drioli e Foresti [35], com algumas adaptações:

- Utilizando uma lista de emoções para ambientes de entretenimento [55] e uma lista de eventos (apresentadas na seção 4.2.2);
 - Um ponto importante é a flexibilidade da ferramenta permitir adicionar novos elementos na listagem de emoções e eventos.
- Utilização de duas telas, uma para face do participante e a outra para *gameplay*. Ambas podem ser recolhidas ou expandidas.
 - A ferramenta permite recolher ou esconder uma tela para que o usuário possa focar em um único vídeo.

Após o processo de anotação de emoção pelos avaliadores, os dados foram analisados em dois níveis de granularidade:

- O primeiro nível consistia em 35 classes de emoções.
- O segundo nível com 8 classes de emoções: raiva (*Anger*), desgosto (*Disgust*), medo (*Fear*), ansiedade (*Anxiety*), tristeza (*Sadness*), desejo (*Desire*), calma (*Calm*) e felicidade (*Happiness*) como descrito em Harmon-Jones et al. [55].

Todas as sessões foram analisadas considerando os dois níveis de granularidade. Cada sessão foi verificada por três avaliadores e, em média, cada um deles levava seis minutos para analisar e anotar cada vídeo. Ainda, a taxa de concordância entre eles foi computada usando o **coeficiente de concordância de Kappa** [53]. Somente as sessões com o coeficiente acima de 0.6 foram selecionadas para análise. Como esperado, usando o segundo nível de granularidade, resultou-se uma maior taxa de concordância entre os avaliadores, como pode ser visto na Tabela 4.2.

Como pode ser visto na Tabela 4.2, a sessão 1 com o segundo nível de granularidade teve a maior taxa de concordância entre os avaliadores e, considerando esse caso, a média

Tabela 4.2: Taxa de concordância entre avaliadores com os diferentes níveis de granularidade.

Inter-rater agreement (Média)				Número de Classes
Sessão 1	Sessão 2	Sessão 3	Sessão 4	
0.33	0.22	0.29	0.17	35
0.81	0.69	0.63	0.65	8

para as quatro sessões foi de 69.5%. Levando em conta o primeiro nível de granularidade, observa-se que é difícil obter uma taxa de concordância razoavelmente aceitável, na qual o espectro de emoções é diversificado.

Com análise de concordância feita, o número de amostras das emoções “felicidade” (*Happiness*), “calma” (*Calm*), “tristeza” (*Sadness*) e “raiva” (*Anger*) foram adequadas para o desenvolvimento do *dataset*. Enquanto “desgosto” (*Disgust*), “medo” (*Fear*), “ansiedade” (*Anxiety*) e “desejo” (*Desire*) foram removidas do *dataset* devido a baixa ocorrência, fato que desencadearia eventuais problemas durante o treinamento do modelo. O presente *dataset* utilizou somente as classes “felicidade”, “calma”, “tristeza” e “raiva” de emoções, em que o número de amostras para cada emoção foram 210, 180, 170, e 100, respectivamente.

A estrutura geral do *dataset* corresponde a um conjunto de *features* associadas às classes de emoções, como pode ser visto na Tabela 4.3. Um ponto importante é que os dados são coletados continuamente ao longo do tempo, logo, para converter tempo contínuo para discreto, os dados foram segmentados em janelas de tempo (*time windows*) de 10 segundos, em que cada janela é constituída em um registro do *dataset*. As *features* de entrada para cada janela compreendem aos dados pré-processados das expressões faciais, GSR e BVP (etapa descrita na seção 4.5). A coluna *Emotional Experience* representa a emoção naquele instante de tempo e é a classe que irá compor a saída do modelo (veja a seção 5.2).

Tabela 4.3: Um exemplo de uma amostra exibindo a entrada para um intervalo de 10s, com evento de jogo, a emoção anotada pelos avaliadores, classe emocional e as *features*.

Player	Session	Interval Initial	Interval Final	Game Event	Rater 1	Rater 2	Rater 3	Emotional Experience	Features
1	1	1567638246.95	1567638256.95	Colision	Anger	Anger	Anger	Anger
1	1	1567638256.95	1567638266.95	Drifting	Calm	Calm	Joy	Calm
....

4.5 Análise de dados

Após a coleta dos dados psicofisiológicos e das informações com respeito ao julgamento de cada participante, foi realizada a análise dos dados para a construção do *dataset* e do modelo de reconhecimento de emoções. Em particular, a análise consistiu em quatro pontos específicos:

Filtragem, Normalização e Segmentação: Essa etapa é responsável em: i) remover os ruídos produzidos pelo sensor e a câmera; ii) redimensionar um ou mais atributos; iii) quebrar dados em janela de tempo (*time window*).

Extração de Características: Essa etapa obteve um conjunto de características a partir dos sinais tratados da etapa anterior utilizando bibliotecas de biosinais;

Redução de Características: Essa etapa seleciona as características mais relevantes para modelo. A consequência direta dessa etapa é no tempo de treinamento e na precisão do modelo;

Predição dos dados: Essa etapa define um modelo capaz de inferir as emoções dos jogadores de acordo os eventos relevantes do jogo.

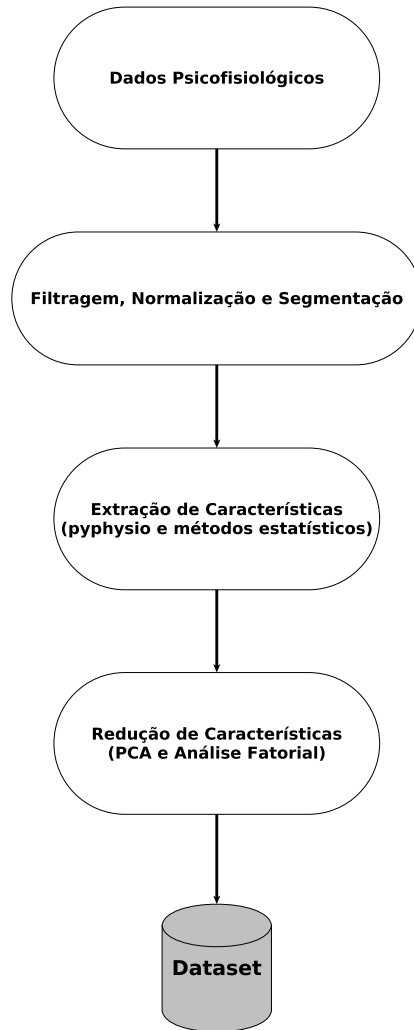
O processo de amostragem dos três sinais analisados (BVP, GSR e expressão facial) produziu uma grande quantidade de dados. A pesquisa contou com 50 participantes no total (fase 1 e fase 3). Em termos de tempo, eles tiveram 1000 minutos com a interação com jogo, 800 minutos em termos de registro de dados psicofisiológicos (excluindo erros), 600 minutos de registro de autorrelato (entrevistas, questionário pós-sessão e autoavaliação usando ferramenta de anotação). As próximas subseções apresentam em detalhes as etapas de pré-processamento, que correspondem as etapas ilustradas na Figura 4.8.

4.5.1 Filtragem, Normalização e Segmentação dos dados

Para corrigir e sincronizar as taxas de amostragem de cada sinal, foi necessário realizar uma nova reamostragem dos sinais com o uso de uma biblioteca de processamento de sinais psicofisiológicos chamada *pyphysio* [14]. Para cada sinal psicofisiológico, foi necessário realizar um conjunto de procedimentos a fim de tratá-los e usá-los adequadamente nas etapas seguintes. Cada sinal foi tratado da seguinte maneira:

Galvanic Skin Response: Foi utilizado um filtro convolucional para remover ruídos. Além disso, a intensidade do GSR gera uma alta variabilidade individual, causando certos problemas no momento de comparação entre os sujeitos da pesquisa. Logo,

Figura 4.8: Diagrama de bloco representando a cadeia de tratamento dos dados.



Fonte: Autor.

para resolver essa questão da variabilidade entre os indivíduos, foi realizado o procedimento de normalização do sinal por meio da equação 4.1[107].

$$Signal_{normalized} = \frac{Signal_t - Signal_{min}}{Signal_{max} - Signal_{min}} \quad (4.1)$$

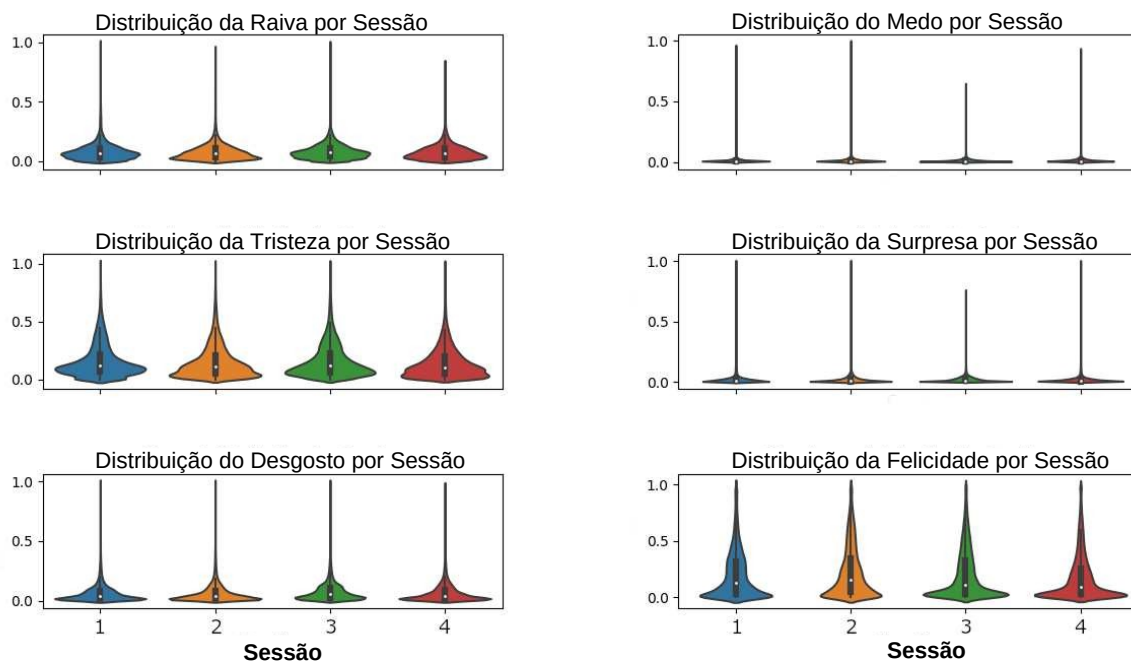
Foi extraída a resposta fásica a partir do sinal, o qual está relacionado com sistema nervoso simpático [8]. As características extraídas e selecionadas (*features*) desse sinal nesse trabalho foram no domínio do tempo (*time domain*) e as estatísticas também, que podem ser vistas na Tabela 4.4.

Blood Volume Pulse: Foi usado o algoritmo de otimização combinatorial reverso (*reverse Combinatorial Optimization*) [15] para filtragem do sinal. Com relação à normalização deste sinal, foi computado da mesma maneira que o GSR, usando a

equação 4.1. Além disso, as características estatísticas e do domínio do tempo foram extraídas para análise, que podem ser vistas na Tabela 4.4. Mais detalhes sobre elas, podem ser vistas em [84].

Expressão Facial: Para coletar e extrair informações relevantes dos vídeos da face dos participantes, foi utilizado o algoritmo desenvolvido por Viera [146]. O mecanismo de rastreamento de face é baseado no algoritmo de Viola-Jones para coletar as imagens da face do vídeo dos jogadores e uma variação do algoritmo *Active Appearance Model* (AAM) para rastrear os pontos de interesse na face. Além disso, foi desenvolvido um classificador SVM (*Support Vector Machine*) que fornece uma estimativa de emoções prototípicas (tristeza, medo, surpresa, raiva, felicidade e desgosto), que são convertidas em dois sinais básicos que representam os aspectos negativos e positivos no processo de detecção de emoção. A Figura 4.9 apresenta a distribuição das emoções prototípicas coletadas em todas as sessões de jogo da fase 1. Segundo a Figura 4.9, foi identificado que algumas emoções possuem o mesmo comportamento entre sessões.

Figura 4.9: Distribuição das emoções prototípicas entre as sessões do jogo.



Fonte: Autor.

4.5.2 Extração e Seleção de Características

Foram processados três sinais psicofisiológicos: Blood Volume Pulse, EDA e as expressões faciais. Os picos do BVP estão associados à atividade cardíaca, então esse sinal é usado


para extrair as distâncias entre batimentos consecutivos (conhecido como *Interbeat Interval (IBI)*). Logo, analisar o HRV, associado à atividade regulatória do sistema nervoso autônomo (ANS). Esse processo de extração do IBI a partir do BVP foi feito usando algoritmo DBD-RCO [15].

O sinal do EDA é associado ao SNA, visto que o aumento da atividade secretora das glândulas sudoríparas provoca crescimento da condutividade da pele, logo a resposta fásica pode ser estimada a partir dos sinais derivados do EDA pelo processo de decomposição visto em Benedek e Kaernbach [9].

