



Universidade de Brasília

Instituto de Ciências Exatas
Departamento de Ciência da Computação

O uso de dados afetivos para implementação de algoritmos de ajuste dinâmico de dificuldade em jogos

Divino J. B. Lopes

Monografia apresentada como requisito parcial
para conclusão do Curso de Engenharia da Computação

Orientadora
Prof.a Dr.a Carla Denise Castanho

Brasília
2023

Dedicatória

Dedico este trabalho à minha família, principalmente aos meus pais, que possibilitaram que eu me dedicasse à graduação e sempre me apoiaram a concluir o que comecei. Dedico também a cada professor que passou pela minha vida acadêmica por terem me proporcionado um ótimo ensino que levarei para a vida toda e, em especial, a Professora Doutora Carla Denise Castanho, que esteve em minha vida acadêmica desde o início da graduação e guiou muito do que se tornaria minha área preferida do curso, os jogos digitais. Por último, mas não menos importante, dedico aos meus amigos, em especial à Leandra e à minha equipe de trabalho, que me deram apoio em diversos momentos onde foram necessários.

Agradecimentos

Primeiramente, gostaria de agradecer a Professora Doutora Carla Denise Castanho pela orientação e contribuição com informações e fontes de informações na confecção do presente trabalho e pelo investimento de tempo feito. Agradeço também aos Professores Doutores Tiago Barros Pontes e Silva e Mauricio Miranda Sarmet por fazerem parte da banca avaliadora deste trabalho. Também sou grato aos estudantes e pesquisadores que abordaram esse assunto previamente fornecendo conhecimentos importantes para esse trabalho. E por fim, gostaria de agradecer a Universidade de Brasília, que fornece um ensino de altíssima qualidade para um enorme número de pessoas, do qual tenho orgulho de fazer parte, levando e gerando conhecimento estimulando o progresso humano, tanto a nível pessoal em cada um de nós, estudantes, quanto a nível de humanidade, com as inúmeras pesquisas produzidas.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES), por meio do Acesso ao Portal de Periódicos.

Resumo

Mercado de jogos vem crescendo cada vez mais, movimentando mais dinheiro e incluindo mais pessoas. Apesar de se tornar cada vez mais um negócio, ainda tem suas bases fundadas como um passatempo e uma fonte de entretenimento, como um filme. Porém, por exigir uma forte interação do usuário e visto que todos acontecimentos que acontecem dentro do jogo decorrem das ações do mesmo, pode ser que em certos momentos a experiência do usuário se torne monótona ou frustrante. Uma das principais causas para essa interferência na experiência do usuário é a dificuldade presente no jogo. Nesse contexto foram desenvolvidas técnicas de adaptação de dificuldade em tempo de execução, de modo que a dificuldade do jogo se adaptasse às habilidades do jogador com o objetivo de tornar a experiência mais equilibrada. Atualmente, a técnica de adaptação de dificuldade mais difundida, baseia-se no desempenho do usuário. Entretanto, existem aspectos fisiológicos do jogador que podem fornecer informações mais fidedignas acerca do estado emocional do jogador durante uma seção de jogo. Nesse sentido, as investigações com o uso de dados fisiológicos para ADD vêm crescendo. Expressões faciais, resposta galvânica na pele, batimentos cardíacos, dentre outros sinais, são coletados e interpretados para detectar o estado afetivo do jogador. Portanto, este trabalho visa fazer um levantamento e apresentar uma análise dos estudos mais relevantes com o emprego de dados fisiológicos para ajustar dinamicamente a dificuldade em jogos eletrônicos. Para isso, os bancos de pesquisas ACM Library, IEEE Xplore e Springer Books foram consultados com o objetivo de coletar todos os trabalhos que abordaram esse assunto anteriormente sendo necessário uma filtragem dos trabalhos retornados nas buscas. Após a filtragem, foi possível uma leitura mais aprofundada de todos os trabalhos respondendo perguntas como quais são os gêneros de jogos mais utilizados para o ajuste dinâmico de dificuldade, quais eram os meios de aquisição de sinais fisiológicos mais utilizada e quais relações podem ser feitas entre os resultados dos trabalhos, além de retirar outras informações dessas pesquisas, como os avanços no uso de sensores para biosinais.

Palavras-chave: dificuldade dinâmica adaptativa, dados afetivos, algoritmos DDA

Abstract

Game market is growing up increasingly, moving more money and get including more people. Although games are becoming a business area, still have your basis being a hobby and a fun source, as a movie. However, for demanding a strong interaction from the user, since all events that happens inside the game happens in function of user actions, the user experience becoming boring, monotonous or frustrating is a possibility in certain moments. This interference in the user experience can elapses from the difficult in the game mostly. In this context, many run-time adaptation of difficulty's techniques was developed in order to adapt the game's difficulty to the player skills and make the experience more balanced. Nowadays, the most usual technique of difficulty's adaptation is based on user's performance. Nevertheless, there's player's physiological aspects that can supply more reliable infos about the player's emotional state during the gameplay. In this way, studies using physiological data to DDA is growing up. Facial expressions, galvanic skin response, heart rate and others signal are collected and interpreted to detect the player's affective state. Therefore this work aims to make a research and to show a analysis of the most relevant studies with the use of physiological data in order to adjust dynamically the difficulty in electronic games. Aiming this, the studies libraries ACM Library, IEEE Xplore and Springer Books were consulted in order to collect all the researches that approached this topic before and a systematic filtering was needed. After the filtering, a deeper reading in every studies was possible answering questions such as which type is mostly used to the dynamic difficulty adjustment, which biofeedback is mostly used, what relations may be observed between all studies, and get others information from these researches, like the development of biosignal's sensors.

Keywords: adaptative dinamic difficult, affective data, ADD algorithm

Sumário

1	Introdução	1
2	Fundamentação Teórica	3
2.1	Emoções	3
2.2	<i>Flow</i> e Imersão	4
2.3	Ajuste Dinâmico de Dificuldade (ADD)	7
2.4	<i>Biofeedback</i>	8
3	ADD Afetivo na Prática	11
3.1	Método	11
3.2	ADD baseado em Batimentos Cardíacos	12
3.3	ADD baseado em Eletroencefalograma	15
3.4	Detecção de <i>Flow</i> utilizando Expressões Faciais	23
3.5	ADD afetivo na terapia de Acrofobia	27
3.6	ADD baseado na Resposta Galvânica da Pele	28
3.7	ADD em Exergames para Reabilitação	32
3.8	ADD baseado em Espectrografia Funcional de Infravermelho Próximo (fNIRS)	35
3.9	ADD Afetivo baseado em autorrelato	38
3.10	ADD baseado na Dilação da Pupila	42
3.11	Computação Afetiva para adaptação automática em jogos de Reabilitação	44
3.12	ADD Híbrido	48
3.13	ADD baseado em atividade eletrodermal e expressões faciais	52
3.14	ADD baseado em Eletromiografia	55
4	Discussão	60
4.1	Tipos de jogos mais utilizados nos estudos de ADD	61
4.2	Fonte de dados afetivos mais utilizada	62
4.3	Resultados obtidos pelos trabalhos relatados	63
4.4	Estudos e aprimoramentos com sensores	64

5 Conclusão	66
Referências	68

Lista de Figuras

2.1	Oito conceitos de emoções descritas em um círculo [1]	4
2.2	Relação entre o nível do desafio e a habilidade demonstrando a zona do <i>Flow</i> [2]	5
2.3	Diferentes jogadores possuem diferentes zonas de <i>Flow</i> [2]	6
2.4	Designers adaptam a experiência ótima para o jogador baseando-se em escolhas feitas dentro da própria experiência [2]	6
3.1	Captura de tela dos três cenários utilizados na primeira população de teste, sendo a primeira (da esquerda para a direita) representando um acidente de trânsito, a segunda, um incêndio, e a terceira, um descarrilamento de trem [3]	13
3.2	Figura representando como cada subsistema interage dentro do sistema [4]	17
3.3	Figura representando os elementos presentes dentro do jogo [4]	17
3.4	Figura representando os elementos do ritmo [4]	19
3.5	Captura de tela do jogo desenvolvido sendo jogado por um jogador de baixo desempenho [4]	20
3.6	Captura de tela do jogo desenvolvido sendo jogado por um jogador de alto desempenho [4]	20
3.7	Médias de valores do nível de atenção (azul), desempenho (vermelho), o valor global (g) (verde) e o dificuldade (roxo) [4]	21
3.8	Médias de valores do nível de atenção (azul), desempenho (vermelho), o valor global (g) (verde) e o dificuldade (roxo) separando em grupos [4] . . .	22
3.9	Captura de tela do jogo em execução mostrando o <i>feedback</i> da câmera e do nível de dificuldade [5]	24
3.10	Gráficos mostrando os resultados dos experimentos [5]	25
3.11	Gráficos mostrando os resultados das perguntas feitas a cada rodada [5] . .	26
3.12	Cena do jogo <i>Asteroids: in the 2nd and 1/2th Dimension</i> [6]	29
3.13	Pulseira <i>Empatica E4</i> [6]	29
3.14	Média de mortes por nível [6]	30
3.15	Média de duração por nível [6]	31

3.16	Média de ajustes feitos por nível [6]	31
3.17	<i>Nintendo Wii Balance Board</i> [7]	32
3.18	<i>Microsoft Kinect</i> [8]	33
3.19	Arquitetura utilizada no experimento [9]	34
3.20	Planejador de Percurso de UAV [10]	36
3.21	Sensor fNIRS utilizado [10]	37
3.22	Arquitetura utilizada para a aquisição dos dados do sensor [10]	37
3.23	Jogo desenvolvido e utilizado nessa pesquisa [11]	39
3.24	Dois variantes de diálogo desenvolvidas sendo a primeira um diálogo propriamente dito e a segunda, um questionário [11]	40
3.25	Média e desvio padrão das respostas da população do pré-estudo acerca da dificuldade em cada nível [11]	40
3.26	Resultados da pesquisa [11]	41
3.27	SMI-RED [12]	42
3.28	Diâmetro da pupila normalizado para cada experimento [13]	43
3.29	Correlação entre as emoções segundo as respostas do questionário. Quanto mais próximo do azul escuro, mais positivamente correlacionado, enquanto quanto mais próximo do vermelho escuro, mais negativamente correlacionado. [13]	43
3.30	Arquitetura do <i>framework</i> desenvolvido [14]	44
3.31	Concordância da questão 2 com relação as subquestões antes e depois da execução da validação [14]	47
3.32	Respostas da questão 3 seguindo a escala <i>Likert</i> [14]	48
3.33	Fluxo dos dados na implementação híbrida do ADD [15]	49
3.34	Capturas de tela mostrando a alteração da distância horizontal entre as plataformas [15]	49
3.35	Capturas de tela mostrando a alteração da distância vertical entre as plataformas [15]	49
3.36	Capturas de tela mostrando a alteração da altura do pulo [15]	50
3.37	Média e desvio padrão para o valor de dificuldade medido pelo questionário na segunda bateria e dividido entre os três conjuntos de dificuldade [15]	51
3.38	Captura de tela do jogo para níveis fáceis de dificuldade (excitação baixa) [16]	53
3.39	Captura de tela do jogo para níveis difíceis de dificuldade (excitação alta) [16]	53
3.40	<i>Box plots</i> dos itens do questionário de engajamento no jogo medidos [16]	55

3.41	<i>HTC Vive</i> sendo utilizado de forma conjunta com uma versão protótipa do sensor <i>Faceteq</i> [17]	55
3.42	Supermercado criado em realidade virtual para a realização das tarefas tratando da <i>working memory</i> [17]	57
3.43	Museu criado em realidade virtual para a realização das tarefas tratando a <i>episodic memory</i> [17]	57
3.44	Tabela montada com as respostas dos participantes sobre cada versão com índices que vão de 0 a 4 [17]	59

Lista de Tabelas

3.1	Pontuação da primeira população sendo representada pelo tempo restante disponível para a solução do cenário [3]	14
3.2	Pontuação da segunda população sendo representada pelo tempo restante disponível para a solução do cenário, ressaltando que todos testes se encontravam em sua dificuldade mais alta [3]	15
3.3	Tabela montada a partir dos resultados apresentados por Balan et al. acerca dos parâmetros que mais se aproximam do que cada participante afirmou nas perguntas	28
3.4	Efeito do estado emocional na dificuldade [11]	39
3.5	Tabela montada com as informações sociodemográficas retiradas do trabalho [15]	51
3.6	Correlação dos estados fisiológicos e excitação inferidos pelas expressões faciais com os itens do questionário de engajamento no jogo [16]	54
3.7	Correlação dos estados fisiológicos e excitação com as emoções inferidas pelas expressões faciais [16]	54
3.8	Tabela com as regras do ADD implementado montada com informações do estudo [17]	56
4.1	Relação entre trabalhos e tipos de biofeedback utilizados	60
4.2	Relação entre o trabalho, o nome do jogo (NC=Não consta), o propósito do jogo utilizado (A=Aplicado, E=Entretenimento), seu gênero, os parâmetros ajustados e o sensor empregado	61

Lista de Abreviaturas e Siglas

ADD Ajuste Dinâmico de Dificuldade.

DBSR Autorrelato Baseado em Diálogos (*Dialog Based Self-report*).

DSA *Data Subset Analysis*.

EDA Atividade Eletrodermal (*Electrodermal Activity*).

EEG Eletroencefalograma.

EMG Eletromiografia.

FE Expressões Faciais (*Facial Expressions*).

fNIRS Espectrografia Funcional de Infravermelho Próximo (*Functional Near-Infrared Spectroscopy*).

GEngQ Questionário de Engajamento no Jogo (*Game Engagement Questionnaire*).

GSR Resposta Galvânica da Pele (*Galvanic Skin Response*).

HR Frequência Cardíaca (*Heart Rate*).

IA Inteligência Artificial.

MS Sensor de Movimento (*Motion Sensor*).

PD Dilatação da Pupila (*Pupil Dilatation*).

RTA *Real-Time Arousal Set*.

UAV Veículo Aéreo Não-tripulado (*Unmanned Aerial Vehicle*).

Capítulo 1

Introdução

Nos últimos anos, o número de trabalhos relacionados ao ajuste dinâmico de dificuldade sendo aplicado em jogos tem crescido. Dentre esses trabalhos, a maioria aborda somente o uso de dados relacionados ao desempenho do jogador [18] para realizar o correto ajuste em tempo real. Esse fenômeno pode possuir como hipótese para base o fato de que é um método que não requer acessórios extras para sua implementação, visto que basta monitorar o desempenho do jogador utilizando o próprio dispositivo que executa o jogo [19].

Entretanto, cada vez mais são desenvolvidos estudos que abordam o uso de alguns sinais emitidos para o corpo humano para inferir o estado emocional. Ou seja, através de sensores, adquirir informações do indivíduo e deduzir o estado emocional do jogador baseando-se nessas informações coletadas [20, 21]. Com isso, pode-se utilizar estas técnicas para inferir o estado emocional do jogador para mantê-lo imerso na experiência do jogo, como defende Chen [2] ao propor um modelo de otimizar a experiência do jogador. Isso motivou o desenvolvimento de muitos estudos abordando o Ajuste Dinâmico de Dificuldade baseando-se em dados afetivos ([17, 10, 14], por exemplo). Porém, esses estudos geram diversas abordagens sem deixar de seguir o foco do ADD afetivo tornando um pouco complexo saber quais são os melhores caminhos dentro desse ramo do ADD.