Para as expressões faciais, foi aplicado a ANOVA (análise da variância) sobre cada emoção prototípica cuja finalidade foi determinar se existe diferença estatisticamente significativa entre as médias da sessão. Como resultado, “Fear” (Medo) ($F_{statistic} = 0.06$, $p-value = .98 > .05$), assim como “Surprise” (Surpresa) ($F_{statistic} = 0.015$, $p-value = .99 > .05$) possuem a mesma média entre as sessões. Como mostrado na Figura 4.9 usando gráfico de violino, ambas as emoções prototípicas possuem densidades relativamente pequenas. Deste modo, para a proposta da análise, ambas as emoções foram removidas deste experimento. Ainda, com a finalidade de reduzir o número de dimensões deste conjunto prototípico, para minimizar a perda de informação, foi escolhido utilizar **Análise Factorial**, por ser um método rápido, robusto e preciso para essa finalidade (Para mais detalhes sobre técnica, veja Cattell [23]). O processo de reduzir o número de dimensões usando a análise factorial é baseado em dois aspectos: *kaiser criterion* (KC) e o teste *Kaiser-Meyer-Olkin (KMO)*. O primeiro é baseado na proporção mais significativa da variância pelo fator que será selecionado, então o *eigenvalue*³ se torna um excelente indicador para determinar o número de fatores. Em geral, um *eigenvalue* > 1 será o critério para seleção de fatores. A Figura 4.10 apresenta a representação visual dos *eigenvalues* pela quantidade de fatores, mostrando que o número de fatores adequados são dois. Enquanto a segunda medida, KMO, tem como finalidade verificar se os dados estão adequados para o uso da análise factorial, quer dizer, se ele define adequabilidade de cada variável observada. Desta forma, os valores do KMO variam entre 0 e 1, sendo que valores menores que 0.6 são considerados inadequados. Neste estudo, foi identificado um KMO com o valor de 0.75.

³Variância explicada pelo fator a partir da variância total [23].

Figura 4.10: Scree plot mostrando a escolha do número de fatores.



Fonte: Autor.

Com base nos resultados da análise factorial, foram combinados raiva (“Anger”), desgosto (“Disgust”), e tristeza (“Sadness”) em um único fator chamado de **Emoção Negativa**, e “Happiness” sendo chamado de **Emoção Positiva**. Para esse dois fatores encontrados, foi possível extrair características estatísticas.

Após a etapa anterior, foi observado que algumas características estão fortemente relacionadas. Essas não são adequadas para próxima etapa, no caso, o processo de classificação da experiência do jogador. Alguns autores [114, 145] aplicaram algoritmos de seleção de características, como PCA (*Principal Component Analysis*), com a finalidade de filtrar essas características redundantes e fortemente relacionadas. Usando o PCA no conjunto de dados atual, foi possível eliminar 13 características de um total de 32. Finalmente, as características utilizadas para construção do modelo podem ser vistas na Tabela 4.4.

Tabela 4.4: Características extraídas a partir dos sinais coletados

Sinal	Característica
GSR	Mean, Range, Standard deviation, Mean peaks amplitude, mean slope, Maximal peak amplitude, Peak slope, Peak duration, Number of peaks
BVP	RRmean, RRSTD, RMSSD, pNN50, pNN25, pNN10, triang, TINN, SD1, SD2, SD12, DFAa1, DFAa2
Expressão Facial (Positiva e Negativa)	Maximum, Minimum, Mean, Range, Standard deviation

Capítulo 5

Modelo Proposto

5.1 Escopo

Esta seção apresenta os detalhes técnicos da arquitetura do modelo reunidos com as informações pertinentes da etapa de treinamento e a validação do modelo. Fornece informações da escolha do algoritmo de rede neural, mostrando um conjunto de informações sobre outros algoritmos de *machine learning*, justificando a escolha do respectivo algoritmo. Além disso, fornece os principais resultados gerados pelo modelo proposto e pelo método de autorrelato, fazendo uma comparação com ambas as abordagens através de gráficos e o uso do coeficiente de correlação com a finalidade de comparar as diferentes amostras coletadas de ambas as abordagens.

5.2 Detalhes da Arquitetura do Modelo

Considerando apenas as *features* adquiridas pelo processo de seleção e de extração apresentado na seção 4.5, testamos diferentes técnicas de aprendizado supervisionado para verificar qual delas teve o melhor desempenho sobre o conjunto de dados de natureza não linear. A Tabela 5.1 apresenta os resultados dos diferentes modelos de classificação testados, de modo que a rede neural artificial (*artificial neural network* - ANN) foi escolhida por apresentar o melhor desempenho entre os demais algoritmos. Os resultados apresentados na Tabela 5.1 mostram as configurações finais de cada modelo após as diversas permutações das configurações dos parâmetros.

A respectiva rede neural é formada por 183 neurônios distribuídos em quatro camadas (com duas camadas escondidas) e número de neurônios de entrada corresponde ao número de variáveis. Para que houvesse uma estimativa correta do desempenho do modelo, foi aplicado processo de validação cruzada com 10CV. A arquitetura da rede neural é descrita a seguir:

Tabela 5.1: Configurações dos Modelos de Classificação

Modelo	Configurações	Acurácia
<i>Decision Tree</i>	max_features = 27, criterion = 'gini', min_samples_split = 10, min_samples_leaf = 30	60%
SVM	'C' = 100, 'gamma' = 0.001, kernel = 'rbf'	63%
KNN	n_neighbors = 30, weights = 'distance', metric = 'euclidean'	58%
Rede Neural	Learning_rate = 0.001, momentum = 0.9	64%

- Durante o trabalho de pesquisa, diferentes números de camadas escondidas bem como em termos de quantidade e distribuição foram testados. Os melhores resultados foram alcançados com duas camadas escondidas com 80 neurônios cada uma. A tabela 5.2 apresenta as diferentes configurações de rede neural analisadas neste trabalho.

Tabela 5.2: As diferentes configurações da rede neural

Nº de Camadas Escondidas	Taxa de Aprendizagem (<i>Learning rate</i>)	Neurônios na Camada Escondida	Precisão (<i>Accuracy</i>)
1	0.1	10	39%
2	0.1	10-10	43%
2	0.01	25-25	55%
2	0.001	35-35	57%
2	0.001	70-70	60%
2	0.001	80-80	64%
3	0.01	55-55-55	58%
3	0.001	70-70-70	61%

- Conjunto de treinamento e teste foram criados para construção da rede neural. O primeiro conjunto teve a finalidade de construir o modelo de acordo com os ajustes dos parâmetros, enquanto o segundo foi utilizado para avaliação do modelo.

Conforme os estudos feitos por Larose [77], a presente pesquisa utilizou 75% dados coletados para treinar o modelo, enquanto 25% para a avaliação deste.

- O procedimento de aprendizagem foi implementado utilizando algoritmo de *back-propagation*. Para ajustar o algoritmo, dois parâmetros foram utilizados: taxa de aprendizagem (*learning rate*) e *momentum*. Nessa etapa, ambos foram definidos em 0.001 e 0.9, respectivamente. Além disso, foram necessários 1000 épocas para treinamento do modelo.
- A função de treinamento para a otimização de pesos para rede foi SGD (*Stochastic Gradient Descent*) e a função de ativação consistiu na tangente hiperbólica ($\varphi(x) = \tanh(x)$) nas camadas escondidas.
- Na camada de saída, o número de neurônios é definido como o número de saídas do sistema. Neste caso, quatro neurônios foram necessários para fornecer as estimativas em termos de probabilidade da experiência emocional associada a experiência do jogador, medidas em termos de: calma (*Calm*), felicidade (*Happiness*), raiva (*Anger*) e tristeza (*Sadness*).
- Para validar o desempenho da classificação do modelo, foi utilizada uma matriz de confusão (veja Figura 5.1). Para o conjunto de teste, uma baixa precisão foi obtida para “Anger” de 50%, enquanto para “Happiness” foi alcançada uma alta precisão de 90%. Outras métricas gerais foram reportadas: *Precision* (0.71), *Recall* (0.70) e *F1-Score* (0.69). Por fim, a medida chi-quadrado foi computada para determinar se o modelo de classificação está adequado e teve como resultado ($\chi^2 = 2.27$, $p\text{-value} = 0.13 > 0.05$), em outras palavras, para um $p\text{-value} > \alpha$, pode-se confiar que nossas expectativas correspondem bem aos dados reais.

5.3 Validação do Modelo

Para analisar a efetividade do modelo proposto, foram utilizados novos dados obtidos de 20 participantes que não participaram do processo de geração do modelo. Os novos dados passaram pelos mesmos métodos apresentados na seção 4.5. Os dados autorrelatados foram produzidos usando a ferramenta de anotação (Figura 4.4). Para a validação, os resultados gerados pelo modelo foram comparados com os resultados do autorrelato gerados pela ferramenta de anotação. Nesse caso, os efeitos mostram a experiência emocional dos participantes para os eventos mais relevantes das sessões do jogo.

O processo de comparação foi estruturado por meio do **grau de concordância** entre autorrelato com as emoções estimadas pelo modelo. Para facilitar o processo de comparação, esta pesquisa definiu um indicador chamado **Score** como uma porcentagem das




Figura 5.1: A matriz de confusão para modelo de classificação

emoções dos participantes para ambas as abordagens. Para efeito de investigação, foram selecionados três eventos que aconteceram com bastante frequência nas sessões de jogos: Colisão (*Collision*), Câmbio (*GearBox*) e *Drifting*. A fim de determinar com que precisão os dados estimados (as respostas produzidas pelo modelo) se assemelham aos dados relatados pelos participantes, foi adotado coeficiente de correlação de Spearman (ρ) de modo a correlacionar as duas amostras de dados para cada evento de jogo. A justificativa de usar esse coeficiente é dada por ser um indicador não paramétrico da monotonicidade de relação entre duas amostras, geralmente usado para os dados que não são normalmente distribuídos [101].

A Figura 5.2 apresenta os resultados da comparação da abordagem do autorrelato com modelo para o evento de colisão. Alguns participantes ficaram calmos durante acontecimento do evento, enquanto outros reportaram raiva, indicando que o *Score* tanto para “Calma” quanto para “Raiva” estão em concordância conforme as abordagens aplicadas vistas na Figura 5.2. A porcentagem de jogadores que reportou por meio do autorrelato a emoção “Calma” foi de 30.46%, enquanto o modelo estimou 29.44%. Para “Raiva”, o valor reportado foi de 17.88%, enquanto o valor estimado pelo modelo foi de 16.56%. Para a experiência emocional de “Tristeza”, não houve uma concordância tão expressiva como nos casos anteriores, porque os valores reportados e estimados foram de 38.41% e 32.07%, respectivamente. Esse fato pode ser justificado por conta do modelo ter detectado muitas ocorrências de “falsa felicidade” devido aos sorrisos irônicos produzidos pelos participantes durante as colisões, resultando no aumento na detecção de “Felicidade” no modelo,

enquanto, no autorrelato, foi identificado como um momento de raiva, conseqüentemente, reduzindo a precisão para a experiência emocional do modelo com relação à “Tristeza”. Essa classificação incorreta traz forte efeito sobre coeficiente de correlação ($\rho = 0.80$, $p\text{-value} = .2$). Desta forma, excluindo esse comportamento não pertinente e recomputando ρ para as outras emoções, alcançamos um coeficiente de correlação relativamente alto ($\rho = 0.99$, $p\text{-value} < .05$). Os casos de sorriso irônico podem ser um interessante tópico de pesquisa em trabalhos futuros.




Figura 5.2: Comparação dos resultados do autorrelato com o modelo em eventos de “Colisão” (*Collision*).

A Figura 5.3 apresenta os resultados da comparação da abordagem do autorrelato com modelo para o evento de câmbio. Para esse caso, existe uma correlação significativa para as duas abordagens ($\rho = 0.94$, $p\text{-value} < .05$). Acredita-se que as configurações das sessões com relação ao câmbio estimularam as emoções consistentemente. Considerando as sessões 1 e 2 com pistas com poucas curvas sem muito esforço na tarefa de troca de marchas, claramente as experiências emocionais de “Calma” e “Felicidade” foram fortemente detectadas por ambas abordagens. O modelo estimou que 23.92% dos jogadores sentiram “Calma” e o autorrelato com 23.81%, mostrando uma concordância forte para essa emoção. Para experiência emocional de “Felicidade”, foi estimada 20.82% contra

19.05%. Um ponto importante é que as emoções negativas estão mais associadas às sessões 3 e 4, que exige do jogador uma maior habilidade no uso do câmbio, proporcionando, de certa forma, mais estresse cognitivo ao participante, aumentando **Score** tanto para “Raiva” quanto para “Tristeza”. O modelo estimou que os jogadores sentiram em torno de 27.73% e 27.54% para “Tristeza” e “Raiva”, respectivamente. Enquanto o autorrelato aferiu 28.57% para ambas experiências emocionais.

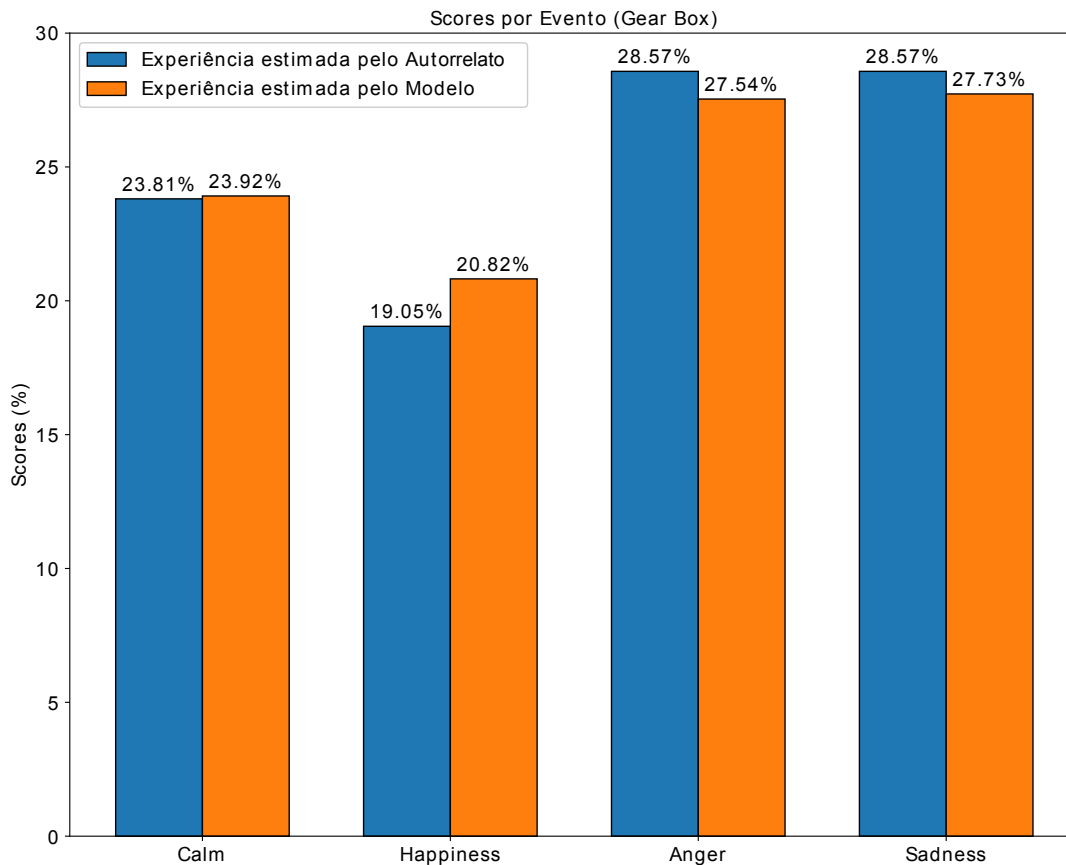


Figura 5.3: Comparação dos resultados do autorrelato com o modelo em eventos de “Câmbio” (*Gear Box*).