Portanto, para uma melhor organização do conhecimento em torno do ADD afetivo, uma revisão crítica de literatura se mostra necessária. Analisando os trabalhos mais recentes produzidos abordando esse assunto para que informações importantes possam ser reunidas, principalmente, quando comparados uns aos outros. Com isso, pode-se levantar 3 questões fundamentais para a pesquisa e importantes sobre o ADD afetivo:

1. Qual é o tipo de jogo mais utilizado para a adaptação?
2. Quais costumam ser os parâmetros ajustados para que ocorra o ADD?
3. Qual é a fonte de dados afetivos mais utilizada nos estudos mais recentes, ou seja, se há alguma metodologias mais empregada?

4. Quais evidências são apresentadas para elucidar a correlação entre os biosinais e o estado afetivo do jogador durante o jogo?

O principal intuito é, com base na análise dos trabalhos que se encaixam no escopo da pesquisa, apontar os principais resultados obtidos pelos autores e agregar um conjunto de informações sobre cada método de aquisição de dados respondendo, dessa forma, as questões fundamentais da pesquisa. Com isso, objetiva-se, também, gerar um guia para futuras pesquisas relacionadas ao tema abordado.

Para isso, este trabalho propõe analisar os trabalhos feitos utilizando a implementação do ajuste dinâmico em jogos utilizando dados fisiológicos, como a atividade cerebral, as expressões faciais e os batimentos cardíacos emitidos pelo usuário. Objetivando delimitar quais artigos participariam do estudo e facilitar a busca dos estudos, o escopo foi definido sendo artigos publicados pela *ACM Library*, *IEEE Xplore* e *Springer Books* entre os anos 2014 e 2022.

Para uma melhor organização, este trabalho está dividido nos seguintes capítulos:

Capítulo 2 Para melhor compreensão do corpo desse trabalho, este capítulo conta com uma apresentação dos conceitos básicos que envolvem os estudos aqui analisados.

Capítulo 3 Neste capítulo são descritos todos os trabalhos que foram considerados relevantes no contexto de ajustes dinâmico de dificuldade em jogos com o uso de algum sinal fisiológico. Para cada um, são descritos a abordagem empregada, a metodologia e os resultados obtidos.

Capítulo 4 Dedicar-se a apresentar o resultado das análises feitas usando como base os artigos. Consequentemente, neste capítulo, as questões fundamentais da pesquisa são respondidas.

Capítulo 5 Aponta as conclusões desta pesquisa e sugestões de trabalhos futuros.

Capítulo 2

Fundamentação Teórica

2.1 Emoções

Emoções normalmente são modeladas utilizando sistemas que partem das perspectivas discreta [22, 23, 24, 25] e multidimensional [1, 26].

No modelo discreto, Ekman, Sorenson e Friesen [23] apontam que tem-se 6 emoções básicas. As emoções básicas seriam felicidade, tristeza, raiva, medo, desgosto e surpresa, sendo esse conjunto utilizado como base em vários estudos [24, 25]. Entretanto, quando comparado com os estudos de Izard e Ackerman [22] e Hupont et al. [24], é perceptível que, a depender da necessidade do estudo, algumas emoções tidas como básicas podem ser alteradas, como foi o caso da vergonha e do interesse [22], ou adicionadas, como o neutro [24]. Contrapondo o conceito de emoções básicas criado por Ekman et al., existem as emoções complexas, que podem ser, por exemplo, a culpa, o orgulho e a vergonha, como apontado por Hudlicka [25]. Estas emoções, diferentemente das emoções básicas, são difíceis de serem detectadas, por terem um componente cognitivo maior. Além disso, possuem a características de ter predisposição para que cada indivíduo reaja de uma forma particular a essas emoções [25].

Já no modelo multidimensional, temos como forte referência o modelo de Russell [1], que afirma que psicólogos, baseados em fatores, tendem a descrever as emoções em um conjunto de várias dimensões, onde cada emoção seria uma combinação das dimensões bases e descreveria um estado psicológico. Essas emoções estariam interconectadas podendo ser representadas em um círculo, que pode ser visualizado na Figura 2.1. A partir do eixo X (ângulo 0°) nesta figura e girando no sentido anti-horário, teremos o agrado, a agitação, a excitação, a angústia, o desgosto, a tristeza, a sonolência, e o contentamento. Nessa figura também, podemos constatar que todas as emoções podem ser resumidas em dois eixos, assim como Russell[1] propõe, sendo eles: o nível de excitação (eixo Y) e a valência (eixo X). Ou seja, no eixo vertical, temos o quanto a atenção do indivíduo está

básico para o que é chamado de *Flow* em seu livro abrangendo o termo para várias áreas, como o *Flow* na música e o *Flow* na degustação, que são situações físicas na qual coloca o indivíduo que vivencia essa experiência se encontra em um estado de imersão no qual toda sua concentração está presa a experiência em si, até chegar ao *Flow* no pensamento, no qual a pessoa é imergida em seus próprios pensamentos. Ou seja, com base na observação de várias pessoas de diferentes origens, ele explica, de forma holística, algumas formas que levam pessoas ao estado de imersão usando diversos sentidos, seja pelo olfato, pelo paladar, pela audição, pelo tato, que leva a pessoa a um estado imersivo, ou até mesmo um momento introspectivo, no qual a pessoa que experencia tem sensações como a desconexão do mundo e a perda da noção temporal quando navegando em seus próprios pensamentos.

Durante seu estudo, Csikszentmihalyi define que o nível de dificuldade deve ser proporcional a habilidade do indivíduo para que ele obtenha experiência em sua forma ótima. Pensando nisso, Chen [2] gerou três constatações em forma de gráficos, representados nas Figuras 2.2, 2.3 e 2.4. A Figura 2.2 visa demonstrar o conceito deixado por Csikszentmihalyi, o qual aponta que a zona de *flow* corresponde a zona na qual as habilidades do indivíduo são proporcionais às dificuldades expostas a ele, enquanto a zona de tédio fica abaixo do *flow* (quando as habilidades estão além da dificuldade) e a zona de ansiedade, acima (quando as habilidades estão aquém da dificuldade). Já a Figura 2.3 demonstra que diferentes jogadores podem ter diferentes zonas de *flow*, o que demonstra que é natural que diferentes pessoas possam preferir diferentes níveis de dificuldade. Por fim, tem-se a Figura 2.4, que demonstra como designers podem ir moldando o nível de dificuldade em torno da zona de *flow* de cada jogador de forma procedural, gradativa e incremental.

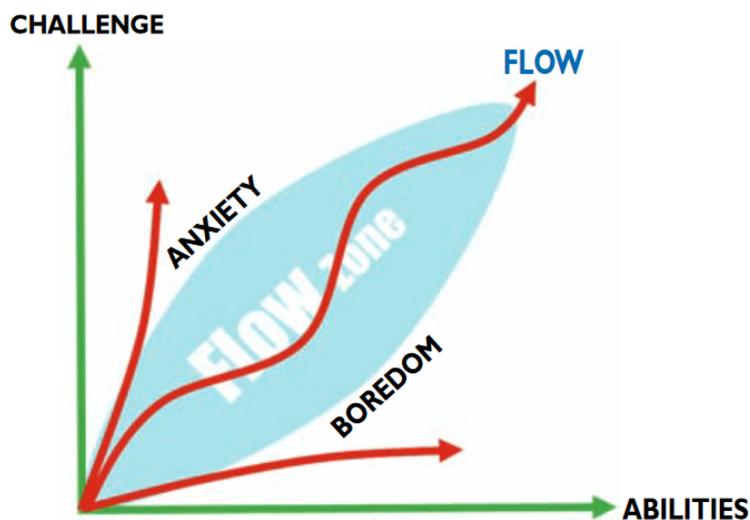


Figura 2.2: Relação entre o nível do desafio e a habilidade demonstrando a zona do *Flow* [2]

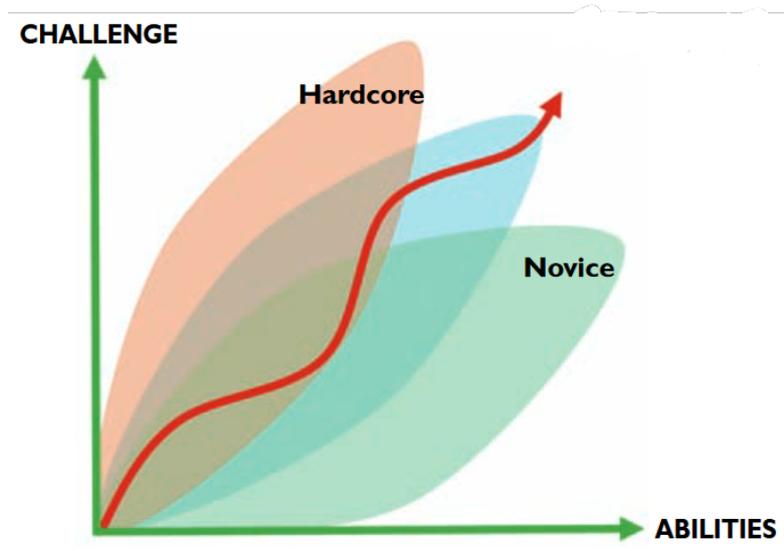


Figura 2.3: Diferentes jogadores possuem diferentes zonas de *Flow* [2]

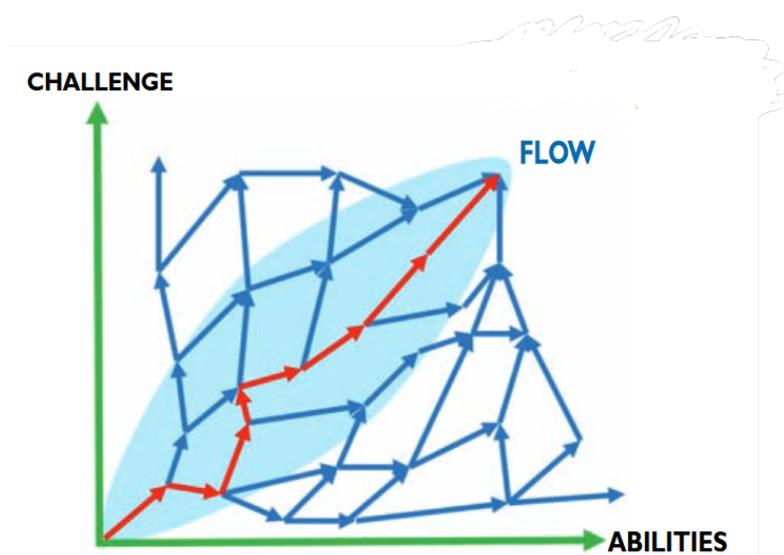


Figura 2.4: Designers adaptam a experiência ótima para o jogador baseando-se em escolhas feitas dentro da própria experiência [2]

Visando avaliar o *flow* experienciado pelo jogador durante algum jogo, Sweetser e Wyeth [28] propuseram um modelo avaliativo chamado *GameFlow*, no qual oito aspectos eram analisados, sendo eles: concentração, desafio, habilidades, controle, metas alcançadas, resposta, imersão e interação social. Entretanto, Bontchev e Dessileva [16] utilizaram em seu estudo outro modelo denominado Questionário de Engajamento no Jogo (*Game Engagement Questionnaire* (GEngQ)), o qual utiliza os aspectos presença, absorção, *flow*, imersão e engajamento. Essa variação demonstra que, assim como as emoções, a forma de

validar as emoções sentidas durante o *flow* podem variar de acordo com a necessidade ou apenas o modelo utilizado. Em ambos modelos, os aspectos são obtidos a partir de estimativas feitas sobre as respostas provenientes da aplicação de um questionário ao jogador, sendo assim, todos se tratam da percepção do jogador e podem não refletir a realidade e dificilmente podem ser mensurados utilizando algum sensor.

2.3 Ajuste Dinâmico de Dificuldade (ADD)

Os jogos podem se tornar frustrantes ou entediante em certas ocasiões e, às vezes, isso decorre da dificuldade do jogo. Assim, produzir um jogo no qual a dificuldade é ajustada em tempo real, poderá minimizar os episódios de frustração ou tédio, maximizando o estado de *flow* do jogador [2]. Como apontado por Ninaus [3], o ADD reflete uma forma automática de adaptar a dificuldade do jogo ao nível de desempenho de dado jogador em tempo real, ou seja, o ajuste deve ser feito de forma automática e sem a interferência direta do jogador. Para isso, são implementados algoritmos que coordenam esse ajuste em tempo real, os quais devem, de alguma maneira, se basear em dados provenientes do jogador, para realizar o incremento ou decremento da dificuldade. O método mais comum até então baseia-se nos dados de desempenho do jogador, principalmente por ser o método de mais fácil aquisição, bastando apenas coletar os dados a partir do próprio jogo [19, 18].

A adaptação pode ocorrer de duas formas: pela geração procedural de conteúdo [4, 29, 30] ou pelo ajuste de parâmetros dentro do jogo [15, 16, 5]. No primeiro caso, os níveis são criados conforme o jogador progride na fase e, conforme a necessidade, vão sendo gerados elementos que balanceiam a experiência do jogador. Já no segundo, os parâmetros estão sempre presentes no nível, entretanto, aspectos deles são alterados de acordo com a necessidade para balancear a experiência do jogador, como, por exemplo, a velocidade de obstáculos [6] e altura do pulo do personagem [15]. Nestas ocasiões, um algoritmo próprio do jogo faria o papel do designer no desenvolvimento da experiência sem a perda do *flow*, como apontado por Chen [2] na Figura 2.4.

Embora os dados de desempenho nos digam muito a respeito da interação do jogador com o jogo, eles certamente não conseguem obter informações mais precisas sobre o atual estado afetivo do jogador, visto que Chen afirma que diferentes jogadores almejam diferentes níveis de desafio [2]. Assim, um método alternativo de ajuste dinâmico de dificuldade vem sendo estudado. Trata-se do uso de sensores que coletam dados fisiológicos do jogador, os chamados biosensores, para a partir deles inferir o estado afetivo do jogador, que servirá de base para a realização do ajuste dinâmico de dificuldade. Estudos demonstram superioridade entre esta quando comparada com a tradicional forma baseada no desempenho do jogador [15].

2.4 *Biofeedback*

Para o uso do ADD afetivo, como dito anteriormente, é necessário formas de aquisição de dados acerca do estado atual do jogador. Para isso, há diversas abordagens e sensores a serem utilizados. Nos trabalhos utilizados nesse estudos, foram utilizados os seguintes meios:

- **Expressões Faciais (*Facial Expressions*) (FE)** referem-se às expressões faciais do jogador durante o jogo. As expressões faciais podem ser capturadas de duas formas diferentes. Na primeira, imagens da face do usuário são capturadas em uma determinada frequência utilizando uma câmera e processadas por uma inteligência artificial [31, 32] a fim de detectar níveis de excitação e valência [5, 16]. Já a segunda forma, utiliza como base a Eletromiografia (EMG), que é uma técnica que envolve investigar as contrações musculares baseando-se nas correntes elétricas que são criadas pelo músculo durante esse evento [33] e, com essas leituras, estimar a expressão facial do indivíduo [17]. Para a leitura desse sinal, vários eletrodos são utilizados, como, por exemplo, o dispositivo criado pela *Faceteq* (Figura 3.41). Como esse método depende de uma Inteligência Artificial (IA) trabalhando para a categorização das emoções e essas IAs se encontram em constante desenvolvimento, as emoções a serem detectadas e categorizadas podem variar de acordo com a necessidade do estudo ou IA utilizada. Por exemplo, a *Affective Affdex SDK* permite tanto a obtenção dos valores de excitação e valência [5] quanto a identificação direta de cada emoção [31].
- **Frequência Cardíaca (*Heart Rate*) (HR)** diz respeito a frequência com a qual o coração do indivíduo bate. Esta forma de aquisição baseia-se no fato de que emoções influenciam substancialmente a saúde humana, sendo que um dos pontos afetados é justamente o ritmo cardíaco. Essa medida, normalmente, está atrelada ao nível de excitação demonstrado pelo usuário e pode ser utilizada para a detecção da felicidade, da tristeza, do medo, da tristeza e da paz [20].
- **Eletroencefalograma (EEG) e Espectrografia Funcional de Infravermelho Próximo (*Functional Near-Infrared Spectroscopy*) (fNIRS)** ambos dizem relação à atividade cerebral, entretanto, se diferenciam pelo fato de que o primeiro utiliza eletrodos para medir a atividade cerebral [34], enquanto o segundo utiliza infravermelho para a detecção de hemoglobina oxigenada e não-oxigenada presente no córtex préfrontal e baseia-se no princípio de que atividades neurais são acompanhadas de demanda de oxigênio, como aponta Afergan et al. [10]. Afergan et al. também apontam em seu estudo que essas medidas estão fortemente correlacionadas com o nível de atenção apresentado pelo usuário.