A Figura 5.4 apresenta os resultados da comparação da abordagem do autorrelato com modelo para o evento de *Drifting*. Segundo coeficiente de Spearman, existe uma alta correlação entre experiência estimada pelo modelo e o autorrelato ($\rho = 0.99$, $p\text{-value} < .05$). A baixa menção de “Raiva” e “Tristeza”, a partir dos dados reportados pelo autorrelato, reforçam a baixa estimativa detectada pelo modelo. As experiências emocionais de “Raiva” e “Tristeza” tiveram uma taxa de 12.33% e 14.05% estimada pelo modelo, enquanto, para o autorrelato, foram de 8.00% e 16.00%, respectivamente. Como mostrado pela Figura 5.4, a experiência emocional de “Raiva” foi superestimada pelo modelo. A diferença percentual aparentemente grande em relação à experiência relatada por meio do autorrelato se deve à baixa quantidade de participantes com essa emoção. De fato,

os participantes relataram que, ao realizar o movimento de *Drifting*, eles sentiram um profundo sentimento de satisfação e aumento da confiança durante a interação com jogo. Fato esse constatado pelo alto **Score** da experiência emocional de “Felicidade”, estimada pelo modelo em 49.42% e 48.00% constatado pelo autorrelato. Por fim, a experiência emocional de “Calma” teve por meio do autorrelato valor de 28.00%, enquanto 23.90% estimada pelo modelo.




Figura 5.4: Comparação dos resultados do autorrelato com o modelo em eventos de *Drifting*.

Capítulo 6

Considerações Finais

6.1 Escopo

O objetivo deste capítulo é discutir os resultados obtidos na seção 5.3 e comparar com as principais pesquisas mostradas na seção 3.4, que estão dentro do contexto do presente estudo. Além disso, o capítulo finaliza com as conclusões e os possíveis trabalhos futuros.

6.2 Discussão

Nesta pesquisa, apresenta-se um *dataset* afetivo baseado na aquisição de sinais psicofisiológicos a partir de um jogo digital. O presente trabalho forneceu uma visão geral do protocolo experimental desde a coleta até o detalhamento da criação da rede neural. Os dados coletados, psicofisiológico e autorrelatados, foram derivados dos participantes que jogaram um jogo de corrida em quatro configurações diferentes. Além disso, foi fornecida uma análise relevante de cada sinal para que fosse viabilizado o desenvolvimento do *dataset*. Por fim, detalhes na criação da rede neural foram apresentados para que o modelo realizasse a predição da experiência emocional com certa precisão. Os resultados confirmam a validade da pesquisa, em que o modelo obtido consegue apresentar concordância parcial com os resultados obtidos com autorrelato.

Essa tese conduziu um estudo detalhado do estado da arte (capítulo 3) e resumizou os principais trabalhos na avaliação da experiência do jogador na Tabela 6.1. Esses estudos foram os que usaram dados psicofisiológicos a partir de biosensores. A estrutura da Tabela 6.1 apresenta os autores do trabalho com ano da publicação, os sinais psicofisiológicos utilizados na pesquisa, classes emocionais inferidas, algoritmo e os resultados em termos de acurácia no reconhecimento das emoções.

O modelo de classificação desenvolvido no presente trabalho é baseado em três sinais psicofisiológicos e foi treinado com um *dataset* de expressões emocionais anotadas por

Tabela 6.1: Principais trabalhos na avaliação da Experiência do Jogador que utilizaram sinais psicofisiológicos.

Autores)	Sinais	Emoção	Método	Resultados (%)
Trabalho Atual	Expressão Facial, BVP e GSR	Calma, Felicidade, Raiva e Tristeza	Rede Neural	64%
AlZoubi et al. (2021) [4]	BVP, ECG, EMG, EDA, Respiração e Expressão Facial	Felicidade, Medo, Ansiedade, Animado e Raiva	XGBoost	66.16%
Chanel and Lopes (2020) [24]	GSR	Tédio, <i>Flow</i> e Ansiedade	Deep Neural Networks	73.2%
Maier et al. (2019) [83]	BVP and GSR	Tédio, <i>Flow</i> e Estresse	Deep Neural Networks	49%
Yang et al. (2018) [159]	GSR, ECG, EMG, Respiração, Temperatura e Expressão Facial	Raiva, Tédio, Medo, Frustração e Felicidade	SVM	65%
Tognetti et al. (2010) [142]	BVP, ECG, GSR, Respiração e Temperatura	Satisfação	KNN	70%
Mandryk and Atkins (2007) [88]	GSR, HR, EMG	Diversão, Desafio, Tédio, Frustração, Excitação	Fuzzy Logic	64%,22%,8%, 9.7%,52%

humanos, fornecendo acurácia média de 64%, com uma acurácia máxima de 90.91% para experiência emocional de “Felicidade”. Segundo os gráficos apresentados na seção 5.3, os resultados produzidos pelo modelo em relação aos do autorrelato resultaram em taxas de emoções próximas às relatadas pelos participantes. Alguns casos excepcionais aconteceram, como erro de interpretação dos sorrisos irônicos como expressão de felicidade. Outro ponto importante é que algumas reações específicas podem estar relacionadas a aspectos culturais e a classificação deve ser mais refinada para levá-los em consideração. Uma maneira de reduzir o problema da questão anterior seria propor uma maior coleta de dados, considerando uma diversificação entre os participantes.

Esse trabalho descreve um protocolo experimental a partir da coleta de dados até a criação da rede neural artificial, como pode ser visto na Figura 4.1. A Tabela 6.1 mostra que a avaliação da experiência do jogador, a partir dos dados psicofisiológicos, não é um novo tópico de pesquisa, no entanto, a forma como os experimentos foram feitos no presente trabalho evidencia que a combinação do BVP, GSR e das expressões faciais processados por uma rede neural artificial treinada por um *dataset* afetivo anotado por especialistas pode produzir boas estimativas da experiência emocional do jogador durante interação com jogo. A adoção de um *dataset* afetivo produzido por meio de uma ferramenta de anotação de emoções discretas contribuiu para qualidade dos resultados obtidos. Uma situação difícil de quantificar é o número de melhorias no *dataset*, porém, dentro de um contexto de análise qualitativa, o fato de especialistas conhecerem os tipos de emoções produzidas por um jogo de corrida permitiu construir um modelo junto com um *dataset* mais personalizado, melhorando a precisão do classificador. Contudo, os classificadores desenvolvidos conforme o protocolo adotado nessa pesquisa são menos portáteis entre os

diferentes gêneros de jogos, ou seja, a rede neural junto ao *dataset* afetivo não seriam eficientes para capturar a experiência do jogador em jogos de outra natureza, por exemplo, jogos de terror, pois as emoções dentro do *dataset* não contemplam as experiências emocionais vivenciadas nesse tipo de jogo.

A etapa de análise de dados vista na seção 4.5 teve a finalidade de melhorar a acurácia do modelo de predição. Mediante a natureza não linear do *dataset*, o valor de 64% alcançado pelo modelo é um resultado significativo e próximo dos trabalhos que utilizaram as mesmas abordagens e o número de classes emocionais vistos na Tabela 6.1, portanto esse modelo é capaz de generalizar bem com a entrada de novos dados. Um ponto importante a ser abordado é a existência do desbalanceamento entre as classes vista na Figura 5.1 que, parcialmente, explica os resultados obtidos pelo modelo. Considerando o contexto da indústria de jogos, o resultado parece ter potencial para ser aplicado como uma abordagem geral para avaliação da experiência do jogador, porque, para cada gênero de jogo, é gerado um conjunto de dados específico. Além disso, em termos de pesquisa científica, foi estabelecido um número de classes emocionais para que a classificação fosse viável e aumentasse a concordância entre os avaliadores.

A validação baseada no autorrelato dos participantes indicou que o modelo proposto pode classificar quatro estados de experiência emocional, mostrando concordância na maioria deles em relação aos eventos de jogo. Ademais, ao analisar as sessões por eventos, proporciona capturar informações mais precisas do que ao analisar a sessão como um todo, pois poderia não refletir a experiência real, uma vez que, durante uma sessão de jogo, ocorrem diferentes emoções devido à natureza dinâmica do jogo. Dessa forma, quando se pesquisa por evento, a abordagem consegue ajudar os desenvolvedores de jogos a identificar problemas na experiência do jogador que podem ser corrigidos ajustando o *game design*.

O algoritmo de *machine learning* proposto nesta pesquisa junto ao *dataset* afetivo avaliam com confiabilidade as emoções dos jogadores quando comparado ao autorrelato. Acredita-se que a abordagem utilizada nesse trabalho seja mais interessante em sessões de jogos longas, por conta do fato de que os participantes possuem dificuldades em lembrar de todos os eventos significativos durante a interação com jogo. No entanto, para as sessões curtas de jogo, é mais fácil para os jogadores fornecerem feedback útil com autorrelato.

6.3 Limitações

Durante os experimentos realizados nessa pesquisa, foram identificadas algumas limitações técnicas relacionadas com a coleta dos dados psicofisiológicos e algumas restrições que impediram alcançar melhores resultados na classificação. Primeiramente, no início

da pesquisa, foi utilizado o sensor Bitalino [13], todavia, esse sensor apresentou ser muito sensível ao movimento das mãos dos participantes durante as sessões de jogos, gerando elevados níveis de ruídos durante a coleta de dados, prejudicando a análise de dados. Com este problema técnico detectado, foi necessário adotar outro equipamento de coleta que pudesse contornar os problemas gerados pelo primeiro. Assim, adotou-se Empatica E4 [59], um dispositivo menos sensível ao movimento das mãos e que fornece um sistema de regularização de sinal, reduzindo, de fato, os ruídos durante a coleta de dados. Uma segunda limitação é que o alto nível de luminosidade do ambiente pode impactar fortemente na qualidade do vídeo da face dos participantes, conseqüentemente reduzindo precisão do sistema de processamento de imagens em virtude da inclusão de ruídos nos vídeos. O *dataset* desbalanceado é um fator que impacta na acurácia do modelo, logo, uma das soluções propostas a fim de melhorar a precisão do modelo é coletar dados de mais jogadores e trabalhar para gerar um *dataset* balanceado ou mais uniforme possível com relação as classes.

Outra limitação deste trabalho foi o uso de apenas um jogo, sendo que a dinâmica do jogo foi capaz de estimular somente quatro emoções, principalmente durante os eventos específicos do próprio jogo. Isso posto, com objetivo de estimar a emoção em outro jogo, será necessário realizar as etapas apresentadas na Figura 4.1. Além disso, nessa pesquisa, não foi considerado o fator cultural dos participantes durante os experimentos e não é possível confirmar se esse fator impacta nos resultados do modelo ou na construção do *dataset*.

6.4 Conclusões e Trabalhos Futuros

A proposta dessa tese de doutorado foi fornecer uma nova contribuição na área da computação afetiva e Game User Research (GUR). Em especial, a pesquisa explorou as emoções dos participantes durante a interação com jogo, em que foram usados diferentes métodos inspirados em diferentes estudos da psicologia, biometria e computação afetiva. Por conseguinte, essa tese teve uma abordagem transversal, que inclui diferentes campos de estudo, em que, no capítulo 2, foi levantado um background sobre a relação entre jogos digitais, biometria e emoções, e como medir o estado emocional dos jogadores. De uma maneira geral, a presente pesquisa analisou como um jogo pode elicitar um conjunto de emoções nos jogadores de acordo com as diferentes configurações do jogo, buscando relacionar diretamente os campos da fisiologia humana e das emoções e, como consequência, possibilitar uma avaliação da experiência emocional de forma adequada. Além disso, no capítulo 3, foram apresentados os principais trabalhos na área da avaliação da experiên-

cia do jogador que utilizam sinais psicofisiológicos, junto aos trabalhos de visualização e análise de dados no contexto de jogos.

No capítulo 4, foi detalhada a metodologia usada para criar o protocolo experimental adotado na pesquisa. Então foram apresentados os dados psicofisiológicos utilizados com os equipamentos usados na pesquisa, justificando os diferentes tipos dados adquiridos sobre os jogadores, além dos métodos aplicados na avaliação das emoções. Essa pesquisa apresentou uma arquitetura capaz de coletar diferentes fontes de dados (podendo ser escalável) para fornecer uma sincronização de dados robusta. Um software auxiliar foi desenvolvido a fim de auxiliar na coleta e sincronização de dados. Um segundo software (PDG_EX) foi codificado para auxiliar na visualização de dados (veja Figura 4.3). Ainda, a ferramenta de anotação de emoção foi desenvolvida (uma extensão do PDG_EX) com a finalidade de adquirir os valores do autorrelato pelos avaliadores e pelos jogadores (Figura 4.4). A ferramenta foi projetada para obter valores de emoções discretas, eventos de jogos e as anotações discretas sobre a sessão de jogo. Este mesmo capítulo descreve o estudo piloto conduzido em três etapas, em que a primeira consistiu sobre 30 participantes quando foram convidados a jogar um jogo de corrida e, durante as sessões, foram coletados os dados psicofisiológicos. Na segunda fase, foram selecionados 18 avaliadores para analisar as emoções dos jogadores a partir dos vídeos da face utilizando uma ferramenta de anotação. Posteriormente, uma subetapa de análise de dados foi executada para construção do *dataset* afetivo e a construção da rede neural. No capítulo 5, mostra-se a validação do modelo desenvolvido por meio de um novo grupo de participantes, de tal modo que o protocolo experimental é reproduzido integralmente.

A tese contribui para introduzir uma nova modalidade de avaliar a experiência do usuário, amplamente discutido na área de computação afetiva. Este documento pode contribuir para expandir as pesquisas na área do Game User Research (GUR), uma vez que os procedimentos aplicados nesta pesquisa pertencem ao estudo das medidas biométricas aferidas das atividades fisiológicas dos jogadores. Esse fato pode ser usado para entender que tipo de estado fisiológico um componente do jogo está produzindo, isto é, a emoção correspondente. Por exemplo, durante o teste beta de um jogo, os desenvolvedores podem identificar as áreas do jogo que involuntariamente induzem emoções indesejadas e, conseqüentemente, reprojeta-las. A partir dessa pesquisa, desenvolvedores podem trabalhar em um algoritmo para adaptação em tempo real da dificuldade do jogo com base nas emoções que o jogador está emitindo durante *gameplay*, ajudando a aumentar o engajamento dos participantes.

Essa pesquisa teve algumas contribuições pontuais:

- A definição de uma arquitetura de rede neural treinada utilizando um *dataset* afetivo que usa um jogo digital como estímulo. Este modelo alcançou uma precisão de 64%

de reconhecimento considerando quatro emoções, sendo que a experiência emocional de felicidade (*"happiness"*) teve melhor resultado em torno de 90% de precisão. Os resultados apresentados indicam que as fortes diferenças individuais das respostas fisiológicas afetam a classificação. Este mesmo fato pôde ser observado em AlZoubi et al. [4];

- A investigação de diferentes combinações de sinais psicofisiológicos e novas características (*features*) extraídas e não identificadas em trabalhos anteriores (veja a Tabela 4.4);
- A consolidação de um protocolo experimental para que pesquisadores e/ou desenvolvedores possam reproduzir todos os processos de forma integral. De fato, isso pode impactar em novas pesquisas científicas e o mercado de jogos, dando a possibilidade de um *Spin-off* para a avaliação das experiências do jogador, impactando diretamente o produto final.
- A criação de um *dataset* afetivo. Os dados coletados estão disponibilizados para outros pesquisadores no github¹. Todos os vídeos coletados neste estudo são estritamente confidenciais. Somente os pesquisadores responsáveis têm acesso a eles.

6.4.1 Trabalhos Futuros

O modelo desenvolvido pode ser melhorado por meio da realização de um estudo aprofundado de outros modelos de emoções, como o modelo circumplexo de afeto (usando as dimensões de *valence* e *arousal*). Para trabalhos futuros, mais esforço pode ser dedicado para encontrar novas *features* a partir de outros sinais psicofisiológicos, por exemplo, EEG, temperatura, respiração e rastreador ocular. Outro assunto que pode ser trabalhado é a construção de *datasets* usando diferentes *Times Windows* (15s, 20s, 25s, e 30s). Além disso, outros gêneros de jogos (por exemplo, jogos de terror) devem ser estudados, com o objetivo de analisar dados psicofisiológicos para reconhecer e criar novos *dataset* afetivos, possibilitando incluir novas emoções, tais como “medo”. Ainda, com a formação de novos *datasets* afetivos, é viável considerar implementação de outros modelos de classificação, como SVM, árvores de decisão, XGBoost, *deep learning*, entre outros.

Outra perspectiva que pode ser explorada em outras pesquisas seria realizar a análise dos perfis dos participantes. Verificar se existe alguma diferença entre as emoções derivadas de homens e mulheres. Se as emoções geradas pelos homens e mulheres impactam na construção do *dataset* ou do modelo de classificação. São importantes pontos que podem ser trabalhados em futuras pesquisas.

¹<https://github.com/eltonsarmanho/PGD-Ex>

Em uma futura extensão deste trabalho, ocorre a possibilidade de alterar o jogo de corrida utilizado no presente estudo e, com base nas *features* extraídas da pesquisa, este adaptará seu nível de dificuldade com base nas emoções dos jogadores (área conhecida como *Dynamic Difficulty Adjustment (DDA)* [24]), tentando manter o entretenimento dos jogadores em um padrão aceitável e exigido pela indústria de jogos.

Além disso, trabalhos futuros na área de avaliação da experiência do jogador abordarão alguns desafios:

- Projetar um ambiente integrado que reconheça os diversos sensores disponíveis no mercado (apresentados na seção 2.3.3 e utilizados em alguns trabalhos da seção 3.4) e que promova, de forma sistemática, o processo de sincronização das diferentes fontes de dados;
- Construir um *dataset* afetivo derivado de diferentes jogos que possa ser flexível e escalável no processo de avaliação da experiência do jogador com relação aos diferentes gêneros de jogos.
- Os modelos de predição são ligados aos participantes da sessão, uma vez que os modelos são treinados a partir dos dados coletados de cada jogador. Como consequência, os algoritmos de *machine learning* necessitam adquirir, para cada sujeito, os dados relatados para fornecer os rótulos emocionais (variável preditora) para o algoritmo em questão. Desta forma, uma opção que surge, durante o processo de criação do jogo, é a construção de elementos de gamificação que possam coletar os dados relatados pelos participantes a fim de reduzir custos operacionais com os avaliadores de emoções [28]. Uma possível abordagem seria a criação de um agente inteligente que pergunte/avalie as emoções dos jogadores em momentos significativos do jogo, após a identificação, e forneça uma recompensa ao jogador. A ideia anterior pode ser baseada no trabalho de Porcino et al. [120].

Este trabalho abre a perspectiva de introduzir modelos mais sofisticados de *machine learning* para avaliação da experiência do jogador. Esta pesquisa explora uma solução alternativa que nos permite avaliar a experiência do jogador sem usar qualquer abordagem tradicional (por exemplo, questionários e entrevistas). No entanto, a abordagem tradicional aliada a métodos automatizados (utilizando biossensores, expressões faciais, entre outros) pode tornar o processo de avaliação mais robusto e preciso.

Referências

- [1] *The Game Experience Questionnaire*. Technische Universiteit Eindhoven, 2013. 50
- [2] Ahsan, Md. R., Muhammad I. Ibrahimy e Othman O. Khalifa: *Emg signal classification for human computer interaction: A review*”, *European Journal of Scientific Research* ISSN 1450-216, páginas 480–501, 2009. 16
- [3] Alessandro, Canossa e Drachen Anders: *Patterns of play: Play-personas in user-centred game development*. Em *DiGRA 2009 - Proceedings of the 2009 DiGRA International Conference: Breaking New Ground: Innovation in Games, Play, Practice and Theory*. Brunel University, September 2009, ISBN ISSN 2342-9666. <http://www.digra.org/wp-content/uploads/digital-library/09287.49165.pdf>. 29
- [4] AlZoubi, Omar, Buthina AlMakhadmeh, Muneer Bani Yassein e Wail Mardini: *Detecting naturalistic expression of emotions using physiological signals while playing video games*. *Journal of Ambient Intelligence and Humanized Computing*, 2021, ISSN 18685145. <https://doi.org/10.1007/s12652-021-03367-7>. 85, 89
- [5] Ambinder, Mike: *Biofeedback in gameplay: how valve measures physiology to enhance gaming experience*, 2011. 15, 20, 21
- [6] Andrienko, Natalia e Gennady Andrienko: *Exploratory Analysis of Spatial and Temporal Data: A Systematic Approach*. Springer-Verlag New York, Inc., Secaucus, NJ, USA, 2005, ISBN 3540259945. 37
- [7] Bauckhage, C., K. Kersting, R. Sifa, C. Thureau, A. Drachen e A. Canossa: *How players lose interest in playing a game: An empirical study based on distributions of total playing times*. Em *2012 IEEE Conference on Computational Intelligence and Games (CIG)*, páginas 139–146, Sept 2012. 29
- [8] Benedek, Mathias e Christian Kaernbach: *A continuous measure of phasic electrodermal activity*. *Journal of Neuroscience Methods*, 190(1):80 – 91, 2010, ISSN 0165-0270. <http://www.sciencedirect.com/science/article/pii/S0165027010002335>. 16, 73
- [9] Benedek, Mathias e Christian Kaernbach: *Decomposition of skin conductance data by means of nonnegative deconvolution*. *Psychophysiology*, 47:647–58, março 2010. 75

- [10] Bernhard, Wymann, Espie Eric, Guionneau Christophe, Dimitrakakis Christos, Coulom Remi e Sumner Andrew: *TORCS, The Open Racing Car Simulator*. <http://www.torcs.org>, 2014. 66, 67
- [11] Bettadapura, Vinay: *Face expression recognition and analysis: The state of the art*. CoRR, abs/1203.6722, 2012. <http://arxiv.org/abs/1203.6722>. 26
- [12] Betts, J.G., P. Desaix, E.W. Johnson, J.E. Johnson, O. Korol, D. Kruse, B. Poe, OpenStax College, J. Wise, M.D. Womble *et al.*: *Anatomy & Physiology*. Open Textbook Library. OpenStax College, Rice University, 2013, ISBN 9781938168130. <https://books.google.com.br/books?id=dvVgngEACAAJ>. 14, 15
- [13] biosignals, Plux wireless: *Sensors - plux store*. <https://store.plux.info/15-BITalino-sensors>. (Accessed on 11/29/2016). 57, 87
- [14] Bizzego, Andrea, Alessandro Battisti, Giulio Gabrieli, Gianluca Esposito e Cesare Furlanello: *pyphysio: A physiological signal processing library for data science approaches in physiology*. SoftwareX, 10:100287, 2019, ISSN 2352-7110. <https://www.sciencedirect.com/science/article/pii/S2352711019301839>. 72
- [15] Bizzego, Andrea e Cesare Furlanello: *Dbd-rc0: Derivative based detection and reverse combinatorial optimization to improve heart beat detection for wearable devices*. bioRxiv, 2017. <https://www.biorxiv.org/content/early/2017/03/21/118943>. 73, 75
- [16] Blizzard: *World of warcraft*. Relatório Técnico, Blizzard Entertainment, 2004. 13
- [17] Boucsein, W.: *Electrodermal Activity*. The Springer series in behavioral psychophysiology and medicine. Springer US, 2012, ISBN 9781461411260. <https://books.google.com.br/books?id=6N6rn0EZEEoC>. 15
- [18] Boucsein, W.: *Electrodermal Activity*. The Springer series in behavioral psychophysiology and medicine. Springer US, 2012, ISBN 9781461411260. <https://books.google.com.br/books?id=6N6rn0EZEEoC>. 15
- [19] Bradley, Margaret M. e Peter J. Lang: *Measuring emotion: the self-assessment manikin and the semantic differential*. 1994. http://ac.els-cdn.com/0005791694900639/1-s2.0-0005791694900639-main.pdf?_tid=4e541106-3f21-11e4-8fb4-00000aab0f6b&acdnat=1411037480_3775a326c690a006e0ea4c9ec6e30d22. 23, 24
- [20] Cacioppo, J.T. e L.G. Tassinary: *Principles of Psychophysiology: Physical, Social and Inferential Elements*. Cambridge University Press, 1990, ISBN 9780521344326. <https://books.google.com.br/books?id=aAxpQgAACAAJ>. 19
- [21] Cannon, W. B.: *The James-Lange theory of emotions: A critical examination and an alternative theory*. The American Journal of Psychology, 39, 1927. 23
- [22] Card, Stuart K., Jock D. Mackinlay e Ben Shneiderman (editores): *Readings in Information Visualization: Using Vision to Think*. Morgan Kaufmann Publishers Inc., San Francisco, CA, USA, 1999, ISBN 1-55860-533-9. 37