- **Atividade Eletrodermal (*Electrodermal Activity*) (EDA) ou Resposta Galvânica da Pele (*Galvanic Skin Response*) (GSR)** diz respeito a alteração das propriedades elétricas da pele conforme alterações nas emoções sentidas pelo jogador, visto que a mudança nas emoções do indivíduo afeta suas glândulas sudoríparas interferindo na condutância da pele [21]. Essas alterações podem ser captadas por dispositivos especializados nesta leitura, como a pulseira *Empatica E4* (Figura 3.13), como foi descrito por Bandeira et al. [6]. Estudos apontam que essas medidas levam a detecção do nível de estresse ou de entusiasmo [21, 15].
- **Sensor de Movimento (*Motion Sensor*) (MS)** está relacionado aos movimentos realizados pelo jogador durante o jogo e utiliza câmeras, como o *Microsoft Kinect* (Figura 3.18, ou outros dispositivos que fornecem informações acerca do movimento do jogador, como a *Nintendo Wii Balance Board* (Figura 3.17). Normalmente estão bastante atrelados a *exergames* [9], entretanto, existem estudos que analisam a viabilidade para outros jogos sérios [35]. Por se tratar de uma categoria um tanto quanto ampla, as emoções que podem ser detectadas por esse método podem variar de acordo com a necessidade do estudo facilmente.
- **Dilatação da Pupila (*Pupil Dilatation*) (PD)** diz relação ao nível de dilatação da pupila. A pupila é a abertura que controla a entrada de luz no olho e estudos apontam que ocorre sua dilatação quando o indivíduo está sobre uma carga mental [36], o que pode inferir também seu nível de atenção[13]. A dilatação da pupila pode ser medida através de câmeras como a SMI-RED (Figura 3.27) [13, 36].
- **Autorrelato Baseado em Diálogos (*Dialog Based Self-report*) (DBSR)** não caracteriza um dado fisiológico, propriamente dito, por consistir em perguntar ao usuário sobre como ele se sente no momento ou sobre um momento bem recente, ou seja, considerar apenas o autorrelato do usuário [11, 9]. Apesar de ser uma experiência um tanto quanto disruptiva, como aponta o estudo de Reidy et al. [17], pode ser empregada para melhorias a nível de técnicas de adaptação, como realizada por Frommel et al. [11].

Observando essa lista, pode-se notar que há a possibilidade de categorizar os meios de aquisição com base no nível de intrusividade apresentado pelo uso. Dessa forma, tem-se Expressões Faciais (*Facial Expressions*) (FE), que apenas necessitam da observação do indivíduo, o que exclui o uso da Eletromiografia (EMG), como menos intrusiva e menos disruptiva. Após isso, tem-se Autorrelato Baseado em Diálogos (*Dialog Based Self-report*) (DBSR), que, apesar de não ser intrusivo e não requisitar nenhum sensor, fornece uma experiência um tanto quanto disruptiva. E, por fim, temos todos os outros sensores,

incluindo o sensor de Eletromiografia (EMG), que necessitam de um sensor diretamente em contato com o indivíduo realizando leituras constantemente.

Capítulo 3

ADD Afetivo na Prática

Neste capítulo serão apresentados os trabalhos levantados para tal estudo elencando-os com um breve resumo apontando o intuito, a metodologia, como foram executados os experimentos e os resultados obtidos para cada trabalho.

3.1 Método

Para o levantamento, foram utilizados apenas os bancos IEEE Xplore, ACM Digital Library e o Springer e trabalhos produzidos entre os anos 2014 e 2022, portanto, é reconhecido que possivelmente há vários trabalhos que falem sobre o assunto foco dessa monografia, porém que foge do escopo de pesquisa por não estar no banco de dados citados. Para colher os trabalhos candidatos, foram utilizadas palavras-chaves como *bio-feedback*, *affective data*, *games*, *dynamic difficulty adjustment* e *emotion* e suas possíveis combinações.

Com essas buscas, foram obtidos algo por volta de 350 trabalhos, entretanto, a maioria, pouco mais de 300, desses artigos foram descartados em uma primeira análise baseando-se somente no resumo do trabalho candidato, que muitas vezes demonstravam como algo muito fora do escopo do presente trabalho, o ADD Afetivo ou Híbrido, caracterizando assim o primeiro critério para seleção dos trabalhos. Então, após baixar os trabalhos, uma leitura completa e bem mais aprofundada foi feita em cada, com o intuito de remover estudos que não faziam a adaptação da dificuldade utilizando dados afetivos como objeto principal do estudo. Além disso, foi estudado nesta etapa a possibilidade de agrupar alguns trabalhos por abordarem o mesmo aspecto ou por serem um desenvolvimento contínuo e mais profundo de outro. Ao se descartar um trabalho, ainda era estudado se o mesmo valeria para a fundamentação teórica ou para embasar futuras constatações. Ou seja, os trabalhos selecionados deveriam conter, explicitamente, uma aplicação ao ADD, deveriam

ter sido publicados entre os anos de 2014 e 2022, deveriam ter sido produzidos na língua inglesa e apresentar uma estrutura com a apresentação de resultados bem definida.

Após todos esses filtros aplicados, foram obtidos 14 trabalhos que respeitaram os critérios de ter como foco o ADD Afetivo ou Híbrido, propor adaptação no estudo ou propor claramente possíveis evoluções para que haja a adaptação e apresentarem a metodologia e os resultados de forma explícita. Entretanto, um estudo se mostrou a continuação de outra pesquisa, sendo assim, foram analisados juntos.

3.2 ADD baseado em Batimentos Cardíacos

Ninaus et al. [3] apresentaram um trabalho visando avaliar qual seria a viabilidade de usar a análise da frequência cardíaca do jogador para a implementação de Ajuste Dinâmico de Dificuldade em jogos de aprendizado. O intuito principal era analisar quão confiável seria o uso da frequência cardíaca para analisar o *Flow* do jogador dentro do jogo.

Os autores iniciam tal trabalho afirmando que um aspecto crucial do aprendizado ou da interação com jogos digitais é a possibilidade de adquirir uma vasta quantidade de dados e métricas do jogo, pois, utilizando esses dados, podemos ter ideias bem mais aprofundadas acerca da performance do jogador. Entretanto a maioria dos jogos se atém a medição de desempenho de jogadores apenas ao final de um determinado intervalo do jogo, normalmente, com a finalidade de dar uma pontuação para o jogador. Os autores também apontam que sensores fisiológicos estão se tornando cada vez mais acessíveis e fáceis de usar, porém, assim como o uso de dados relacionados a *gameplay* do jogador, apenas ao fim de um intervalo pré-determinado, criticando o uso de dados fisiológicos ao fim do jogo para apenas entender como o jogador se sentiu após o jogo ao invés de medir constantemente tais dados biológicos, principalmente porque isso seria peça fundamental para a melhor personalização e adaptação do jogo para o jogador.

Para motivar o uso da frequência cardíaca como fonte de dados biológicos, foram citados estudos anteriores que mostram que o grau de excitação da pessoa reflete em dados biológicos e, pensando em específico na frequência cardíaca, ela tende a aumentar proporcionalmente ao grau de excitação. Portanto, a frequência cardíaca se mostra viável para a aplicação, fortalecendo a tese apresentada pelos autores. Porém, ainda são necessários ensaios para corroborar essa afirmação e, para isso, foi proposto a implementação de um algoritmo de ADD em um jogo que visa treinar pessoas para situações de emergência, como acidente de trânsito ou incêndios, tendo um tempo limite para cada cenário e dificuldade. Para os ensaios foram desenvolvidos três cenários (acidente de trânsito, incêndio e, para a primeira população foi escolhido, descarrilamento de trem, já para a segunda população, incêndio em um posto de gasolina), que podem ser visualizados na Figura 3.1,

com três níveis de dificuldade cada e, conforme a frequência cardíaca do jogador varia, o jogo altera entre as dificuldades para que o jogo se adapte ao nível de excitação do jogador.



Figura 3.1: Captura de tela dos três cenários utilizados na primeira população de teste, sendo a primeira (da esquerda para a direita) representando um acidente de trânsito, a segunda, um incêndio, e a terceira, um descarrilamento de trem [3]

O jogo inicialmente se baseava em ajudar pessoas feridas em acidentes, apagando o fogo, prevenindo que outras casas e carros peguem fogo, evacuando pessoas e levando pessoas ao hospital, cada qual com o seu devido cenário. A versão adaptativa não mudava as possibilidades de acontecimentos, ou seja, não eram introduzidos novos fenômenos, porém a frequência e a complexidade com a qual tais fenômenos ocorriam era variada de acordo com o estado do jogador. Em outras palavras, se a frequência cardíaca indicasse um grande nível de excitação, a quantidade de eventos para um determinado momento seria reduzido, enquanto para o baixo nível de excitação, seria aumentado. A versão adaptativa também se iniciava com um tutorial de 2 minutos e colocava o jogador numa espera de 3 minutos para que fosse feita uma medição base para que se tenha um parâmetro acerca da média normal da frequência cardíaca do participante e seja possível dizer se a frequência subiu ou desceu.

Os experimentos foram separados em duas populações, sendo a primeira formada por 7 pessoas e a segunda, 15 pessoas, porém 3 tiveram problemas técnicos, reduzindo a população efetiva para 12 pessoas. A primeira população foi utilizada como base para o estudo, sendo assim, essa população foi exposta a uma versão não adaptativa do jogo e jogaram os três cenários em todas suas três dificuldades, de forma crescente, montando a Tabela 3.1 com o tempo restante para cada voluntário naquele cenário e naquela dificuldade em específico. O resultado disso foi que em dificuldades mais altas, muitos não conseguiram concluir o cenário por esgotarem o tempo disponível, agindo conforme o esperado. Já a segunda população jogou o jogo em todos seus três cenários duas vezes, sendo a primeira no seu nível mais difícil em uma versão não adaptativa e a segunda, na versão adaptativa. Os resultados dessa segunda população, que podem ser observados na Tabela 3.2, foi uma queda da porcentagem de finalização bem sucedida em todos os cenários. Com base nos

resultados, os autores concluem que adaptar o jogo é algo sensível e não irá fazê-lo mais fácil ou mais difícil que em um jogo não adaptativo. Ao fim, foi aplicado um *Flow-Short-Scale* que se trata de um questionário com 8 questões e esse questionário revelou que a maioria das pessoas considerou a versão não adaptativa mais fácil enquanto a versão adaptativa como mais desafiadora, portanto, talvez tenha sido provado o contrário do que se esperava.

	Acidente de Trânsito			Incêndio			Descarrilamento de Trem		
	Fácil	Médio	Difícil	Fácil	Médio	Difícil	Fácil	Médio	Difícil
P1	00:22	01:01	00:33	03:30	02:06	00:00	03:28	01:30	00:00
P2	00:41	00:58	00:45	04:06	01:45	00:19	03:01	00:00	00:00
P3	02:05	01:35	01:14	04:15	02:06	01:54	03:37	01:59	01:19
P4	00:35	00:58	01:43	00:00	03:06	00:00	02:34	01:14	00:00
P5	00:36	00:39	00:36	02:36	00:00	00:46	02:20	00:00	00:00
P6	00:01	00:00	00:12	02:42	00:00	00:00	02:28	00:00	00:00
P7	01:48	01:11	00:44	03:55	01:30	00:00	02:59	00:00	00:00

Tabela 3.1: Pontuação da primeira população sendo representada pelo tempo restante disponível para a solução do cenário [3]

	Versão Não Adaptativa			Versão Adaptativa		
	Acidente de Trânsito	Incêndio	Incêndio em um Posto de Gasolina	Acidente de Trânsito	Incêndio	Incêndio em um Posto de Gasolina
P1	00:49	00:00	00:00	00:00	00:00	00:00
P2	00:00	00:00	00:00	00:00	00:00	00:00
P3	00:00	00:00	00:00	00:00	00:00	00:00
P4	00:00	00:00	00:00	00:11	00:00	00:00
P5	00:04	00:00	00:00	00:00	00:00	00:00
P6	00:00	00:00	00:00	00:00	00:24	00:00
P7	00:50	02:41	01:55	00:58	00:00	00:00
P8	00:26	00:00	00:00	00:16	00:00	00:00
P9	00:00	00:00	00:00	00:00	00:00	00:00
P10	00:00	00:00	00:00	00:00	00:00	00:00
P11	01:02	00:00	00:00	00:00	00:00	00:00
P12	01:30	00:00	00:42	00:48	00:00	00:00

Tabela 3.2: Pontuação da segunda população sendo representada pelo tempo restante disponível para a solução do cenário, ressaltando que todos testes se encontravam em sua dificuldade mais alta [3]

É concluído com os autores apontando que, por meio do ADD baseado na frequência cardíaca, foi possível variar a taxa de sucesso dentro do jogo e manter os jogadores mais imersos dentro das situações apresentadas, que jogadores que participaram sem saber de tudo que estava envolvido no jogo encontraram uma experiência mais desafiadora e fascinante, como o jogo se propunha a ser. Para encerrar, é dito que em trabalhos futuros o DDA usando frequência cardíaca pode ser explorado em outros contextos, que não o treinamento de agentes de situação de emergência ou implementar o DDA sem que nenhum voluntário saiba para que seja possível estudar a reação dos participantes aos ajustes realizados.

3.3 ADD baseado em Eletroencefalograma

Fernández et al. [29] propõem um estudo envolvendo Geração Procedural de Conteúdo para a geração das fases em um jogo de plataforma associado com um sistema híbrido de ADD, no qual são utilizados como base os dados de desempenho e um eletroencefalograma para medir a atenção do jogador a cada momento. O trabalho foi iniciado em 2016 com

uma produção inicial e foi desenvolvido em 2017 [4], portanto, ambos trabalhos seguem a mesma premissa, apenas um complementando o outro.

Os autores reforçam que jogos podem oferecer uma experiência inadequada para jogadores de diferentes níveis de habilidade conforme seu *Game Design* é desbalanceado. Porém, para fazer tal balanceamento alterando de forma estática gerando níveis de dificuldade para cada tipo de jogador, seria algo bastante complicado, visto que existem vários tipos. Portanto, o ADD se mostra uma solução bastante adequada quando bem desenvolvido. Para corroborar o uso do EEG para a aquisição de dados afetivos do jogador, afirmam, baseando-se em estudos anteriores, que a imersão é parte fundamental para como a experiência do jogador é moldada e o nível de atenção empregada no jogo influencia em como a imersão varia.