- [23] Cattell, R.B.: *The scientific use of factor analysis in behavioral and life sciences*. Plenum Press, 1978, ISBN 9780306309397. <https://books.google.com.br/books?id=JjoNAQAAMAAJ>. 75
- [24] Chanel, Guillaume e Phil Lopes: *User evaluation of affective dynamic difficulty adjustment based on physiological deep learning*. International conference on human-computer interaction, augmented cognition. Springer, Cham, 2020. <https://archive-ouverte.unige.ch/unige:142293>. 85, 90
- [25] Chanel, Guillaume, Cyril Rebetez, Mireille Bétrancourt e Thierry Pun: *Boredom, engagement and anxiety as indicators for adaptation to difficulty in games*. Em *Proceedings of the 12th International Conference on Entertainment and Media in the Ubiquitous Era*, MindTrek '08, páginas 13–17, New York, NY, USA, 2008. ACM, ISBN 978-1-60558-197-2. <http://doi.acm.org/10.1145/1457199.1457203>. 5
- [26] Converse, H., T. Ferraro, D. Jean, L. Jones, V. Mendhiratta, E. Naviasky, M. Par, T. Rimlinger, S. Southall, J. Sprenkle e P. Abshire: *An emg biofeedback device for video game use in forearm physiotherapy*. Em *SENSORS, 2013 IEEE*, páginas 1–4, Nov 2013. 16
- [27] DeRosa, P.: *Tracking player feedback to improve game design*. Gamasutra, 2007. http://www.gamasutra.com/view/feature/1546/tracking_player_feedback_to_.php. 38
- [28] Deterding, Sebastian, Dan Dixon, Rilla Khaled e Lennart Nacke: *From game design elements to gamefulness: Defining gamification*. Volume 11, páginas 9–15, setembro 2011. 90
- [29] Dörner, R., S. Göbel, W. Effelsberg e J. Wiemeyer: *Player Experience*. Springer International Publishing, 2016, ISBN 9783319406121. <https://books.google.com.br/books?id=nQ7pDAAAQBAJ>. 1
- [30] Drachen, A., R. Sifa, C. Bauckhage e C. Thureau: *Guns, swords and data: Clustering of player behavior in computer games in the wild*. Em *2012 IEEE Conference on Computational Intelligence and Games (CIG)*, páginas 163–170, Sept 2012. 29, 30
- [31] Drachen, Anders e Alessandro Canossa: *Towards gameplay analysis via gameplay metrics*. Em *Proceedings of the 13th International MindTrek Conference: Everyday Life in the Ubiquitous Era*, MindTrek '09, páginas 202–209, New York, NY, USA, 2009. ACM, ISBN 978-1-60558-633-5. <http://doi.acm.org/10.1145/1621841.1621878>. 2, 28
- [32] Drachen, Anders e Alessandro Canossa: *Evaluating motion: spatial user behaviour in virtual environments*. International Journal of Arts and Technology, 4(3):294–314, 2011. <http://www.inderscienceonline.com/doi/abs/10.1504/IJART.2011.041483>. 13
- [33] Drachen, Anders, Magy Seif El-Nasr e Alessandro Canossa: *Game Analytics – The Basics*, páginas 13–40. Springer London, London, 2013, ISBN 978-1-4471-4769-5. https://doi.org/10.1007/978-1-4471-4769-5_2. 8

- [34] Drachen, Anders, Christian Thureau, Rafet Sifa e Christian Bauckhage: *A comparison of methods for player clustering via behavioral telemetry*. CoRR, abs/1407.3950, 2014. <http://arxiv.org/abs/1407.3950>. 31
- [35] Drioli, Carlo e Gian Luca Foresti: *The simple video coder: A free tool for efficiently coding social video data*. Volume 49, páginas 1563–1568, 2015, ISBN 9781479919598. 63, 70
- [36] Duchowski, Andrew: *Eye Tracking Methodology: Theory and Practice*. janeiro 2007, ISBN 978-1-84628-608-7. 20
- [37] Ekman, P.: *Universals and cultural differences in facial expressions of emotion*. Em Cole, J. (editor): *Nebraska symposium on motivation*, página 207–283. 1971. 23
- [38] Ekman, P.: *Are there basic emotions?* *Psychological Review*, 99 (3). 1992. 23
- [39] Ekman, P.: *An argument for basic emotions*. *Cognition and Emotion*, 6, 1992. 23
- [40] Ekman, P., W.V. Friesen e J.C. Hager: *Facial Action Coding System (FACS): Manual*. A Human Face, Salt Lake City (USA), 2002. 27
- [41] Ekman, Paul e Wallace V. Friesen: *Constants across cultures in the face and emotion*. *Journal of Personality and Social Psychology*, 17(2):124–129, 1971. <http://search.ebscohost.com/login.aspx?direct=true&db=pdh&AN=psp-17-2-124&site=ehost-live>. 26, 27
- [42] El-Nasr, Magy Seif, Anders Drachen e Alessandro Canossa (editores): *Game Analytics, Maximizing the Value of Player Data*. Springer, 2013, ISBN 978-1-4471-4768-8. <https://doi.org/10.1007/978-1-4471-4769-5>. 1, 2, 8, 11, 12, 13, 29, 32, 33, 37, 38, 41
- [43] Ester, Martin, Hans Peter Kriegel, Jörg Sander e Xiaowei Xu: *A density-based algorithm for discovering clusters in large spatial databases with noise*. páginas 226–231. AAAI Press, 1996. 43
- [44] Faraone Stephen V. e Dorfman Donald D.: *Lag sequential analysis: Robust statistical methods*. *Psychological Bulletin*, 101(2):312–323, 1987, ISSN 1939-1455(ELECTRONIC);0033-2909(PRINT). 34
- [45] Folgieri, Raffaella, Marco Granato, Claudio Lucchiari e Daniele Grechi: *Brain, Technology and Creativity. BrainArt: A BCI-Based Entertainment Tool to Enact Creativity and Create Drawing from Cerebral Rhythms*. março 2014, ISBN 978-1-4939-0964-3. 48
- [46] Fourati, Nesrine e Catherine Pelachaud: *Perception of emotions and body movement in the emilya database*. *IEEE Transactions on Affective Computing*, 9(1):90–101, 2018. 48
- [47] Fye, W. Bruce: *A history of the origin, evolution, and impact of electrocardiography*. *American Journal of Cardiology*, 73(13):937–949, 1995, ISSN 0002-9149. [http://dx.doi.org/10.1016/0002-9149\(94\)90135-X](http://dx.doi.org/10.1016/0002-9149(94)90135-X). 18

- [48] Gagné, André R., Magy Seif El-Nasr e Chris D. Shaw: *Analysis of telemetry data from a real-time strategy game: A case study*. *Comput. Entertain.*, 10(1):2:1–2:25, dezembro 2012, ISSN 1544-3574. <http://doi.acm.org/10.1145/2381876.2381878>. 29
- [49] Gomez-Uribe, Carlos A. e Neil Hunt: *The netflix recommender system: Algorithms, business value, and innovation*. *ACM Trans. Manage. Inf. Syst.*, 6(4):13:1–13:19, dezembro 2015, ISSN 2158-656X. <http://doi.acm.org/10.1145/2843948>. 5
- [50] Granato, Marco: *Emotions Recognition in Video Game Players Using Physiological Information*. 2019. <https://air.unimi.it/handle/2434/607597>. 5
- [51] Granato, Marco: *Emotions recognition in video game players using physiological information*. 2019. 48
- [52] Granato, Marco, Davide Gadia, Dario Maggiorini e Laura A. Ripamonti: *Software and hardware setup for emotion recognition during video game fruition*. Em *Proceedings of the 4th EAI International Conference on Smart Objects and Technologies for Social Good*, Goodtechs '18, página 19–24, New York, NY, USA, 2018. Association for Computing Machinery, ISBN 9781450365819. <https://doi.org/10.1145/3284869.3284895>. 53, 54, 55
- [53] Gwet, Kilem: *Handbook of inter-rater reliability: The definitive guide to measuring the extent of agreement among raters*. janeiro 2012. 70
- [54] Hansen, D. W. e Q. Ji: *In the eye of the beholder: A survey of models for eyes and gaze*. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 32(3):478–500, 2010. 21
- [55] Harmon-Jones, Cindy, Brock Bastian e Eddie Harmon-Jones: *The discrete emotions questionnaire: A new tool for measuring state self-reported emotions*. *PLoS ONE*, 11(8):1–25, 2016, ISSN 19326203. 63, 70
- [56] Heyer, L. J., S. Kruglyak e S. Yooseph: *Exploring Expression Data: Identification and Analysis of Coexpressed Genes*. *Genome Res.*, 9(11):1106–1115, 1999. 43
- [57] Hurst, J. Willis: *Naming of the waves in the ecg, with a brief account of their genesis*. *Circulation*, 98(18):1937–1942, 1998. <http://circ.ahajournals.org/content/98/18/1937.short>. 18, 20
- [58] Inc, Empatica: *Real-time physiological signals | e4 eda/gsr sensor*. <https://www.empatica.com/research/e4/>. (Accessed on 05/29/2018). 17
- [59] Inc, Empatica: *Real-time physiological signals | e4 eda/gsr sensor*. <https://www.empatica.com/research/e4/>. (Accessed on 05/29/2018). 49, 87
- [60] Isbister, K. e N. Schaffer: *Game usability: Advancing the player experience*. San Francisco: Morgan Kaufman, 2008. 3

- [61] Isbister, Katherine: *Enabling Social Play: A Framework for Design and Evaluation*, páginas 11–22. Springer London, London, 2010, ISBN 978-1-84882-963-3. http://dx.doi.org/10.1007/978-1-84882-963-3_2. 3
- [62] Isbister, Katherine e Noah Schaffer: *Game Usability: Advancing the Player Experience*. Morgan Kaufmann, agosto 2008, ISBN 0123744474. <http://www.amazon.com/exec/obidos/redirect?tag=citeulike07-20&path=ASIN/0123744474>. 3
- [63] Isbister, Katherine e Noah Schaffer: *Game Usability: Advancing the Player Experience*. Morgan Kaufmann, Burlington, MA, USA, 2008, ISBN 0123744474. <http://www.sciencedirect.com/science/book/9780123744470>. 13
- [64] James, William: *What is an emotion?* *Mind*, 9(34):188–205, 1884. 23
- [65] JAQUES, P. A. ; VICCARI e R. M.: *Estado da arte em ambientes inteligentes de aprendizagem que consideram a afetividade do aluno*. *Revista Informática na Educação Teoria e Prática*, 8:15–38, 2005. 22
- [66] Kang, Shin Jin, Young Bin Kim, Taejung Park e Chang Hun Kim: *Automatic player behavior analysis system using trajectory data in a massive multiplayer online game*. *Multimedia Tools and Applications*, 66(3):383–404, 2013, ISSN 13807501. 30, 31
- [67] Kim, Jun H., Daniel V. Gunn, Eric Schuh, Bruce Phillips, Randy J. Pagulayan e Dennis Wixon: *Tracking real-time user experience (true): A comprehensive instrumentation solution for complex systems*. Em *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, CHI '08, páginas 443–452, New York, NY, USA, 2008. ACM, ISBN 978-1-60558-011-1. <http://doi.acm.org/10.1145/1357054.1357126>. 3, 29
- [68] King, D. e S. Chen: *Metrics for social games*. Presentation at the social games summit 2009, game developers conference, 2009. 28, 29
- [69] Kivikangas, J. M., Guillaume Chanel, Ben Cowley, Inger Ekman, Mikko Salminen, Simo Jarvela e Niklas Ravaja: *A review of the use of psychophysiological methods in game research*. Volume 3, páginas 181–199, 2011. 2, 3, 59
- [70] Kobayashi, H. e F. Hara: *The recognition of basic facial expressions by neural network*. Em *Neural Networks, 1991. 1991 IEEE International Joint Conference on*, páginas 460–466 vol.1, Nov 1991. 27
- [71] Koster, Raph e Will Wright: *A Theory of Fun for Game Design*. Paraglyph Press, 2004, ISBN 1932111972. 3
- [72] Koštomaj, Mitja e Bojana Boh: *Evaluation of User's Physical Experience in Full Body Interactive Games*, páginas 145–154. Springer Berlin Heidelberg, Berlin, Heidelberg, 2009, ISBN 978-3-642-04076-4. http://dx.doi.org/10.1007/978-3-642-04076-4_16. 4

- [73] Kreibig, Sylvia D.: *Autonomic nervous system activity in emotion: A review*. *Biological Psychology*, 84(3):394–421, 2010, ISSN 0301-0511. <https://www.sciencedirect.com/science/article/pii/S0301051110000827>, The biopsychology of emotion: Current theoretical and empirical perspectives. 52
- [74] Kriglstein, Simone, Günter Wallner e Margit Pohl: *A user study of different game-play visualizations*. Em *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, CHI '14, páginas 361–370, New York, NY, USA, 2014. ACM, ISBN 978-1-4503-2473-1. <http://doi.acm.org/10.1145/2556288.2557317>. 38
- [75] Lang, P.: *The emotion probe. studies of motivation and attention*. *The American psychologist*, 50 5:372–85, 1995. 15
- [76] Lange, C. G.: *The mechanism of the emotions*. Em Rand, B. (editor): *The classical psychologists*, páginas 672–684. Houghton Mifflin, Boston, 1912. 23
- [77] Larose, Daniel T. e Chantal D. Larose: *Data Mining and Predictive Analytics*. 2015, ISBN 9781118116197. 79
- [78] Lee, Yeng Ting, Kuan Ta Chen, Yun Maw Cheng e Chin Laung Lei: *World of warcraft avatar history dataset*. Em *Proceedings of the Second Annual ACM Conference on Multimedia Systems*, MMSys '11, páginas 123–128, New York, NY, USA, 2011. ACM, ISBN 978-1-4503-0518-1. <http://doi.acm.org/10.1145/1943552.1943569>. 42
- [79] Levillain, Florent, Joseph Onderi Orero, Maria Rifqi e Bernadette Bouchon-Meunier: *Characterizing player's experience from physiological signals using fuzzy decision trees*. Em *Proceedings of the 2010 IEEE Conference on Computational Intelligence and Games*, páginas 75–82, 2010. 48
- [80] Lopetegui, E., B. G. Zapirain e A. Mendez: *Tennis computer game with brain control using eeg signals*. Em *Computer Games (CGAMES), 2011 16th International Conference on*, páginas 228–234, July 2011. 20
- [81] Machado, Letícia Vier, Marilda Gonçalves Dias e Sonia Mari Shima Barroco: *Teoria das emoções em Vigotski*. *Psicologia em Estudo*, 16:647–657, 2011, ISSN 1413-7372. http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1413-73722011000400015&nrm=iso. 23
- [82] Maier, Marco, Daniel Elsner, Chadly Marouane, Meike Zehnle e Christoph Fuchs: *Deepflow: Detecting optimal user experience from physiological data using deep neural networks*. Em *Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence, IJCAI-19*, páginas 1415–1421. International Joint Conferences on Artificial Intelligence Organization, julho 2019. <https://doi.org/10.24963/ijcai.2019/196>. xii, 49, 51
- [83] Maier, Marco, Chadly Marouane e Daniel Elsner: *Deepflow: Detecting optimal user experience from physiological data using deep neural networks*. Em *Proceedings of the 18th International Conference on Autonomous Agents and MultiAgent Systems*,

- AAMAS '19, página 2108–2110, Richland, SC, 2019. International Foundation for Autonomous Agents and Multiagent Systems, ISBN 9781450363099. 85
- [84] Malik, M., A. J. Camm, J. T. Bigger, G. Breithardt, S. Cerutti, R. J. Cohen, P. Coumel, E. L. Fallen, H. L. Kennedy, R. E. Kleiger, F. Lombardi, A. Malliani, A. J. Moss, J. N. Rottman, G. Schmidt, P. J. Schwartz e D. H. Singer: *Heart rate variability. Standards of measurement, physiological interpretation, and clinical use.* European Heart Journal, 17(3):354–381, 1996, ISSN 0195668X. 74
- [85] Mandryk, Regan: *Physiological Measures for Game Evaluation.* Morgan Kaufmann. 2008. K. Isbister and N. Shaffer, Eds. 3
- [86] Mandryk, Regan e Lennart Nacke: *Biometrics in Gaming and Entertainment Technologies: Trends, Technologies, and Challenges*, páginas 191–224. dezembro 2016, ISBN 978-1-315-31708-3. 10, 19
- [87] Mandryk, Regan L. e M. Stella Atkins: *A fuzzy physiological approach for continuously modeling emotion during interaction with play technologies.* Int. J. Hum.-Comput. Stud., 65(4):329–347, abril 2007, ISSN 1071-5819. <http://dx.doi.org/10.1016/j.ijhcs.2006.11.011>. 45
- [88] Mandryk, Regan L. e M. Stella Atkins: *A fuzzy physiological approach for continuously modeling emotion during interaction with play technologies.* Int. J. Hum.-Comput. Stud., 65(4):329–347, abril 2007, ISSN 1071-5819. <http://dx.doi.org/10.1016/j.ijhcs.2006.11.011>. 85
- [89] Mandryk, Regan L. e Kori M. Inkpen: *Physiological indicators for the evaluation of co-located collaborative play.* Em *Proceedings of the 2004 ACM Conference on Computer Supported Cooperative Work, CSCW '04*, página 102–111, New York, NY, USA, 2004. Association for Computing Machinery, ISBN 1581138105. <https://doi.org/10.1145/1031607.1031625>. 15
- [90] Mandryk, Regan L., Kori M. Inkpen e Thomas W. Calvert: *Using psychophysiological techniques to measure user experience with entertainment technologies.* Behaviour & Information Technology, 25(2):141–158, 2006. <http://dx.doi.org/10.1080/01449290500331156>. 3
- [91] Mandryk, Regan L, Kori M Inkpen e Thomas W Calvert: *Using psychophysiological techniques to measure user experience with entertainment technologies.* Behaviour & information technology, 25(2):141–158, 2006. 48
- [92] Maricic, A. e Hiew Pang Leang: *Biofeedback computer game-based training.* Em *47th International Symposium ELMAR, 2005.*, páginas 185–188, June 2005. 19
- [93] Marshall, C. e G.B. Rossman: *Designing Qualitative Research.* SAGE Publications, 2014, ISBN 9781483324265. <https://books.google.com.br/books?id=qTByBgAAQBAJ>. 2
- [94] Mauss, Iris B. e Michael D. Robinson: *Measures of emotion: A review.* Cognition & emotion, 2(20), novembro 2016. 26

- [95] McAllister, Graham e Gareth R. White: *Chapter 2 video game development and user experience*. 2017. 2
- [96] Medler, B.: *Play with data-an exploration of play analytics and its effect on player experiences*. PhD, 2012. 37
- [97] Mellon, Larry: *Applying metrics driven development to mmo costs and risks*. Relatório Técnico, Versant Corporation, 2009. http://maggotranch.com/MMO_Metrics.pdf. 10
- [98] Michels, Anton Kai, Peter Sikachev, Samuel Delmont, Uriel Doyon, Francis Maheux, Jean Normand Bucci e David Gallardo: *Labs r&d: rendering techniques in rise of the tomb raider*. Em *SIGGRAPH Talks*, 2015. 12
- [99] Mirza-Babaei, Pejman, Günter Wallner, Graham McAllister e Lennart E Nacke: *Unified visualization of quantitative and qualitative playtesting data*. Proceedings of the extended abstracts of the 32nd annual ACM conference on Human factors in computing systems - CHI EA '14, páginas 1363–1368, 2014. <http://dl.acm.org/citation.cfm?id=2581224> <http://dl.acm.org/citation.cfm?doid=2559206.2581224>. 44, 47
- [100] Movisens: *product_edamove_worn.jpg (1024×1024)*. https://www.movisens.com/wp-content/uploads/product_edamove_worn.jpg. (Accessed on 05/10/2017). 17
- [101] Myers, J.L., A. Well e R.F. Lorch: *Research Design and Statistical Analysis*. Routledge, 2010, ISBN 9780805864311. https://books.google.com.br/books?id=nbs0IJ_saUAC. 80
- [102] Nacke, L. E.: *An introduction to physiological player metrics for evaluating games*. Em *Game Analytics - Maximizing the Value of Player Data*, capítulo 26, páginas 585–619. Springer London, 2013, ISBN 1447147685. http://link.springer.com/chapter/10.1007/978-1-4471-4769-5_26. 26
- [103] Nacke, L.E.: *Introduction to biometric measures for Games User Research*, páginas 281–299. março 2018. 14, 17
- [104] Nacke, Lennart: *Towards a framework of player experience research*. Em *In Proceedings of EPEX'11 at FDG 2011*. 8, 12
- [105] Nacke, Lennart: *Introduction to biometric measures for Games User Research*. Em Drachen, Anders, Pejman Mirza-Babaei e Lennart Nacke (editores): *Games User Research*, páginas 281–299. Oxford University Press, New York, NY, 2018, ISBN 978-0198794844. 59
- [106] Nacke, Lennart e Anders Drachen: *Towards a framework of player experience research*. Em *Proceedings of the Second International Workshop on Evaluating Player Experience in Games at FDG 2011*, Bordeaux, France, 2011. 1
- [107] Nacke, Lennart E.: *An Introduction to Physiological Player Metrics for Evaluating Games*, páginas 585–619. Springer London, London, 2013, ISBN 978-1-4471-4769-5. https://doi.org/10.1007/978-1-4471-4769-5_26. 73

- [108] Nacke, Lennart E: *Games user research and physiological game evaluation*. Em Bernhaupt, Regina (editor): *Game User Experience Evaluation*, capítulo 4, páginas 63–86. Springer International Publishing, 2015, ISBN 978-3-319-15985-0. 9, 10
- [109] Nacke, Lennart E., Mark N. Grimshaw e Craig A. Lindley: *More than a feeling: Measurement of sonic user experience and psychophysiology in a first-person shooter game*. *Interact. Comput.*, 22(5):336–343, setembro 2010, ISSN 0953-5438. <http://dx.doi.org/10.1016/j.intcom.2010.04.005>. 17, 18, 19
- [110] Nacke, Lennart E., Joerg Niesenhaus, Karolien Poels, Anders Drachen, Hannu J. Korhonen, Wijnand A. Ijsselstein, Kai Kuikkaniemi, Wouter M. Van Den Hoogen e Yvonne A. W. De Kort: *Playability and player experience research*. 2009. 3
- [111] Niedermeyer, E. e F.H.L. da Silva: *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields*. LWW Doody’s all reviewed collection. Lippincott Williams & Wilkins, 2005, ISBN 9780781751261. <https://books.google.fi/books?id=tndqYGPHQdEC>. 19
- [112] Oliveira, Eduardo de e Patrícia Augustin Jaques: *Inferindo as emoções do usuário pela face através de um sistema psicológico de codificação facial*. Em *Proceedings of the VIII Brazilian Symposium on Human Factors in Computing Systems, IHC ’08*, páginas 156–165, Porto Alegre, Brazil, Brazil, 2008. Sociedade Brasileira de Computação, ISBN 978-85-7669-203-4. <http://dl.acm.org/citation.cfm?id=1497470.1497488>. 27
- [113] Pagulayan, Randy J., Kevin Keeker, Dennis Wixon, Ramon L. Romero e Thomas Fuller: *The human-computer interaction handbook*. capítulo User-centered Design in Games, páginas 883–906. L. Erlbaum Associates Inc., Hillsdale, NJ, USA, 2003, ISBN 0-8058-3838-4. <http://dl.acm.org/citation.cfm?id=772072.772128>. 2
- [114] Park, B. ., E. . Jang, S. . Kim, C. Huh e J. . Sohn: *Feature selection on multi-physiological signals for emotion recognition*. Em *2011 2nd International Conference on Engineering and Industries (ICEI)*, páginas 1–6, Nov 2011. 76
- [115] Park, Duck Gun e Hee Chan Kim: *Muscleman: Wireless input device for a fighting action game based on the emg signal and acceleration of the human forearm*. 16
- [116] Pejman, Mirza babaei, Long Sebastian e Foley Emma: *Understanding the contribution of biometrics to games user research*. Em *DiGRA 2011 - Proceedings of the 2011 DiGRA International Conference: Think Design Play*. DiGRA/Utrecht School of the Arts, January 2011, ISBN ISSN 2342-9666. <http://www.digra.org/wp-content/uploads/digital-library/11310.43254.pdf>. xii, 49, 50
- [117] Phillips, B.: *Peering into the black box of player behavior: The player experience panel at Microsoft Game Studios*. In: *Games Developers Conference, 2010*. <http://www.gdcvault.com/play/1012646/Peering-into-the-Black-Box>. 38, 39
- [118] Pietro, Guardini e Maninetti Paolo: *Better game experience through game metrics: A rally videogame case study*. Em El-Nasr, Magy Seif, Anders Drachen e Alessandro

- Canossa (editores): *Game Analytics, Maximizing the Value of Player Data*, páginas 325–361. Springer, 2013. https://doi.org/10.1007/978-1-4471-4769-5_16. 68
- [119] Plutchik, R.: *A general psychoevolutionary theory of emotion*. Em Plutchik, R. e H. Kellerman (editores): *Emotion: Theory, research, and experience (Vol. 1, volume 1, página 3–31*. Academic, New York, 1980. 23
- [120] Porcino, Thiago, Erick O. Rodrigues, Flavia Bernardini, Daniela Trevisan e Esteban Clua: *Identifying cybersickness causes in virtual reality games using symbolic machine learning algorithms*. *Entertainment Computing*, 41:100473, 2022, ISSN 1875-9521. <https://www.sciencedirect.com/science/article/pii/S1875952121000707>. 90
- [121] Ravaja, N.: *Contributions of psychophysiology to media research: Review and recommendations*. *MEDIA PSYCHOLOGY*, (6):193–235, 2004, ISSN 1521-3269. 3
- [122] Revolution, BITalino: *Microsoft word - eda sensor datasheet*. http://bitalino.com/datasheets/REVOLUTION_EDA_Sensor_Datasheet.pdf, Jan 2016. (Accessed on 05/10/2017). 17
- [123] Revolution, BITalino: *Microsoft word - emg sensor datasheet*. http://bitalino.com/datasheets/REVOLUTION_EMG_Sensor_Datasheet.pdf, Jan 2016. (Accessed on 05/10/2017). 18
- [124] Rosenthal, Robert: *Experimenter effects in behavioral research*. Appleton-Century-Crofts, East Norwalk, CT, US, 1966. 68
- [125] Salen, Katie e Eric Zimmerman: *Rules of Play: Game Design Fundamentals*. The MIT Press, 2003, ISBN 0262240459, 9780262240451. 12
- [126] Sarmanho, Elton, Thiago Santos, Carla Castanho e Ricardo Jacobi: *Estimating Player Experience from Arousal and Valence using Psychophysiological Signals*. SBGames 2018 - Computing Track (), 2018. <http://www.sbgames.org/sbgames2018/files/papers/ComputacaoFull/188391.pdf>. 48
- [127] Schachter, S.: *The interaction of cognitive and physiological determinants of emotional state*. Em Berkowitz, L. (editor): *Advances in experimental social psychology (Vol, volume 1, página 49–80*. Academic, New York, 1964. 23
- [128] Schachter, S. e J. Singer: *Cognitive, social, and physiological determinants of emotional state*. *Psychological Review*, 69:379–399, 1984. 23
- [129] Schell, Jesse: *The Art of Game Design: A Book of Lenses*. Morgan Kaufmann Publishers Inc., San Francisco, CA, USA, 2008, ISBN 0-12-369496-5. 3
- [130] Scherer, Klaus R.: *What are emotions? and how can they be measured?* *Social Science Information*, 44(4):695–729, 2005. <http://ssi.sagepub.com/content/44/4/695.abstract>. 24, 26
- [131] Schuyttema, Schuyttema Paul: *Design de Games: Uma abordagem prática*. 2008. 4