Para a execução dos experimentos, os autores desenvolveram um jogo de plataforma 2D que calcula o desempenho do jogador em tempo real e combina com os dados do EEG obtidos através de um sensor chamado *Neurosky Mindwave Mobile*, que calcula internamente o nível de atenção do jogador, e possui tecnologia chamada *ThinkGear*, que permite interface entre as ondas cerebrais do jogador com o computador. A partir de ambos resultados, o jogo decide automaticamente qual nível de dificuldade deve ser apresentado para o jogador. Portanto, se os resultados do jogador em determinado momento são positivos, o nível de dificuldade é aumentado. Esses resultados alimentam um sistema de Geração Procedural de Conteúdo cujo método é chamado de *Rhythm-Group Theory* que foi implementado inicialmente por Gillian Smith et al. e tal método visa gerar automaticamente mapas para jogos de plataforma 2D que possa passar para o jogador uma ideia de ritmo gerando mapas agradáveis. Como os subsistemas do jogo se comunicam é representado na Figura 3.2 enquanto o jogo final pode ser observado nas Figuras 3.3, sendo:

- **A** Jogador
- **B** Inimigo derrotável
- **C** Inimigo invencível
- **D** Vão a ser pulado
- **E** Meta
- **F** Vida do jogador
- **G** Tempo de jogo
- **H** Nível atual

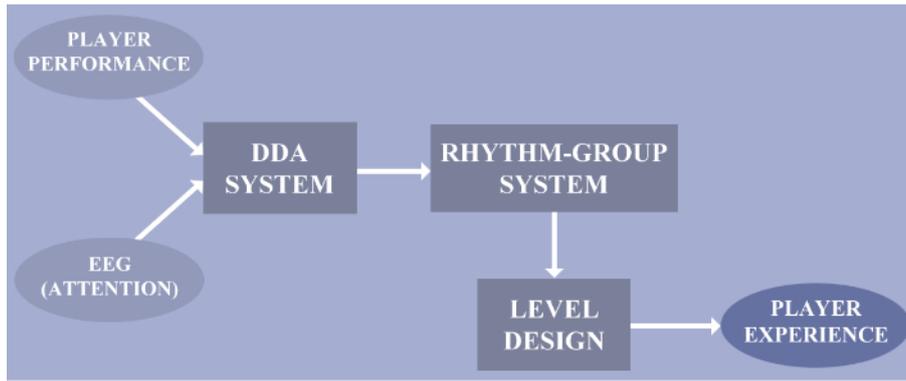


Figura 3.2: Figura representando como cada subsistema interage dentro do sistema [4]

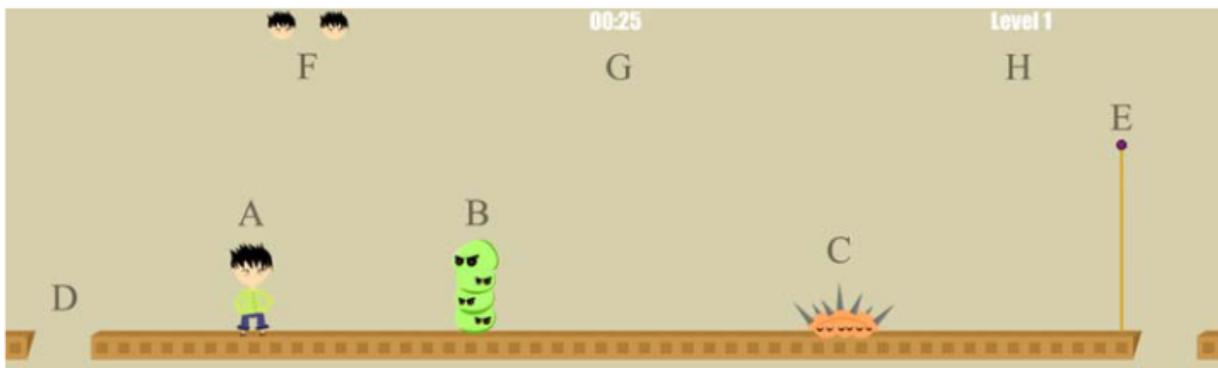


Figura 3.3: Figura representando os elementos presentes dentro do jogo [4]

O biosensor retorna valores de 0 a 100 mostrando o nível de atenção do jogador e então é feita uma média aritmética simples, provavelmente para que os valores sejam mais constantes e não haja grandes saltos de dificuldade a todo momento, somando todos os valores recebidos e dividindo a soma pela quantidade de valores. A esse resultado, daremos o nome de m . Já para a mensuração dos dados de desempenho do jogador, que chamaremos de p , é utilizado a Equação 3.1, onde d é o número de mortes, gT é o tempo de jogo, eT é o tempo esperado para finalização e W_1 e W_2 são pesos para quantas vezes o jogador morreu e quanto tempo o jogador deve levar para completar o nível, respectivamente. Para os testes, os autores deixaram W_1 configurado como 0.6 e W_2 , 0.4, ou seja, o número de morte é mais importante que a velocidade com a qual o jogador progride no jogo.

$$p = \frac{1}{d+1} * W_1 + \frac{gT}{eT} * W_2 \quad (3.1)$$

Agora calculando o valor efetivo, teríamos uma média aritmética ponderada entre m e p , mostrada na Equação 3.2, no qual se define qual forma de aquisição de dados

terá maior prioridade, dados afetivos ou dados de desempenho, respectivamente. Para os experimentos, os autores deixaram ambos com a mesma prioridade, sendo assim, $W_1 = W_2 = 0.5$.

$$g = p * W_1 + m * W_2 \quad (3.2)$$

Para passar os valores para o *Rhythm-Group System*, é necessário calcular o valor global (g) para cada elemento. Nisso, a Equação 3.1 é alterada para 3.3, na qual é feita uma espécie de porcentagem de vezes que o jogador morreu para um determinado tipo de elemento, que representa o quão fácil é para o jogador lidar com esse tipo de elemento. E o nível de atenção também é isolado para cada tipo de elemento fazendo a mesma média aritmética simples. Substituindo os novos valores em 3.2 chegamos na Equação 3.4. Esse cálculo é feito para que o *Rhythm-Group System* gere itens que o jogador tem mais facilidade de lidar e, conforme o tempo passa, o jogador pode melhorar seus valores em outros tipos de elementos recebendo novos elementos que antes tinha dificuldade.

$$p_{tipo} = \frac{1}{1 + h_{tipo} + d_{tipo}} \quad (3.3)$$

$$g_{tipo} = p_{tipo} * W_1 + m_{tipo} * W_2 \quad (3.4)$$

O *Rhythm-Group System* possui 4 variáveis internas:

- **Tipos de Ação** são os tipos de ação disponíveis para serem gerados. Observando a Figura 3.4, podemos observar que as ações disponíveis eram três tipos diferentes de pulo (baixo, médio e alto);
- **Tipo de Ritmo** diz sobre como as ações são distribuídas ao longo do mapa. Os autores usaram um ritmo regular, o que quer dizer que os eventos são igualmente espaçados;
- **Densidade de Ritmo** diz sobre quão perto, uma das outras, as ações serão distribuídas. Quanto melhor for os resultados do jogador, maior será a densidade de ritmo, flutuando entre 5 ações por ritmo até 50 ações;
- **Comprimento de Ritmo** diz sobre quão longo o mapa gerado será. Também gerado em cima dos resultados do jogador, quanto maior o resultado do jogador, mais longo será o mapa, flutuando entre 5 segundos e 30 segundos.

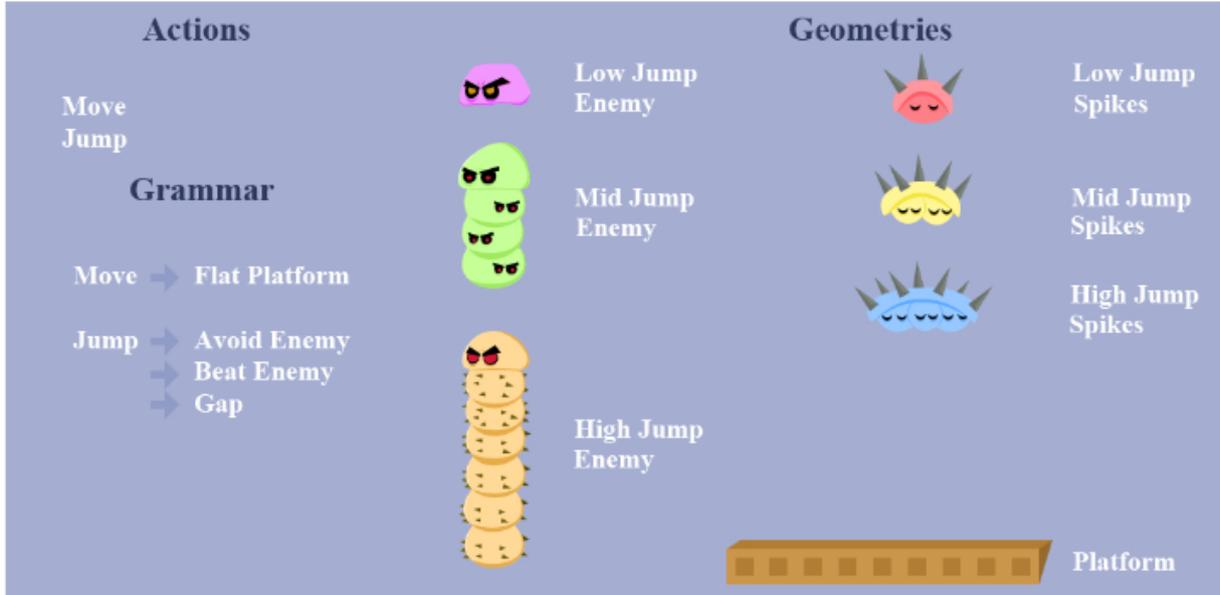


Figura 3.4: Figura representando os elementos do ritmo [4]

Tendo em mãos os valores para cada tipo de ação (Equação 3.4), deve-se calcular a quantidade que cada um será gerado para a formação do ritmo do jogo, então usa-se a Equação 3.5, onde v será 1 caso o desempenho do usuário tenha melhorado e -1 caso contrário, S é uma constante para fazer a troca entre níveis de dificuldade mais suaves a fim de que sejam menos perceptíveis e o g , o valor calculado na Equação 3.4.

$$d_{atual} = d_{anterior} + v * S * g \quad (3.5)$$

Além do ritmo, deve ser gerado a geometria, também descrita na Figura 3.4. O primeiro elemento sempre será um vão, caso o jogador caia no vão, será colocado um inimigo com espinhos e, em última circunstância, será colocado um inimigo derrotável, gerando o mapa final para o nível, que pode ser algo próximo da Figura 3.5, caso o jogador tenha resultados ruins, ou mais próximo da Figura 3.6, caso contrário.

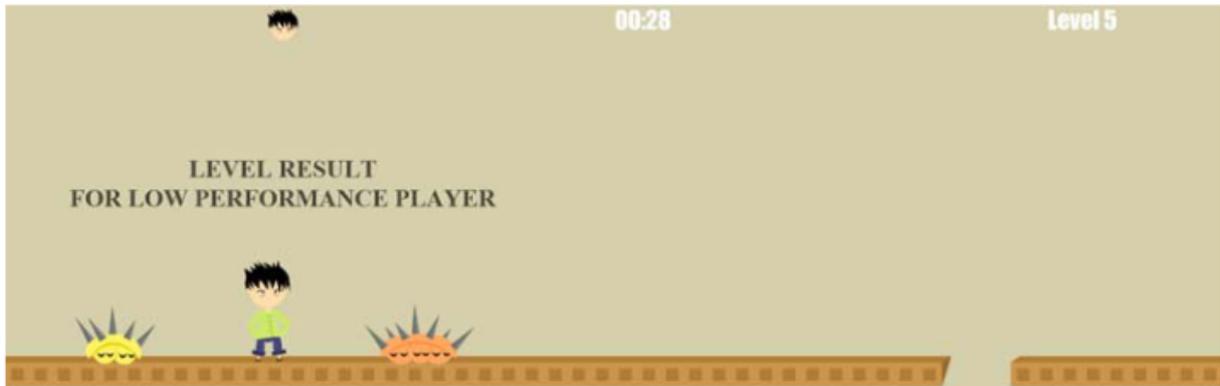


Figura 3.5: Captura de tela do jogo desenvolvido sendo jogado por um jogador de baixo desempenho [4]

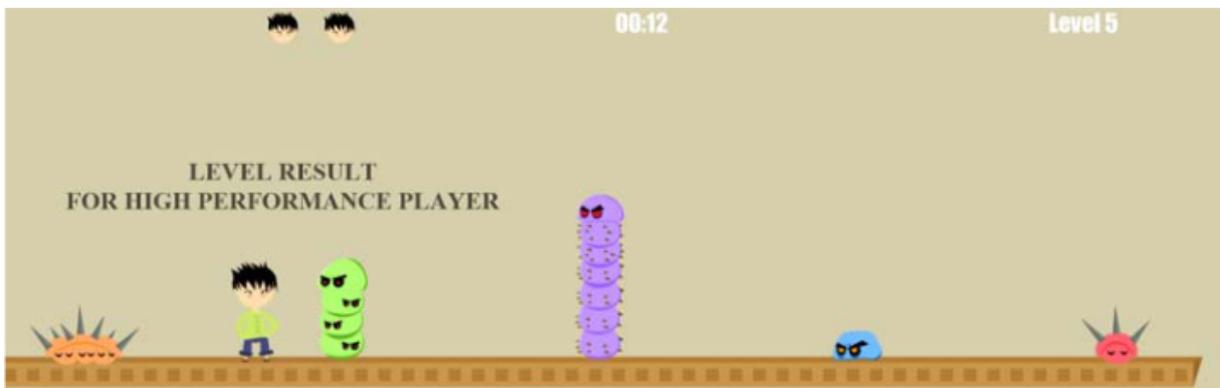


Figura 3.6: Captura de tela do jogo desenvolvido sendo jogado por um jogador de alto desempenho [4]

A população experimental foi formada por 25 pessoas. Antes de começarem o jogo foi perguntado a cada indivíduo se já jogaram Super Mario Bros antes (onde 88% respondeu que sim) e se já completaram Super Mario Bros (onde 36% respondeu sim). Tal pergunta foi útil para classificar melhor os participantes em nível de familiaridade com o gênero. Inicialmente, todos parâmetros foram definidos como 0.5 para o primeiro nível, a partir do segundo, o jogo foi adaptando ao jogador até o quinto e último nível. Durante a execução dos testes, os autores se depararam com algumas dificuldades, sendo elas, a conexão instável entre o biosensor e o computador e o desconforto causado pelo uso do biosensor. Para os participantes que tiveram qualquer tipo de problema e poderia interferir na correteza dos resultados da pesquisa foram excluídos.

Os resultados foram analisados de dois paradigmas, o primeiro analisa cada jogador sem considerar o histórico obtido nas duas perguntas iniciais e fazendo média aritmética

de todos. Já o segundo paradigma analisa os grupos baseados nas perguntas iniciais separados. Observando o gráfico na Figura 3.7, que representa a média dos valores de todos participantes, podemos observar que a curva do ADD híbrido (combinando atenção e desempenho, destacado em verde) e a curva da dificuldade (em roxo) se aproxima conforme o jogo vai se adaptando ao jogador. Porém, a curva do desempenho (em vermelho) e a curva do desempenho se juntam no final. Pode ser que apenas não houveram níveis suficientes para que a dificuldade acompanhe o ADD Híbrido, porém, como os autores afirmam, pode indicar que o algoritmo desenvolvido tende a se aproximar do desempenho do jogador.