- [132] Soares, R. Teixeira, E. Sarmanho, M. Miura, T. Barros, R. Jacobi e C. Castanho: *Biofeedback sensors in electronic games: A practical evaluation*. Em *2017 16th Brazilian Symposium on Computer Games and Digital Entertainment (SBGames)*, páginas 56–65, Nov 2017. 59
- [133] Soares, Rodrigo, Elton Sarmanho, Marco Miura, Tiago Silva e Carla Castanho: *Biofeedback Sensors in Game Telemetry Research*. XV Simpósio Brasileiro de Jogos e Entretenimento Digital, páginas 3–4, 2016. 2, 3, 19
- [134] Stepp, C. E., D. Britton, C. Chang, A. L. Merati e Y. Matsuoka: *Feasibility of game-based electromyographic biofeedback for dysphagia rehabilitation*. Em *Neural Engineering (NER), 2011 5th International IEEE/EMBS Conference on*, páginas 233–236, April 2011. 16
- [135] Stern, R.M., W.J. Ray e K.S. Quigley: *Psychophysiological Recording*. Psychophysiological Recording. Oxford University Press, 2001, ISBN 9780195113594. <https://books.google.com.br/books?id=9WmvzrkZdv8C>. 19
- [136] Subahni, A. R., L. Xia e A. S. Malik: *Association of mental stress with video games*. Em *Intelligent and Advanced Systems (ICIAS), 2012 4th International Conference on*, volume 1, páginas 82–85, June 2012. 18, 19
- [137] Sundstedt, Veronica, Matthias Bernhard, Efstathios Stavarakis, Erik Reinhard e Michael Wimmer: *Visual Attention and Gaze Behavior in Games: An Object-Based Approach*, páginas 543–583. Springer London, London, 2013. 21, 22
- [138] Tan, Chek Tien, Sander Bakkes e Yusuf Pisan: *Inferring player experiences using facial expressions analysis*. Em *Proceedings of the 2014 Conference on Interactive Entertainment, IE2014*, páginas 7:1–7:8, New York, NY, USA, 2014. ACM, ISBN 978-1-4503-2790-9. <http://doi.acm.org/10.1145/2677758.2677765>. 15, 60
- [139] Tan, Chek Tien, Daniel Rosser, Sander Bakkes e Yusuf Pisan: *A feasibility study in using facial expressions analysis to evaluate player experiences*. Em *Proceedings of The 8th Australasian Conference on Interactive Entertainment: Playing the System, IE '12*, páginas 5:1–5:10, New York, NY, USA, 2012. ACM, ISBN 978-1-4503-1410-7. 26
- [140] Tao, Jianhua e Tieniu Tan: *Affective computing: A review*. Em Tao, Jianhua, Tieniu Tan e Rosalind W. Picard (editores): *Affective Computing and Intelligent Interaction*, páginas 981–995, Berlin, Heidelberg, 2005. Springer Berlin Heidelberg, ISBN 978-3-540-32273-3. 4, 46
- [141] Tijs, Tim J., Dirk Brokken e Wijnand A. Ijsselstein: *Dynamic game balancing by recognizing affect*. Em *Proceedings of the 2Nd International Conference on Fun and Games*, páginas 88–93, Berlin, Heidelberg, 2008. Springer-Verlag, ISBN 978-3-540-88321-0. http://dx.doi.org/10.1007/978-3-540-88322-7_9. 5

- [142] Tognetti, Simone, Maurizio Garbarino, Andrea Tommaso Bonanno, Matteo Matteucci e Andrea Bonarini: *Enjoyment recognition from physiological data in a car racing game*. Em *Proceedings of the 3rd International Workshop on Affective Interaction in Natural Environments*, AFFINE '10, páginas 3–8, New York, NY, USA, 2010. ACM, ISBN 978-1-4503-0170-1. <http://doi.acm.org/10.1145/1877826.1877830>. 49, 85
- [143] Tognetti, Simone, Maurizio Garbarino, Andrea Bonarini e Matteo Matteucci: *Modeling enjoyment preference from physiological responses in a car racing game*. Em *Proceedings of the 2010 IEEE Conference on Computational Intelligence and Games*, páginas 321–328, 2010. 48
- [144] Vachiratamporn, Vanus, R. Legaspi, K. Moriyama, Ken ichi Fukui e M. Numao: *An analysis of player affect transitions in survival horror games*. *Journal on Multimodal User Interfaces*, 9:43–54, 2014. xii, 50, 52
- [145] Valenza, Gaetano, Antonio Lanata e Enzo Pasquale Scilingo: *The role of nonlinear dynamics in affective valence and arousal recognition*. *IEEE Transactions on Affective Computing*, 3(2):237–249, 2012, ISSN 19493045. 76
- [146] Vieira, Luiz: *Assessment of fun from the analysis of facial images*. Tese de Doutorado, University of São Paulo, maio 2017. 60, 74
- [147] Vieira, Luiz e Flávio Silva: *Assessment of fun in interactive systems: a survey*. 41, setembro 2016. 1
- [148] Viola, P. e M. Jones: *Rapid object detection using a boosted cascade of simple features*. Em *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. CVPR 2001*, volume 1, páginas I–511–I–518 vol.1, 2001. 27
- [149] Wallner, G.: *Sequential Analysis of Player Behavior*. CHI PLAY '15 Proceedings of the 2015 Annual Symposium on Computer-Human Interaction in Play, páginas 349–358, 2015. 34, 35, 36, 46
- [150] Wallner, G. e S. Kriglstein: *Visualization-based analysis of gameplay data – a review of literature*. *Entertainment Computing*, 4(3):143 – 155, 2013, ISSN 1875-9521. <http://www.sciencedirect.com/science/article/pii/S1875952113000049>. 37
- [151] Wallner, G. e S. Kriglstein: *PLATO: A visual analytics system for gameplay data*. *Computers and Graphics (Pergamon)*, 38(1):341–356, 2014, ISSN 00978493. <http://dx.doi.org/10.1016/j.cag.2013.11.010>. 41, 43, 44, 45
- [152] Wallner, Günter e Simone Kriglstein: *Game research methods*. capítulo An Introduction to Gameplay Data Visualization, páginas 231–250. ETC Press, Pittsburgh, PA, USA, 2015, ISBN 978-1-312-88473-1. <http://dl.acm.org/citation.cfm?id=2812774.2812792>. 39, 40, 41, 42

- [153] Ware, Colin: *Information Visualization: Perception for Design*. Morgan Kaufmann Publishers Inc., San Francisco, CA, USA, 2004, ISBN 1558608192. 37
- [154] Watson, D., L. A. Clark e A. Tellegen: *Development and validation of brief measures of positive and negative affect: the panas scales*. *Journal of Personality and Social Psychology*, 54:1063–1070, 1988. 23
- [155] Watson, David e Lee Anna Clark: *THE PANAS-X: Manual for the Positive and Negative Affect Schedule - Expanded Form*. 1994. 23
- [156] Wawrzyniak, Andrew J.: *Handbook of psychophysiology (3rd edition)*. *The Psychologist*, 21(3):218, março 2008. 3
- [157] Weber, Ben G, Michael John, Michael Mateas e Arnav Jhala: *Modeling Player Retention in Madden NFL 11*. Em *Innovative Applications of Artificial Intelligence (IAAI)*, San Francisco, CA, 2011. AAAI Press, AAAI Press. 12
- [158] Williams, D., M. Consalvo, S. Caplan e N. Yee: *Looking for gender (LFG): Gender roles and behaviors among online gamers*. *Journal of Communication*, 59, 2009. 29
- [159] Yang, W., M. Rifqi, C. Marsala e A. Pinna: *Physiological-based emotion detection and recognition in a video game context*. Em *2018 International Joint Conference on Neural Networks (IJCNN)*, páginas 1–8, 2018. 5, 51, 53, 85
- [160] Yannakakis, Georgios, Katherine Isbister, Ana Paiva e Kostas Karpouzis: *Guest editorial: Emotion in games*. *Affective Computing, IEEE Transactions on*, 5:1–2, janeiro 2014. 48

Apêndice A

Questionário de Autoavaliação das sessões de jogo

1. Nome*

Escreva uma ou algumas palavras...

500

2. Qual sua idade*

Escreva uma ou algumas palavras...

500

3. Qual seu sexo?*

Selecione uma resposta

Masculino

Feminino

4. Já teve alguma experiência com jogo de corrida?*

Selecione uma ou mais respostas

Sim

Não

5. Com que frequência tem jogado jogos desse gênero ?*

Selecione uma ou mais respostas

Todos os dias

Uma vez por semana

Duas vezes por semana

Fins de semana

Duas vezes por mês

De vez em quando

Nunca

6. Possui um bom entendimento da mecânica dos jogos de corrida (câmbio, drift, modos de visualização) ?*

Selecione uma ou mais respostas

1- Nenhum Entendimento


2 - Pouco Entendimento

3 - Entendimento Razoável

4 - Bom Entendimento

5 - Total Entendimento

7. Quão habilidoso você se considera nesse tipo de jogo em uma escala 1 (Inábil) à 5 (Habilidoso) ?



**9. Descreva qual foi o melhor momento na sessão 1
(Deixar em branco caso não houver)**

Escreva uma ou algumas palavras...

500

**10. Descreva qual foi o pior momento na sessão 1
(Deixar em branco caso não houver)**

Escreva uma ou algumas palavras...

500

**12. Descreva qual foi o melhor momento na sessão 2
(Deixar em branco caso não houver)**

Escreva uma ou algumas palavras...

500

**13. Descreva qual foi o pior momento na sessão 2
(Deixar em branco caso não houver)**

Escreva uma ou algumas palavras...

500

14. Descreva sua experiência com relação a sessão 3

1) "Dificuldade" - No geral a pista desta sessão foi "Fácil" ou "Difícil" ? 2)

"Utilidade" - O recurso do câmbio foi "Complicado" ou "Simples" ? 3) "Utilidade" -

O recurso do drift foi "Não Essencial" ou "Essencial" ? 4) "Engajamento" - A maneira que a sessão desenvolveu foi "Entediante" ou "interessante"?

5) "Motivação" - Quando você esteve jogando, a sessão foi "Desestimulante" ou "Emocionante"? 6) "Diversão" - A sessão foi divertida? 7) No geral a sessão foi irritante ?



**15. Descreva qual foi o melhor momento na sessão 3
(Deixar em branco caso não houver)**

Escreva uma ou algumas palavras...

500

**16. Descreva qual foi o pior momento na sessão 3
(Deixar em branco caso não houver)**

Escreva uma ou algumas palavras...

500

**18. Descreva qual foi o melhor momento na sessão 4
(Deixar em branco caso não houver)**

Escreva uma ou algumas palavras...

500

**19. Descreva qual foi o pior momento na sessão 4
(Deixar em branco caso não houver)**

Escreva uma ou algumas palavras...

500

20. A presença da câmera e do biosensor atrapalhou sua experiência com jogo ?*

Selecione uma resposta

Sim

Não

21. O controle do Jogo Facilitou muito jogo*

Selecione uma resposta

Discordo Totalmente

Discordo Parcialmente

Neutro

Concordo Parcialmente

Concordo Totalmente

22. As configurações do controle do Jogo ajudaram no seu desempenho*

Selecione uma resposta

Discordo Totalmente

Discordo Parcialmente

Neutro

Concordo Parcialmente

Concordo Totalmente

Anexo I

Artigos decorrentes dessa proposta

Figura I.1: *R. Teixeira Soares, E. Sarmanho, M. Miura, T. Barros, R. Jacobi and C. Castanho, "Biofeedback Sensors in Electronic Games: A Practical Evaluation," 2017 16th Brazilian Symposium on Computer Games and Digital Entertainment (SBGames), 2017, pp. 56-65, doi: 10.1109/SBGames.2017.00015.*

Biofeedback Sensors in Game Telemetry Research

Rodrigo T. Soares¹ Elton S. Siqueira¹ Marco A. Miura² Tiago P. B. e Silva² Carla D. Castanho¹

¹Departamento de Ciência da Computação

²Departamento de Design
Universidade de Brasília

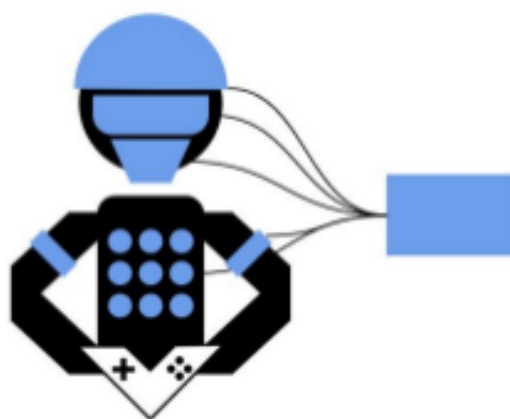


Figure 1: User data acquisition schema in Game Analytics.

ABSTRACT

Game Analytics is one of the new research trends in digital games' industry. It consists of analyzing the variables collected during a game session in order to improve game designing and collaborate with gamer behavior research as well. These data may be acquired from the game itself, such as level progression, session duration and the user's overall performance; or from the users, like heartbeat, brain activity, gaze movement or any indication of attention, fun or boredom. The automatic process used to capture such data is called game telemetry. Several studies have been proposing different ways to apply measurement techniques and to employ specific sensors to collect user data. This study aims to survey the uses of biofeedback sensors in recent research, in the context of game data telemetry. The devices will be described and their reliability aspects will be outlined to better summarize the survey. The results shown here intend to assist researchers interested in obtaining information on sensors and methods applied in game telemetry.

Keywords: Game analytics, user data telemetry, biofeedback sensors.

1 INTRODUCTION

Game development was, during the early years of game history, a process of experimenting and trying out new game concepts [4]. Since then, many design theories have been created and studied in this area, based on new games and genres that rose in the following decades. When new games have become a success, they made the industry grow from that new concept or genre recently introduced.

These cases, however, did not always give useful information neither a recipe on how to systematically develop a remarkable game, as user behavior and acceptance of the game were not predictable in a simple way.

In order to improve the development process and to analyze player behavior, game design has been moving towards a new approach in recent years. For modern designers, it has become clear that more information on the user experience was needed, to identify and analyze the aspects that produce a notable game. Several studies point that a data-driven game design is not only beneficial to the industry but also necessary, given the game market diversification, in both companies and consumer spheres [15].

Game Analytics, then, emerged as a new way to proceed when designing a game. The application of analytics in game data serves as a powerful tool when thinking about user preferences and expected reaction to the game [15]. Recently, games are being developed with not only the designer's experience, but also based on actual data derived directly from the game and its users. Level proceed rate, average play session time and other game-related variables are being collected and stored in order to evaluate game progression and replayability. In addition, users are also supplying useful data, as their excitement level is being analyzed to determine which moments in the game are thrilling or boring, for example.

Game Telemetry, as it is called the process of measuring game data from a distant source [15], is a key step in game analytics to gather user and game information. While game data is obtained directly from inner computational methods and sent via network, for instance, user data is acquired from sensors and supervisor systems physically linked to them, and also from questionnaires given after a game session. The devices employed usually sense biofeedback data, i.e. data derived from the physiological and motor systems of the human body [17], so gamer behavior can be studied directly from his/her body reactions.

Figura 1.2: *E. S. Siqueira, C. D. Castanho, G. N. Rodrigues and R. P. Jacobi, "A Data Analysis of Player in World of Warcraft Using Game Data Mining," 2017 16th Brazilian Symposium on Computer Games and Digital Entertainment (SBGames), 2017, pp. 1-9, doi: 10.1109/SBGames.2017.00009.*

A Data Analysis of Player in World of Warcraft using Game Data Mining

Elton S. Siqueira^{1*}

Genaina N. Rodrigues¹

Carla D. Castanho¹

Ricardo P. Jacobi¹

¹Universidade de Brasília, Departamento de Ciência da Computação, Brazil

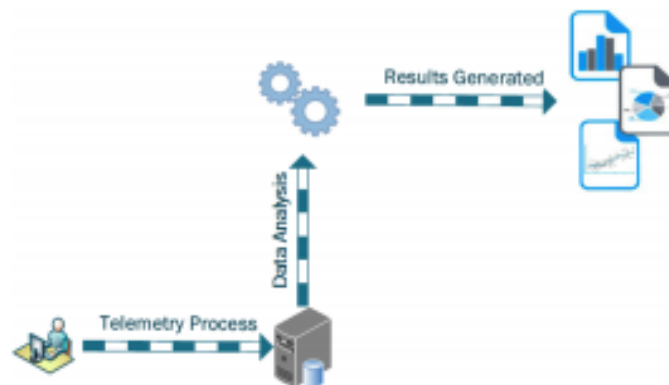


Figure 1: An overview of Game Analytics.

ABSTRACT

Online Games platforms have become a very prospective field of investigation to the game industry. Many business models are being created to understand the dynamics of player behavior to promote improvements in game design and to keep players in the virtual world so that they maintain and renew their respective subscription. From the business perspective it is crucial to predict how many players will join the game and how many will stay in the game, important factors for the company's revenue. This work aims to identify significant data from a popular Massively Multiplayer Online Game (MMOG) - World of Warcraft - using appropriate data mining methods for deduction of players profiles. Multiple linear regression was applied to check whether a player will leave or not the game in the near future. Also, a clustering technique, i.e. K-means, was used to extract clusters of players and identify their common characteristics. The regression model showed that "Level" and "Playing Density" contribute significantly to predict whether a player will or not renew the subscription, while the clustering revealed four forms of player profile: Beginner, Intermediate I, Intermediate II and Professional.

Keywords: World of Warcraft, game analytics, MMOG, data Mining, clustering, k-means

1 INTRODUCTION

Massively Multiplayer Online Games (MMOGs) are a popular type of entertainment on the Internet. Data released by ESA[13] in 2015 indicate that there are 155 million Americans who play video games and 29% of them currently pay to play (P2P) online. The report released [14] in 2016 also underscores the video game industry's impact on the US economy, the industry contributed \$11.7 billion

*e-mail: eltonsamirho@gmail.com

in value to US GDP (Gross Domestic Product). Also, the report revealed that frequent gamers who play multiplayer and online games spend an average of 6.5 hours per week playing online. Currently, the most common business model for online gaming is based on monthly subscription fees that gamers pay to obtain credits, which allow them to start or continue a journey in the game's virtual world. From the perspective of games industry, to understand players behavior in the virtual world and predict "how long they will stay in the game" are crucial factors to control their revenue [15]. Identifying players profiles and predicting players behavior is based on analyzing their data (for example, Playtime per month). Therefore, data collection (a process known as **Data Telemetry**) and data mining techniques are important for data analysis, as depicted in Figure 1.

There is a wealth of information hidden in process of telemetry data. However, not all of it is readily available, and some are very hard to discover without the proper expert knowledge. In addition, the challenge faced by the game industry to take advantage of telemetry data mirrors the challenge of working with big data. Simply retrieving information from databases is not enough to guide analysts. Instead, new procedures have appeared to help analysts to obtain the information they need to make better decisions. These include: automatic data summarization, the extraction of the essence of the stored information, and the discovery of patterns in raw data [12]. When datasets become very large and complex, many traditional methodologies and algorithms used on smaller datasets fail. Instead, methods designed for large datasets must be used. These methods are called data mining, and they perform a quick and effective analysis, making the results intuitively accessible to non-experts.

The aim of this work is to explore the relationships among the attributes of the World of Warcraft (WoW) players in order to extract profiles and to present a regression model that shows the probability of a player renewing the subscription. Our study contributes to a better understanding of the flow of players in massively multiplayer online games and supports improvements in the business

Figura I.3: *E. S. Siqueira, T. A. A. Santos, C. D. Castanho and R. P. Jacobi, "Estimating Player Experience from Arousal and Valence Using Psychophysiological Signals," 2018 17th Brazilian Symposium on Computer Games and Digital Entertainment (SBGames), 2018, pp. 107-10709, doi: 10.1109/SBGAMES.2018.00022.*

2018 17th Brazilian Symposium on Computer Games and Digital Entertainment (SBGAMES)

Estimating Player Experience from Arousal and Valence using Psychophysiological Signals

Elton S. Siqueira, Thiago A. A. Santos, Carla D. Castanho and Ricardo P. Jacobi

Department of Computer Science

University of Brasilia, UnB

Brasília, Brazil

Email: eltonsarmanho@gmail.com, thiagoaas1990@gmail.com, carlacastanho@unb.br, jacobi@unb.br

Abstract—This work proposes a process for an assessment of Player Experience. In a simple way, the emotions are extracted according to arousal and valence values using a bi-dimensional model of affective states. The proposed process obtains affective states from two psychophysiological signals (Facial Expressions and Electrodermal Activity). Standard methods and Principal Component Analysis were used to extract a set of features from the collected signals. In this paper we propose to model a fuzzy system to assess Player Experience.

Keywords—Player Experience, GUR, Emotion, Physiological Measures

I. INTRODUCTION

The main goal of most digital games is to provide players appropriate and positive experiences that are linked to fun [1], [2]. A game designer also often crafts different game scenes to generate experiences like fear, anger and surprise, among others. For this reason, it is essential that developer teams manage to measure whether these experiences are actually reached. A great interest has been seen in emotional and affective aspects of user experience (UX), mainly in digital games. The UX in the games industry context is known as **Player Experience (PX)**, which focuses on the quality of users interaction with the game, by taking users' emotions and attitudes into account [3]. In the last years, Game User Research (GUR) was often done unconventionally within game industry, e.g. the process of selection of game testers had no specific criterion. Nowadays, GUR is a strict process with its own set of methodologies, and always finding new ways to improve the player experience [4], [1]. Even with an increasing number of techniques, researchers and game developers have difficulties to make effective evaluation of the player experience [1].

The current approaches for evaluating player experience are widely based on procedures that have been adapted from other fields, repurposed in the domain of GUR [5]. It has been adopted by the game industry, as it can generate meaningful user insights, which could generate a competitive advantage for game companies [6]. However, the success of conducting GUR is largely dependent on the appropriate application of methods which are traditionally reserved for

productivity analysis on software, which are not specific to games. Approaches for evaluating player experience are grounded in a variety of fields and research protocols. The evaluation process varies among game developers; also, elements like target audience, platform and genre can affect the methods for evaluating games [5].

Conventional evaluation methods have been adopted with some success for evaluating player experience, and include both subjective and objective techniques. The most usual procedure is through subjective self-reports, including questionnaires, interviews, and by means of objective reports from observational video analysis. However, these approaches solely rely on player's subjective responses, and hardly capture real experiences in while players feel them on the spot [7], [1].

In this study, we explore an approach of using physiological signals and facial expressions to evaluate player experience. This approach has some potential advantages: first, it enables in-situ assessment of player experience during the game play without breaking the player's immersion; secondly, once applied successfully, it could allow a more objective measurement of the experiences during a game session. The psychophysiological signals (such as electrodermal activity and facial expressions) are involuntary, consequently, those captured data are useful to detect the real experience of the player.

The purpose of this paper is to presented new way to evaluate the player experience by using: i) the concepts of emotion; ii) Thayer's AV-Space; iii) psychophysiological signals; and iv) fuzzy logic. These different subjects are combined in a process to more accurately estimate the actual user experience during a game session.

The remaining of this paper is organized as follows. The second section presents fundamental concepts we deal with in this work. In Section 3 we describe some related works. The details about the experiment in this study are given in Section 4. In section 5 we show the details about the fuzzy model created. The results we obtained are shown in Section 6. At last, the Sections 7 and 8 we give some final considerations.

Figura I.4: “An Automated Approach to Estimate Player Experience in Game Events from Psychophysiological Data”

Multimedia Tools and Applications
<https://doi.org/10.1007/s11042-022-13845-5>



An automated approach to estimate player experience in game events from psychophysiological data

Elton Sarmanho Siqueira¹ · Marcos Cordeiro Fleury² · Marcus Vinicius Lamar² · Anders Drachen¹ · Carla Denise Castanho² · Ricardo Pezzuol Jacobi²

Received: 4 December 2020 / Revised: 18 April 2022 / Accepted: 6 September 2022
© The Author(s), under exclusive licence to Springer Science+Business Media, LLC, part of Springer Nature 2022

Abstract

Games User Research (GUR) is a relevant field of research that exploits knowledge on human-computer interaction, game design, and psychology, with a focus on improving the player experience (PX) and the quality of the game. Games form an environment of rich interactions which can lead to a variety of experiences for the player. Researchers employ new ways to assess PX over time with some degree of precision, while avoiding the interruption of gameplay. A possible way of attaining great PX evaluation can be using psychophysiological data. It is a source that can provide relevant details about the emotional states and a potential information in the context of GUR. This paper presents a process for classifying PX in games based on psychophysiological data acquired from the user during the gameplay. Biosensors and a webcam were employed to capture three signals: Galvanic Skin Response (GSR), Blood Volume Pulse (BVP) and Facial Expression. Our artificial neural network was trained with a dataset formed by psychophysiological data and human-annotated emotional expressions derived from assessment and judgment of players' face and behavior with the help of an emotion annotation tool. Four classes of emotions, derived from the most significant game events, are considered for classification: Anger, Calm, Happiness and Sadness. The experimental results indicate that the proposed method leads to good human emotion recognition, and an accuracy score of 64%. The automatic assessment of player experience was compared with a traditional evaluation based on self-report, corroborating the effectiveness of the method.

Keywords Player experience · Psychophysiological data · Games · Biometric sensors · Machine learning · Emotion classification

—

Anexo II

Documento referente ao Termo de Consentimento Livre e Esclarecido

Figura II.1: Termo de Consentimento Livre e Esclarecido



TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO

(De acordo com as normas da Resolução nº 466, do Conselho Nacional de Saúde de 12/12/2012)

Você está sendo convidado para participar da pesquisa **Processo de avaliação automatizada de jogos utilizando dados psicofisiológicos**. Você foi selecionado através de um **questionário** e sua participação não é obrigatória. A qualquer momento você pode desistir de participar e retirar seu consentimento. Sua recusa não trará nenhum prejuízo em sua relação com o pesquisador ou com a instituição.

Os objetivos deste estudo é **testar um modelo multimétodo de análise de game design e investigar o impacto de diferentes técnicas de avaliação de jogos**.

Sua participação nesta pesquisa consistirá em interagir com um jogo, de modo que serão coletados dados fisiológicos através do uso de sensores, expressões faciais (utilização de uma webcam para gravar seu rosto durante experimento) e por fim, registro da sua interação com jogo. Além disso, você será convidado realizar julgamento (ou avaliação) das sessões que você realizou (uma sessão consiste em média 3 minutos) através de uma ferramenta de anotação de estados afetivos.

Os riscos relacionados com sua participação são nulos, de modo que o ambiente do experimento e os equipamentos são seguros, não levando uso de produtos químicos ou equivalentes.

Os benefícios relacionados com a sua participação é ajudar diretamente um projeto de pesquisa de doutorado e graduação, de modo a fornecer dados experimentais fidedignos. As informações obtidas através dessa pesquisa serão confidenciais e asseguramos o sigilo sobre sua participação. Os dados não serão divulgados de forma a possibilitar sua identificação. Ao final da análise dos dados, todas as informações como vídeos e áudios pertinentes a sua participação serão excluídas.

Uma cópia deste Termo de Consentimento Livre e Esclarecido ficará com o senhor (a) ou será enviado por E-mail (digitalizado), podendo tirar suas dúvidas sobre o projeto e sua participação, agora ou a qualquer momento com o pesquisador responsável ELTON SARMANHO SIQUEIRA no e-mail eltonss@ufpa.br ou no telefone (61) 999440636

Pesquisador Responsável

Declaro que entendi os objetivos, riscos e benefícios de minha participação na pesquisa e concordo em participar.

Brasília, _____ de _____ de 20____.

Sujeito da pesquisa

Pai / Mãe ou Responsável Legal (Caso o sujeito seja menor de idade)