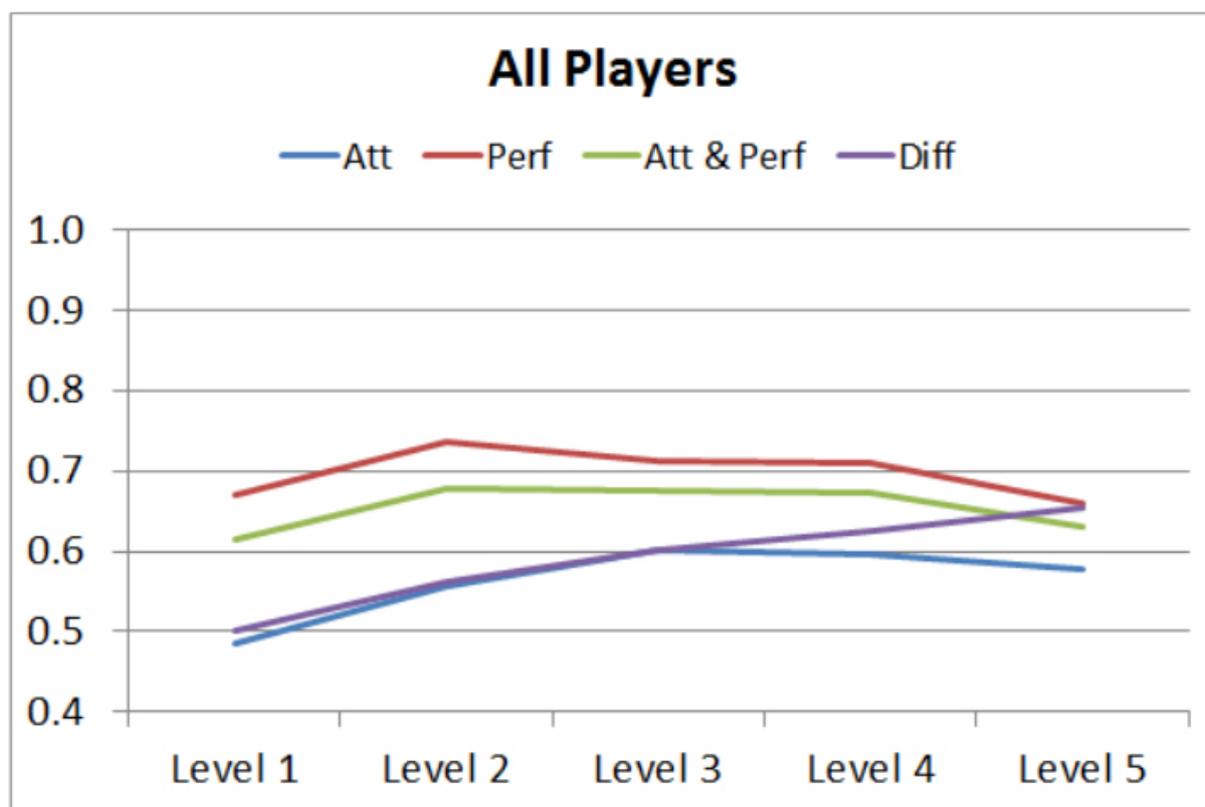


Figura 3.7: Médias de valores do nível de atenção (azul), desempenho (vermelho), o valor global (g) (verde) e o dificuldade (roxo) [4]

Para a segunda análise, foram gerados os gráficos expostos na Figura 3.8. A primeira pergunta inicial gerou a separação para a primeira linha, enquanto a segunda pergunta inicial, a segunda linha. Apesar do fato de que o grupo de pessoas que nunca jogaram Super Mario Bros ser pequeno (3 pessoas), é notável que as curvas do ADD Híbrido e nível de dificuldade tendem a se aproximar sempre, como por exemplo no nível 3 para as pessoas

que nunca jogaram *Super Mario Bros* no qual a curva de dificuldade ultrapassa a curva do ADD Híbrido, então o algoritmo reage diminuindo a dificuldade no nível seguinte.

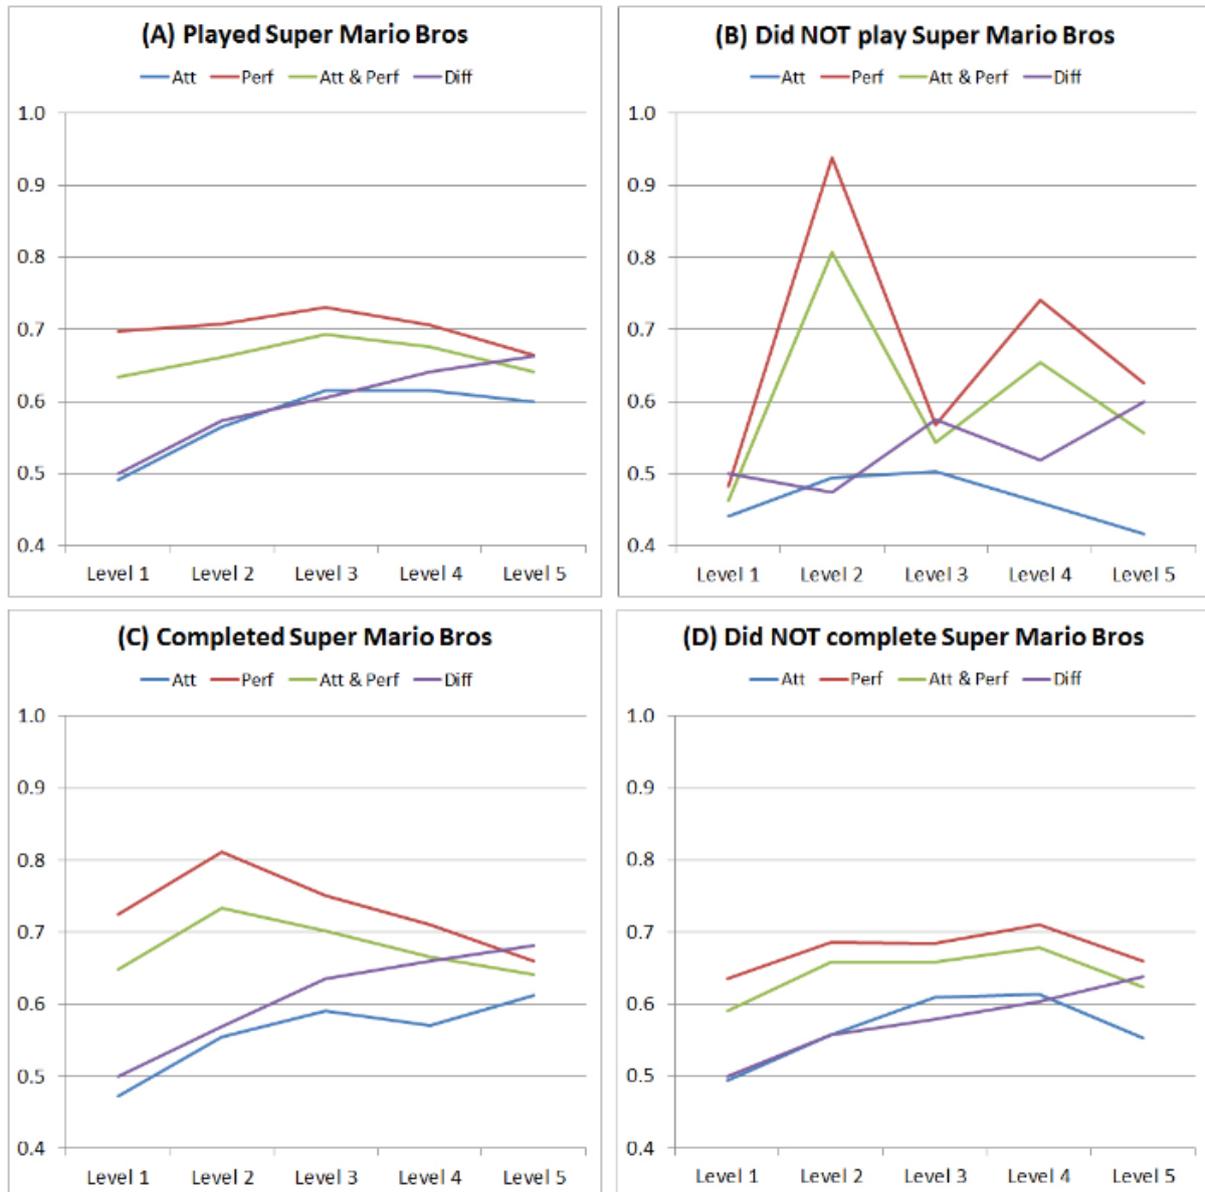


Figura 3.8: Médias de valores do nível de atenção (azul), desempenho (vermelho), o valor global (g) (verde) e o dificuldade (roxo) separando em grupos [4]

Portanto, é possível constatar com o conteúdo que mesmo com as dificuldades encontradas tanto no uso quanto a obtenção acerca do biosensor, é viável a implementação de algoritmos de ADD Híbrido utilizando o EEG para a aquisição de dados biológicos do jogador. Porém, ainda parece algo distante do ponto de vista comercial, devido aos mesmos problemas. Entretanto, os autores apontam que a técnica descrita pode ser

utilizada, ainda comercialmente, para a criação de mapas melhores de jogos aplicando iterativamente para melhorar o design até chegar num estado tido como o com melhores parâmetros gerando níveis de dificuldade estáticos melhores adaptados para pessoas de baixo e alto nível de habilidade.

Os autores almejam prosseguir progredindo com a pesquisa implementando com diferentes sensores, executando novos experimentos, testando com novos jogadores, melhorando o método desenvolvido e alterando valores iniciais para comparação e constatação de quais são os melhores para uma aproximação inicial, além de adicionar novos elementos para melhor adaptar a dificuldade aos jogadores.

3.4 Detecção de *Flow* utilizando Expressões Faciais

Apesar do título do trabalho citar apenas a detecção do *Flow* do jogador utilizando suas expressões faciais, Burns e Tulip [5] produziram uma pesquisa entorno do uso desses dados para o ajuste dinâmico da dificuldade associados a dados de desempenho (i.e. ADD Híbrido) em jogos.

Os autores apontam inicialmente que o engajamento é uma peça fundamental para dizer se determinado jogo fará sucesso ou não. Para tal, relembram que o *Flow* está intrinsecamente conectado ao engajamento do jogador, ou seja, para um bom engajamento dos jogadores, é necessário um bom balanceamento entre dificuldade e habilidade do jogador. Os autores também criticam o fato de que a maioria dos sistemas de ADD existentes utilizam métricas que ignoram o histórico do jogador equiparando novatos. Nisso correm o risco de exigir bastante dos novatos ou "pegarem leve" com veteranos.

Para corroborar a ideia de que se deve utilizar expressões faciais como meio de aquisição de dados afetivos para o que chamam de ECDDA (Emotion Controlled - Dynamic Difficulty Adjustment, ou Ajuste Dinâmico de Dificuldade Controlado pela Emoção), os autores apontam que os métodos mais utilizados (e.g. EEG e ECG) acabam por se tornar bastante intrusivos. Foi utilizado para o monitoramento das expressões faciais um SDK chamado *Affective Affdex SDK*, que é capaz de detectar 7 emoções e 15 expressões faciais (no momento do experimento, entretanto, em pesquisas atuais, esse número já subiu para 20 [31]) com bastante precisão, portanto através desse *software* é possível obter tanto os valores para valência quanto para excitação acerca do jogador. Os próprios desenvolvedores afirmam um grau de 80% de exatidão na detecção de emoções como diversão, nojo e surpresa, porém o grau cai em emoções como raiva, tristeza e medo.

Os autores desenvolveram um jogo, que pode ser visto na Figura 3.9, inspirando em outro chamado *Star-Surf* utilizando o *Unity Engine* por julgarem que a integração com a biblioteca de detecção de emoções seria facilitada, visto que existe um *plugin* da mesma

para o *Unity*. A integração é feita adicionando um detector dessa biblioteca a uma cena do *Unity* e um método de *callback* que recebe quadros proveniente da *webcam* conectada ao computador e, posteriormente, são analisados e calculados os valores de valência e excitação referentes ao jogador a cada quadro. Esses valores serão utilizados para que ocorra o ajuste da dificuldade e também são lançados em um arquivo no fim do jogo para posteriores comparações. Além desse módulo de detecção de expressões faciais, os autores implementaram um ADD por desempenho no qual três eventos são observados: caso o jogador colida com o obstáculo, a dificuldade é reajustada em 3% para menos; caso o jogador perca um objetivo, a dificuldade é reajustada em 1% para menos; caso o jogador capture um objetivo, a dificuldade é reajustada em 1% para mais.

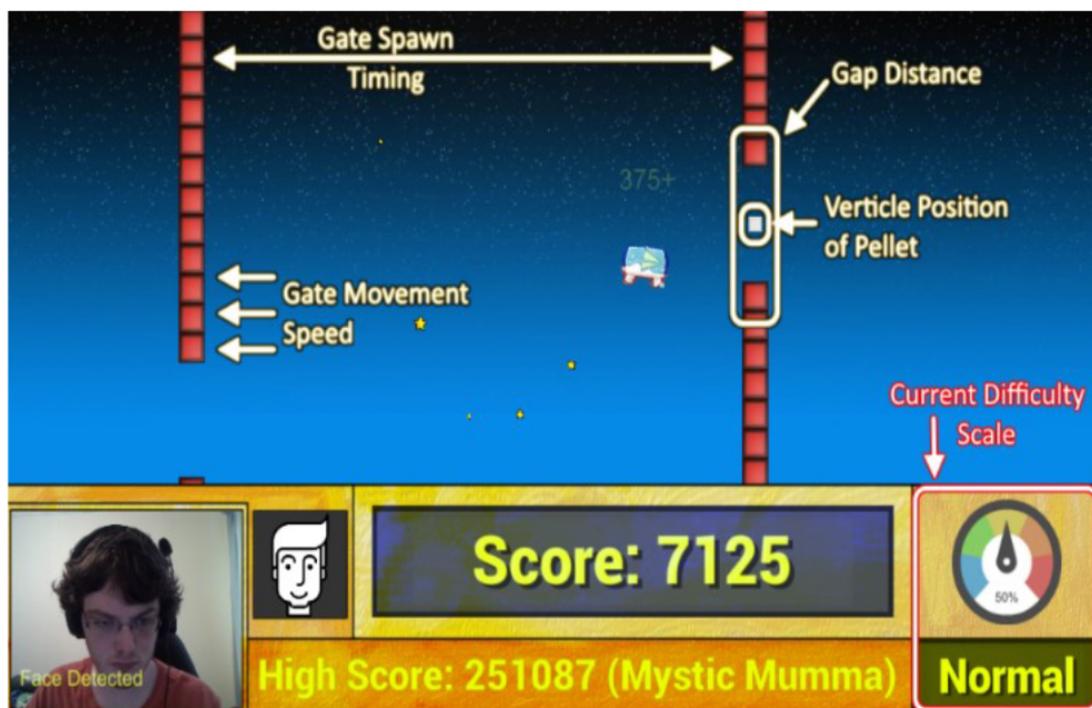


Figura 3.9: Captura de tela do jogo em execução mostrando o *feedback* da câmera e do nível de dificuldade [5]

O ajuste de dificuldade foi feito flutuando o valor de três variáveis, sendo elas a largura do vão entre os obstáculos, a distância entre os obstáculos e a velocidade. Com exceção da velocidade, todos parâmetros vão decrementando conforme a dificuldade aumenta. O algoritmo incrementa a dificuldade quando é detectado que jogador está entediado (excitação baixa e valência neutra) e decrementa quando é detectado frustração (excitação alta e valência baixa).

Os experimentos foram separados em duas partes para que seja possível melhores comparações. Na primeira forma, os participantes foram apresentados a uma versão

adaptativa do jogo normal como citado anteriormente. Já a segunda forma, expôs aos participantes os extremos, ou seja, os participantes jogaram ou uma versão na maior dificuldade, ou na menor. Em todos os três cenários, os dados sobre as expressões faciais foram acumulados e guardados além dos dados sobre como a dificuldade variou durante a execução. A cada rodada do jogo era perguntado aos participantes se eles se sentiam desafiados, se sentiam no controle do jogo, se distraíram ou perderam a noção do tempo em escalas de -1 a 1. Como podemos observar na Figura 3.10, é bem fácil notar como os jogos trabalhando nos extremos mostram bem a atenção caindo quando o jogo é tedioso, ou o aumento de excitação e atenção quando frustrante. Já no modo dinâmico, a análise é mais complexa, mas é possível notar a dificuldade sempre sendo alterada a fim de compensar os picos na média de excitação e valência.

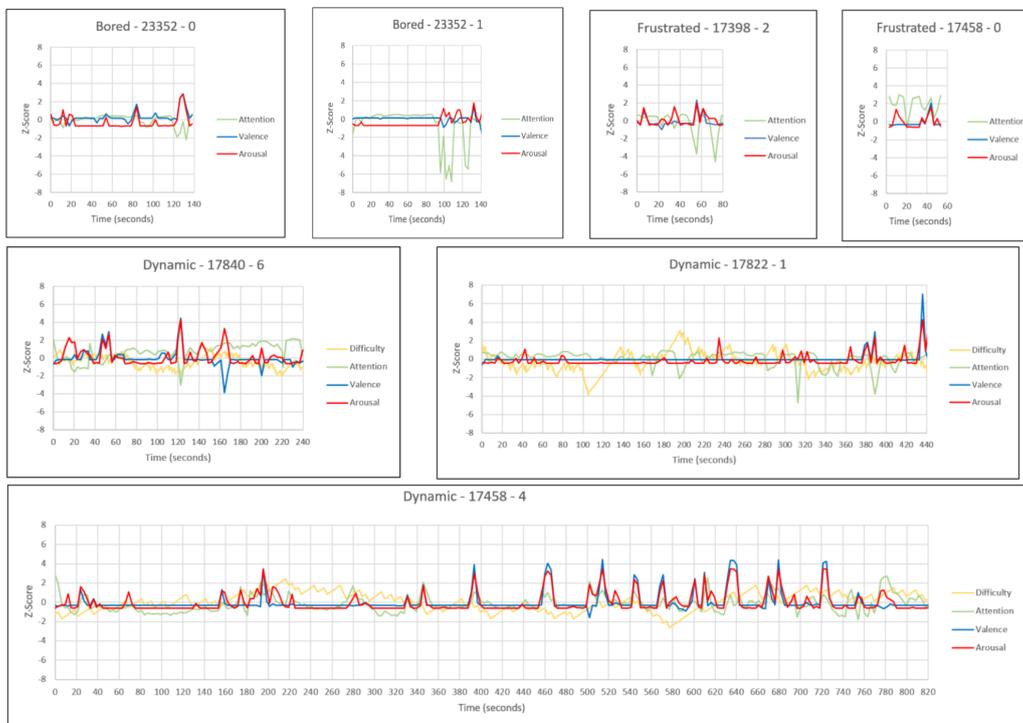


Figura 3.10: Gráficos mostrando os resultados dos experimentos [5]

As perguntas feitas a cada rodada foram reunidas e formado o gráfico da Figura 3.11, no qual é possível notar que os participantes tendem a se sentir no *Flow* quando o desafio é proporcional ao quanto a pessoa se sente no controle, reforçando a definição de Csikzentmihalyi de *Flow*.

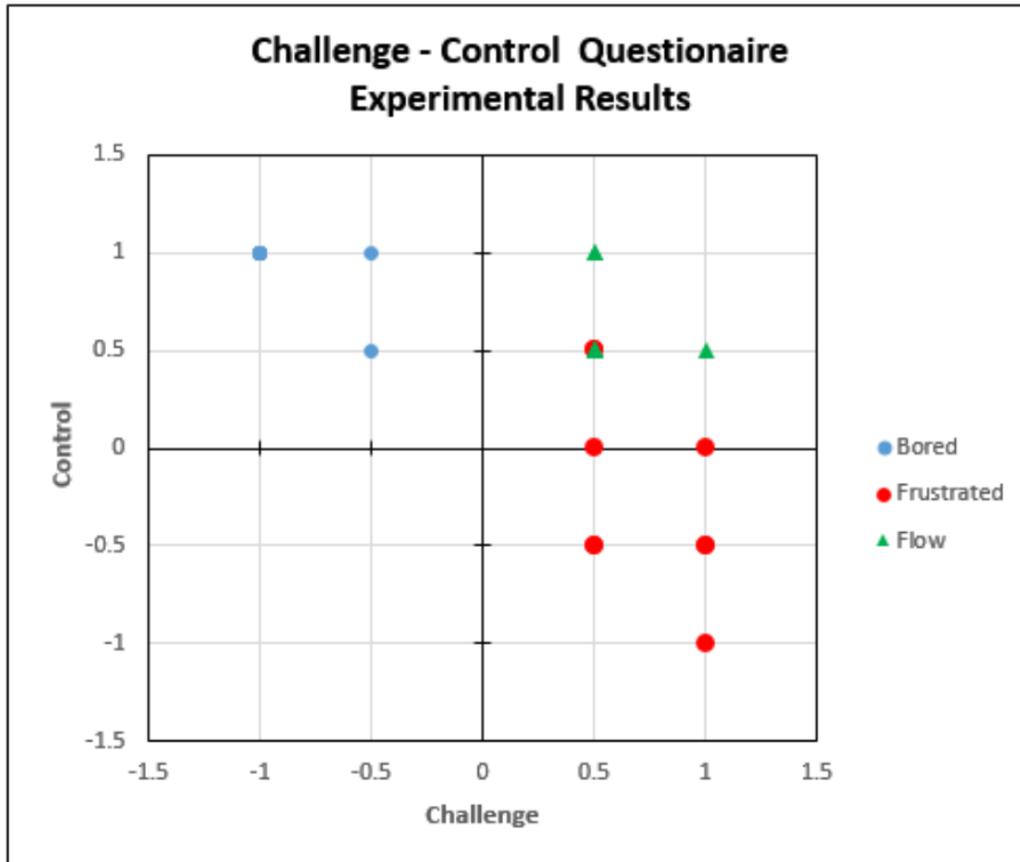


Figura 3.11: Gráficos mostrando os resultados das perguntas feitas a cada rodada [5]

Concluindo, os autores confirmam que o conjunto de ferramentas da *Affective* pode ser muito facilmente integrado com jogos feitos no *Unity* e pode ser usado para obter métricas sobre o estado emocional do jogador em tempo real de forma ágil e satisfatória raramente perdendo o rosto do jogador. Contudo, reconhecem que a forma com a qual o experimento foi conduzido foi ingênua, necessitando de estudos e abordagens mais robustas em cima dessa técnica. Esse fato pode ser bastante notado na segunda bateria de experimentos, na qual jogadores expostos ao sistema adaptativo tiveram resultados baseados em vários aspectos que não apenas a experiência dentro daquele jogo. Os autores também citam que jogos frustrantes devem ser mais longos, pois, caso sejam curtos, tal sentimento não será passado ao jogador, que sentirá apenas uma surpresa com o grau de dificuldade e, provavelmente, será incapaz de sentir que o sucesso naquele jogo é possível. Com base nos resultados dos experimentos, também é citado que os dados acerca do *Flow* experienciado pelo jogador não é algo consistente, visto que foi bastante normal longos períodos onde nenhum afeto foi detectado. Logo, a relação entre os dados obtidos através das expressões faciais e os algoritmos de ADD parecem bem mais complexa que se imaginava, visto que existem jogadores que querem ser desafiados, corroborando o disposto na Figura 2.3, que

mostra que diferentes pessoas podem ter diferentes canais de *flow*. Sem contar que as emoções podem ser rápidas sem fornecer tempo necessário para que o algoritmo detecte e descubra que decisão tomar.

3.5 ADD afetivo na terapia de Acrofobia

Balan et al. [37] sugerem uma pesquisa buscando averiguar a eficácia do uso de ADD para a melhoria da terapia de acrofobia, que trata-se do medo irracional de lugares altos. Para isso, os autores desenvolveram um jogo em realidade virtual utilizando o *HTC Vive* em conjunto a aquisição de dados através do eletroencefalograma, da atividade eletrodermal e da frequência cardíaca.

O jogo consistia em dois níveis, sendo o primeiro no chão, onde o jogador deveria coletar três tipos diferentes de moedas (bronze, prata e ouro). Após isso, o jogador deveria responder a duas perguntas para que o nível de medo do mesmo fosse, inicialmente, estimado. Essas perguntas eram se o participante se encontrava relaxado ou com medo em uma escala de 2 níveis (0 - relaxado, 1 - medo), e, novamente, a mesma pergunta, porém em uma escala de 4 níveis agora (0 - relaxado, 1 - medo baixo, 2 - medo moderado, 3 - medo alto). A partir desse ponto, o jogador deve passar por um portal que o leva para outra área, que se passava terraço de um prédio, onde o jogador deveria coletar novamente as três moedas de bronze, prata e ouro novamente, que agora estavam dispostas a 4 metros, 2 metros e 0 metros, respectivamente, do corrimão da sacada. Novamente são feitas as mesmas perguntas a fim de fazer uma nova estimativa do nível de medo do jogador e o jogador passa pelo portal. Então o usuário passa a ser exposto as alturas do térreo, do primeiro andar, do quarto andar, do sexto andar e do oitavo andar, que trata-se da cobertura do prédio desenvolvido no jogo, cuja ordem é escolhida por um algoritmo de ADD.

Para os experimentos, quatro pessoas que sofrem de acrofobia participaram preenchendo um formulário de consentimento e preenchendo um questionário para estabelecer o nível de acrofobia de cada indivíduo. Primeiramente, os autores colocaram os participantes em diferentes alturas, tanto no jogo quanto fora do jogo, enquanto dados eram coletados através dos já citados três sensores para que duas redes neurais profundas (i.e. redes neurais com mais de uma camada oculta) fossem treinadas. A primeira rede neural é treinada para estimar o nível de medo com base nos dados biológicos adquiridos, enquanto a segunda rede neural é treinada para prever qual deve ser o próximo nível de dificuldade que o participante deve experimentar. Então cada participante jogou o jogo duas vezes novamente, sendo que, na primeira, a pergunta com 2 escalas foi feita e, na segunda, com 4 escalas, para que posteriormente fossem utilizadas para comparação com

os dados obtidos pela rede neural. Com isso, os dados biológicos são adquiridos pela rede neural que estima o nível de medo para que esta passe os seus resultados para a rede neural que prevê qual deve ser o próximo nível de dificuldade.

Como resultado, os autores obtiveram que a primeira rede neural teve uma precisão de 87,5% quando comparadas as perguntas com 2 escalas, enquanto 70%, quanto as perguntas com 4 escalas, mostrando que a precisão da mesma foi relativamente alta. Já observando os resultados, é possível montar a Tabela 3.3, que aponta qual foi o parâmetro mais correlacionado com as respostas apresentadas pelos participantes.

Usuário	2 escalas	4 escalas
U1	EDA	FaD(EEG)
U2	EDA e HR	HR
U3	EDA	HR
U4	HR	HR

Tabela 3.3: Tabela montada a partir dos resultados apresentados por Balan et al. acerca dos parâmetros que mais se aproximam do que cada participante afirmou nas perguntas

Os autores encerram o trabalho afirmando que, com base nos resultados experimentais obtidos, ajustar os níveis dinamicamente com base em dados fisiológicos oferece uma boa melhoria para que níveis de medo sejam estimados, sendo o jogo desenvolvido uma solução ótima para a terapia para acrofobia. Além disso, os autores afirmam que irão continuar melhorando as redes neurais empregadas e realizar experimentos com uma população maior.

3.6 ADD baseado na Resposta Galvânica da Pele

Bandeira et al. [6] desenvolveram um estudo que visava comparar dois algoritmos de ADD, sendo eles, o *Data Subset Analysis* (DSA) e o *Real-Time Arousal Set* (RTA), utilizando o EDA como fonte dos dados bioafetivos.

Inicialmente é apontado a diferença acerca do funcionamento dos dois algoritmos. O DSA é um algoritmo simples, que calcula a diferença entre as duas últimas medidas e o resultado é agregado a dificuldade do jogo. Já o RTA utiliza os dois extremos, máximo e mínimo dos valores possíveis de EDA do jogador, para calcular as componentes tônicas (mudanças lentas) e fásicas (mudanças abruptas) permitindo uma parametrização para posteriores comparações.

O jogo *Asteroids: in the 2nd and 1/2th Dimension*, que pode ser visto na Figura 3.12, foi utilizado pelos autores para desenvolverem a implementação de ambos algoritmos. O

jogo utilizado é de código aberto para uso não comercial. Portanto, os autores se responsabilizaram pela adaptação e implementação de ambos algoritmos de ADD. Enquanto isso, para a aquisição dos dados foi utilizada a pulseira *Empatica E4*, que é capaz de medir a atividade eletrodermal da pele e comunica-se com o computador que roda o jogo através da conexão Bluetooth.

O jogo utilizado consiste em passar pelos níveis atravessando um campo de asteróides desviando ou atinjindo-os com projéteis. A dificuldade do jogo é modificada através da velocidade de aproximação, sendo essa a variável ajustada pelos algoritmos de ADD.

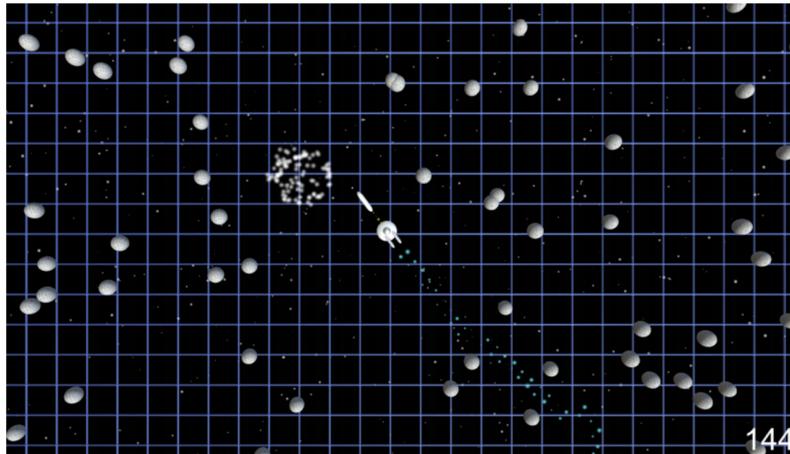


Figura 3.12: Cena do jogo *Asteroids: in the 2nd and 1/2th Dimension* [6]



Figura 3.13: Pulseira *Empatica E4* [6]

Para a aplicação dos testes experimentais, uma amostra de 60 pessoas foi selecionada e dividida, igualmente e de forma aleatória, em três grupos com a finalidade de não haver viés. O primeiro grupo foi utilizado como grupo controle jogando o jogo sem qualquer tipo de adaptação. No segundo e terceiro grupo foram utilizados, respectivamente, os

algoritmos RTA e DSA. Inicialmente, cada participante recebeu um questionário para ter uma base do nível de experiência da pessoa com jogos. Após isso, foram expostos a 6 níveis do jogo, cada qual com a sua versão, e, ao fim de cada nível, era perguntado ao participante sobre a sua percepção de dificuldade, aborrecimento, frustração e diversão no jogo. Então era aplicado um novo questionário ao fim do experimento solicitando que o participante desse notas para: seu desempenho; para quão desafiante era o jogo; o quanto ele conseguiu lidar com os desafios do jogo; o quão apropriada era a dificuldade do jogo; o quão boa foi a experiência; quanto da atenção do participante estava focada no jogo; o quanto o participante pode fazer coisas automaticamente dentro do jogo sem muito pensar; e o quão perdido ficou durante o jogo.

Com os resultados obtidos foram confeccionados gráficos relacionando o grupo e a média de mortes em cada fase que podem ser visualizados na Figura 3.14 e que relacionam o grupo com a duração média de cada nível, na Figura 3.15. Além desses, também confeccionaram gráficos relacionando a quantidade média de vezes que o algoritmo fez o reajuste por nível que pode ser visto na Figura 3.16.

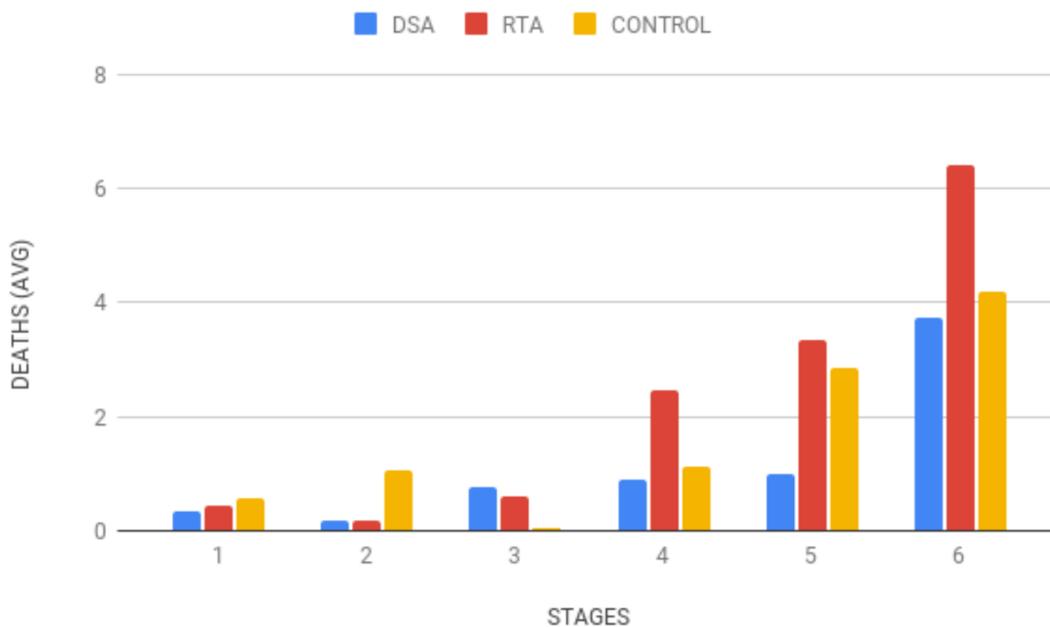


Figura 3.14: Média de mortes por nível [6]

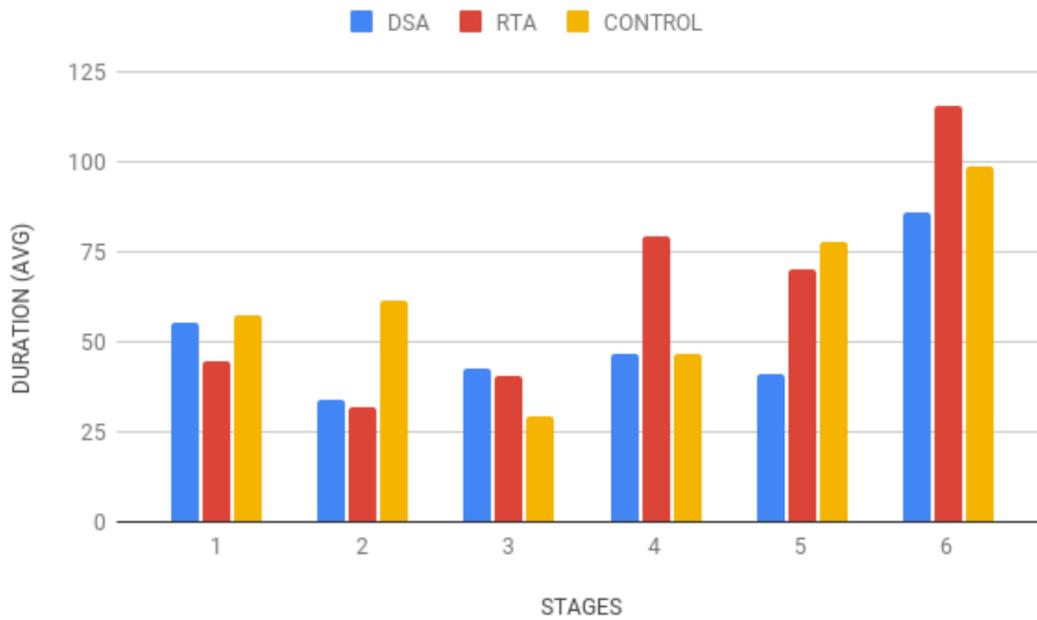


Figura 3.15: Média de duração por nível [6]

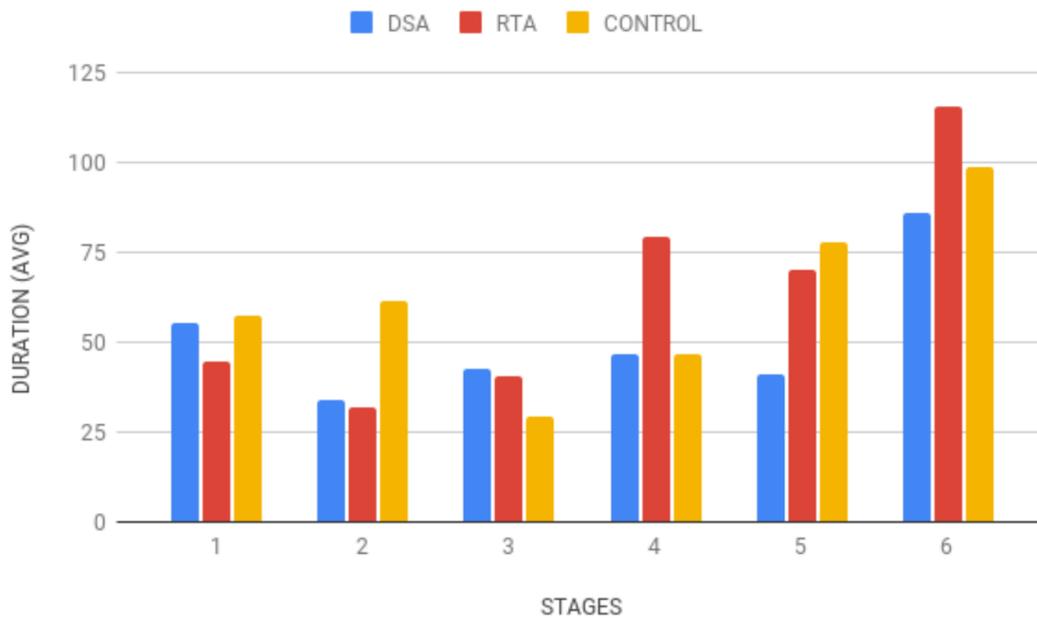


Figura 3.16: Média de ajustes feitos por nível [6]

Com base nos resultados, os autores concluem comparando ambos algoritmos. Nessa comparação, o DSA se mostrou mais satisfatório, visto que ele tende a ser mais responsivo e fornecer melhor ajuste ao usuário. Tal resultado é atribuído ao fato de que o DSA é melhor para detectar o nível de excitação do jogador, enquanto o RTA tende a mostrar mais inconsistências.

3.7 ADD em Exergames para Reabilitação

Pezzera e Borghese [9] iniciam seu estudo apontando que os esforços e custos necessários para cuidar da reabilitação de pacientes que sofrem de esclerose múltipla, derrame, doenças traumáticas ao cérebro, entre outras, tem crescido conforme a expectativa de vida cresce. Para contornar esse problema, apontam que plataformas de reabilitação em casa estão sendo desenvolvidas de forma cada vez mais barata e com dispositivos de monitoramento mais confiáveis permitindo a gravação dos dados do paciente e monitorando seu desenvolvimento no processo de reabilitação. Completando essa alternativa, indicam como principal ferramenta o que eles chamam de *exergames*, que são jogos que guiam exercícios físicos utilizando dispositivos de monitoramento como a Nintendo Wii Balance Board, que pode ser visualizada na Figura 3.17, e câmeras RGB-D como a *Microsoft Kinect*, disponível na Figura 3.18, além de um autorrelatório baseado em diálogos.



Figura 3.17: *Nintendo Wii Balance Board* [7]



Figura 3.18: *Microsoft Kinect* [8]

Entretanto, não basta utilizar os *exergames* para a reabilitação. Os *exergames* devem ser adaptados para cada usuário para maximizar sua efetividade. Isso iria requerer que o terapeuta configurasse todos os parâmetros em cada jogo para cada paciente, a fim de moldar a experiência para o quadro no qual o paciente se encontra. E então que sugerem o uso do ADD para suprir essa necessidade de um terapeuta tão ligado a aplicação desse método de reabilitação. Porém, vale ressaltar que ainda é necessário a presença de um terapeuta que, remotamente, irá verificar o progresso do paciente ao mesmo tempo que agenda os exercícios. Para isso foi implementado o sistema de acordo com a Figura 3.19 que foi retirada do trabalho e representa as quatro principais unidades, sendo elas:

- **Banco de dados do servidor**(*Server's database*) que contém os dados os exercícios que podem ser executados e seus respectivos modelos de parâmetros e informações sobre o paciente, bem como exercícios já executados e futuros agendamentos de exercícios para ele.
- **Servidor**(*Server*) que contém os módulos de gerenciamento do paciente, o agendador de exercícios e o analisador dos resultados.
- **Hospital** é a unidade pela qual o terapeuta acessa o sistema podendo verificar o progresso do paciente, agendar novos exercícios e alterar cadastros dos pacientes.
- **Casa do paciente**(*Patient's home*) é a unidade pela qual o paciente acessa o sistema e é onde serão baixados os exercícios designados para o mesmo e irá enviar as informações da execução do exercício para o servidor.

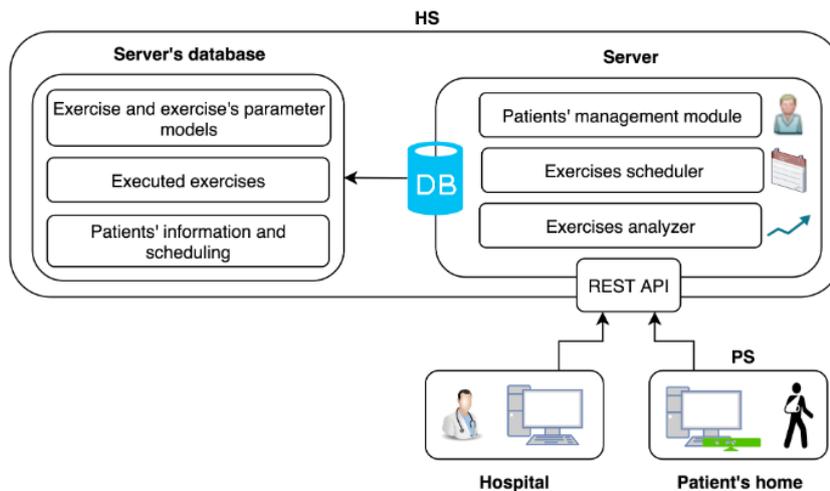


Figura 3.19: Arquitetura utilizada no experimento [9]

Na casa do paciente, terá um computador que poderá instruir o paciente em até 8 jogos diferentes com 9 exercícios de reabilitação indicando o que deve ser feito. Caso o paciente execute movimentos perigosos para o seu quadro ou apenas errados, ele será avisado para que a segurança do paciente não seja comprometida por não ter o acompanhamento de um profissional. Após a finalização do exercício, esse computador irá enviar para o servidor os dados acerca da execução pelo paciente. Esse sistema instalado em um computador na casa do paciente conta com a aplicação do ADD em três módulos:

- **Adaptador *offline*** utilizando informações de exercícios anteriores, o sistema define o ponto de partida para o exercício atual do paciente.
- **Adaptador emocional** com base em uma conversa entre o paciente e um terapeuta empático virtual é determinado o estado emocional do paciente, que, posteriormente, é utilizado para que a dificuldade seja definida em torno dessa informação.
- **Adaptador *online*** com base na pontuação e corretude dos movimentos realizados pelo paciente, a dificuldade é adaptada em tempo real.

Ou seja, temos um ADD misto, que inclui tanto dados relacionados com a performance do jogador/paciente quanto seu humor, visto que toda adaptação é feita levando em consideração o estado físico e psicológico.

Para a definição de cada exercício a ser executado, os autores do estudo desenvolveram duas definições sendo a do *exer-game* em si e a dos parâmetros relacionados com o jogo e o ADD implementado nessa sessão. O *exer-game* a ser executado é definido através de: qual dos 8 jogos disponíveis será executado, qual exercício dentro do jogo será executado, quais serão os parâmetros do *exer-game*, quais dispositivos serão necessários para essa execução

e um conjunto de informações sobre o perfil do paciente. Já os parâmetros do *exergame* são definidos através de: dispositivos necessários para a execução, valores mínimos e máximos para cada parâmetro dentro do jogo relacionado ao ADD e o valor atual de cada parâmetro. A dificuldade pode ser calculada, então, como a média ponderada dos parâmetros utilizados, onde o peso é dado através da relação entre o paciente e o parâmetro em questão. Entretanto, como o foco é o desenvolvimento do paciente, essa dificuldade não é tão relevante para a pesquisa, mas o quanto e como ela varia.

Para cada execução, era estipulado um valor α variando de 0 a 1, que diz quão voltado para o desempenho do paciente (quando se aproximava mais do valor 1) ou para os dados dos sensores (caso contrário).

Para a aplicação dos testes, os autores visavam aplicar, de forma preliminar, em um centro de reabilitação real. Porém, devido à pandemia, foi necessário aplicar para um grupo bem reduzido de indivíduos saudáveis para verificar o funcionamento do sistema e obter uma validação preliminar. Nesses testes, foram utilizados os valores 0, 0.25, 0.5, 0.75 e 1 para o parâmetro α e foi notado que para valores mais baixos de α , ou seja, com mais foco no desempenho, o jogo se tornava mais difícil, mas o jogador prestava menos atenção em sua postura, o que poderia levar a um treinamento incorreto indo contra o fundamento do uso dos *exergames*. Já valores mais altos de α possibilitava ao jogador focar em manter a postura, o que era bom, entretanto, em excesso, poderia tornar o jogo fácil demais e chato.

Os autores concluem dizendo que o sistema proposto, bem como seus três módulos de ADD, teve êxito frente aos resultados dos testes preliminares, que, apesar de terem sido feitos em um ambiente não tão próximo do desejado, encoraja para novas pesquisas seguindo essa linha.

3.8 ADD baseado em Espectrografia Funcional de Infravermelho Próximo (fNIRS)

Afergan et al. [10] propõem demonstrar em seu trabalho que é possível utilizar o fNIRS como fonte de dados fisiológicos para a implementação de sistemas ADD e que essa forma de aquisição de dados possui vantagens específicas nessa aplicação. É destacado como uma das principais vantagens com relação a outros sensores o fato de que é resistente a movimentos, ou seja, movimentos realizados pelo jogador não produzem ruídos.

O trabalho é iniciado apontando as duas metas que os autores visavam. A primeira era mostrar que é possível construir uma interface cérebro computador que aloca dinamicamente as tarefas para o usuário de acordo com sua leitura. Já a segunda, sugerir estratégias adaptativas que ajudam a sanar problemas tradicionais utilizando sistemas

biocibernéticos ao mesmo tempo que adaptam, de forma viável, a utilização de sistemas ADD no mundo real. Para a primeira meta, eles apontam que foi aplicado a aquisição de dados utilizando a espectroscopia funcional de infravermelho para detectar sinais do córtex pré-frontal e correlacionar com a carga mental do usuário para ser utilizado como informação relacionando ao engajamento na tarefa sendo executada. Com isso, apontam que conseguiram diminuir o erro do jogador em 35%. Já para a segunda meta, foi implementado o sistema de ADD em um planejador de caminhos para veículos aéreos não tripulado, que é chamado de Veículo Aéreo Não-tripulado (*Unmanned Aerial Vehicle*) (UAV), de forma que o usuário não perceba, visto que isso poderia ser um desvio de atenção e influenciaria nas leituras do sensor. O jogo utilizado pode ser visto na Figura 3.20 e a meta dentro do jogo é guiar entre três e sete UAV até o destino, passando por alguns pontos de checagem, sem que colida com os obstáculos.

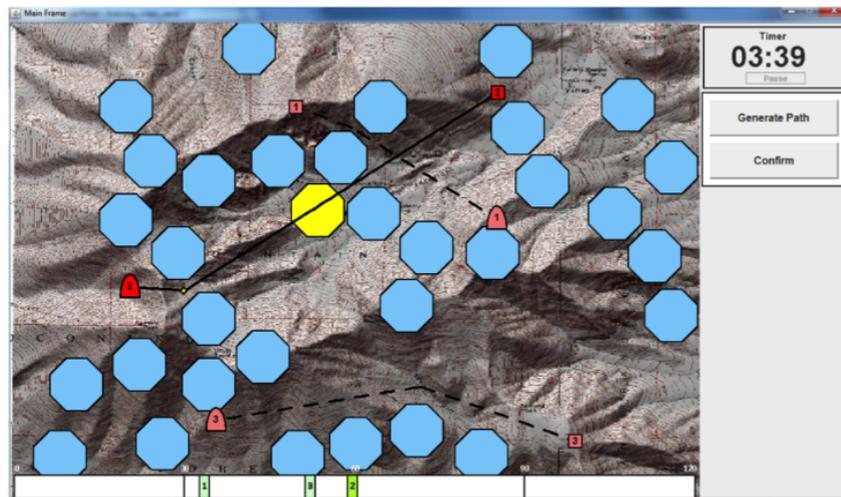


Figura 3.20: Planejador de Percurso de UAV [10]

Para a aquisição de dados, foi utilizado um dispositivo fNIRS da ISS Inc. que pode ser visualizado na Figura 3.21 no qual podemos ver cinco emissores de luz infravermelho e um detector, contudo só foram utilizados quatro emissores, como apontado pelos autores. Após os dados serem passados para o computador de forma crua, eles passavam pelo sistema descrito na Figura 3.22, o qual tratava no MATLAB as entradas buscando eliminar ruídos, passava os dados pela LibSVM, que é uma biblioteca com funções relacionadas a vetores para fazer regressões para que se chegue ao resultado de adicionar ou remover um UAV, normalmente quando a leitura chega em valores extremos tanto de alta quanto baixa carga, a fim de alterar a dificuldade do jogo em tempo real.

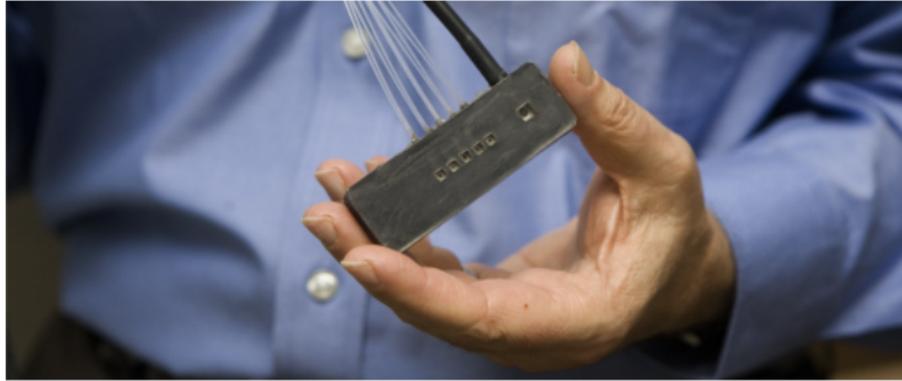


Figura 3.21: Sensor fNIRS utilizado [10]

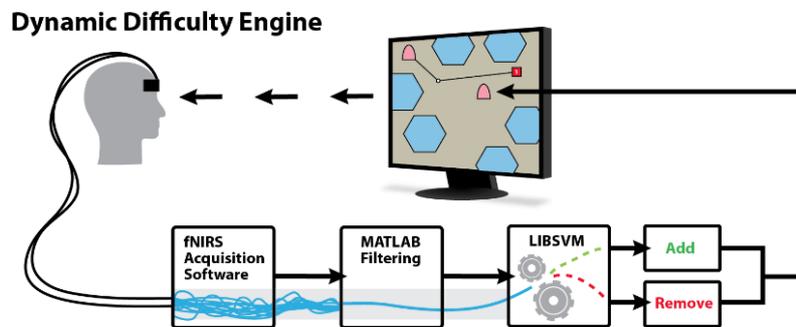


Figura 3.22: Arquitetura utilizada para a aquisição dos dados do sensor [10]

Para a aplicação, foram desenvolvidos dois cenários, sendo um adaptativo e o outro, não, e aplicados para vinte indivíduos com idades entre 18 e 26 anos com a proporção de 75% sendo do sexo feminino. No primeiro cenário, UAVs eram adicionados ou removidos de acordo com as leituras do sensor seguindo o sistema descrito na Figura 3.22. Entretanto, após uma adição ou remoção de UAV, havia um tempo de espera para evitar que houvesse rápidas flutuações. Já no segundo cenário, não havia o uso de sensor e UAVs eram criadas em um intervalo de tempo que varia de 20 a 40 segundos, sendo o tempo aleatório. Visando a menor interferência de fatores externos, ao escolher os participantes dos experimentos, foram escolhidos apenas pessoas destros, sem histórico de problema cerebral e com a visão normal (natural ou corrigida através de cirurgia).

Em todos os casos, tanto no sistema adaptativo quanto no não-adaptativo, os autores apontam que os participantes tiveram a mesma taxa de completude, sendo assim, não houve diferença nesse aspecto. Entretanto, quando se observa as falhas, o sistema adaptativo apresentou muito menos casos quando comparados com o não-adaptativo, tendo uma média de 3,25 com desvio padrão de 2,14, para o sistema adaptativo, contra uma média de 5 com desvio padrão de 1,95, para o sistema não-adaptativo. Portanto, a redução no

número de erros apresentados é notória, apesar de não ser tão consistente. Outro ponto destacado pelos autores foi o fato de que os participantes dentro do sistema adaptivo viajaram muito mais perto dos obstáculos, tendo uma média de 101,38 pixels de distância com desvio padrão de 91,43, comparando ao sistema não-adaptativo, com média de 206,39 com desvio padrão de 179,1. Com essa informação, foi-se inferido que os participantes prestaram mais atenção durante a execução num sistema adaptativo, visto que um dos fundamentos apoiados pelos autores era justamente manter o engajamento do jogador ao implementar o ADD.

Concluindo, os autores reforçam que com esse trabalho, o ADD se mostra uma ferramenta valiosa para manter as pessoas no estado ótimo para aprender e executar melhor além de tornar o processo de aprendizagem mais divertido. Além disso, lembram que os sensores seguem evoluindo e que, com o tempo, se tornarão mais fáceis de usar, mais acurados e mais comuns de serem vistos.

3.9 ADD Afetivo baseado em autorrelato

Frommel et al. [11] sugerem nesse trabalho um sistema adaptativo baseado em diálogos entre o jogador e um personagem não jogável dentro do jogo visando, através das respostas fornecidas pelo jogador, averiguar o estado emocional do jogador. Validar que diálogos tornam a experiência do jogador melhor que o uso de questionários também é uma meta do estudo.

Os autores iniciam apontando que uma boa motivação para o uso dessa forma de aquisição de dados é a ausência da necessidades de sensores. Entretanto, reconhecem que, apesar de colher as informações necessárias, esse método pode interromper o jogo. Contudo, apontam que essa integração feita da maneira correta, que seria mapeando objetos dentro do jogo para elementos do questionário feito ao jogador, pode mitigar os efeitos negativos dessas interrupções produzidos sobre a experiência do jogador.

Foi desenvolvido um jogo chamado *Space Jump* como objeto da pesquisa, que pode ser visto na Figura 3.23. Esse jogo se trata de um jogo de rolagem automática vertical, no qual o jogador controla um personagem com o objetivo de fazer com que ele pule entre plataformas sem cair e sem colidir com obstáculos até um determinado ponto. Ao cair ou passar de fase, o jogador é colocado em um diálogo com um personagem não-jogável, como pode ser visto na Figura 3.24, onde o jogador irá demonstrar seu nível de frustração ou tédio com o jogo durante a fase anterior para possíveis ajustes.

O jogo conta com três parâmetros para o ajuste da dificuldade, sendo eles: número de obstáculos por nível, movimento horizontal das plataformas e velocidade das plataformas, e, com base nesses três parâmetros, foram desenvolvidos 17 níveis de dificuldade. Cada

vez que se passa a etapa do diálogo, caso a frustração e o tédio não esteja baixos, a dificuldade será recalculada seguindo a Tabela 3.4. No caso de tédio e frustração altos, é apontado que nesse caso é difícil de se indicar qual será a atitude correta, portanto, é utilizado a análise de desempenho para agregar informações para a tomada de decisão.

Estado	Influência na dificuldade
Tédio Baixo e Frustração alta	Diminui
Tédio Alto e Frustração baixa	Aumenta
Tédio Alto e Frustração alta	Aumenta ou Diminui

Tabela 3.4: Efeito do estado emocional na dificuldade [11]

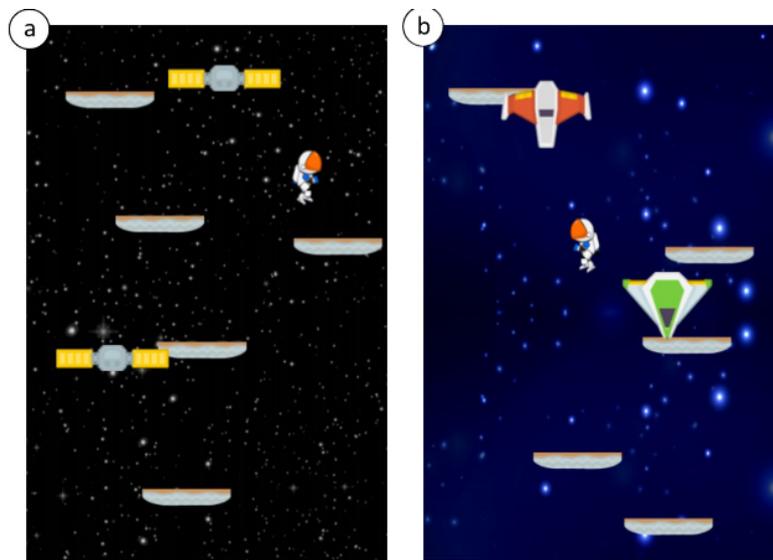


Figura 3.23: Jogo desenvolvido e utilizado nessa pesquisa [11]

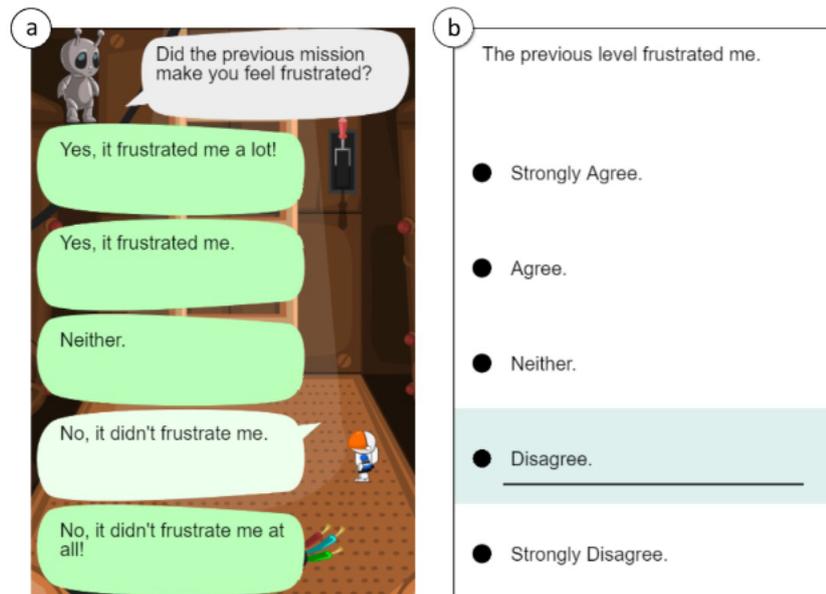


Figura 3.24: Duas variantes de diálogo desenvolvidas sendo a primeira um diálogo propriamente dito e a segunda, um questionário [11]

Antes do estudo ser aplicado a população de testes, foi necessário averiguar se os parâmetros para cada dificuldade foram distribuídos de forma que houvesse uma linearidade na progressão das dificuldades. Com essa finalidade, o jogo foi exposto a dez estudantes em todas suas dificuldades para que respondessem, em uma escala de 1 a 9, quão difícil acharam cada dificuldade. Então, a partir das respostas fornecidas por cada indivíduo nesse pré-estudo, foi montado o gráfico mostrado na Figura 3.25. Com isso, é perceptível que há uma linearidade nas dificuldades validando os parâmetros escolhidos para cada dificuldade.

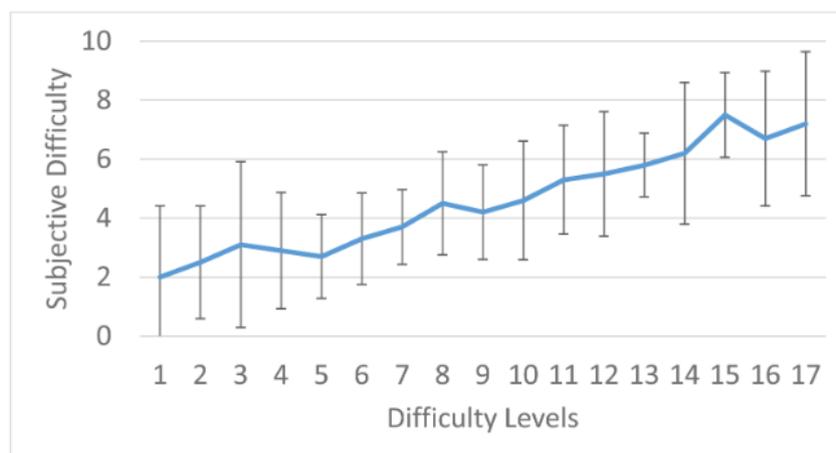


Figura 3.25: Média e desvio padrão das respostas da população do pré-estudo acerca da dificuldade em cada nível [11]

Com a validação da variação da dificuldade, o jogo foi exposto para 66 indivíduos com idades entre 19 e 55 anos com uma proporção de 72% de indivíduos do sexo masculino. Esse grupo foi aleatoriamente dividido em indivíduos que jogariam a variante usando diálogos e indivíduos que jogariam a variante usando questionário, ficando uma proporção de 35 indivíduos com a variante de questionários e 31, com a variante de diálogos. A execução dos experimentos foram separadas em três blocos, sendo:

1. Utilizando o sistema adaptativo em 5 níveis, porém sempre começando na dificuldade 8, que seria a média.
2. Utilizando o sistema de dificuldade incremental, que variava a dificuldade seguindo a sequência 2, 5, 8, 11, 14.
3. Utilizando o sistema de dificuldade constante, que fixava a dificuldade em 8.

A aplicação em três blocos visava comparar o uso do ADD com outros cenários para que o mesmo fosse validado. Portanto, com os resultados de média de quedas em cada nível para cada situação, foi montado o gráfico da Figura 3.26. Observando o gráfico gerado, notamos que conforme os níveis se passavam no sistema adaptativo, os jogadores iam falhando cada vez menos, o que mostra que o sistema estava realmente se adaptando ao jogador. Já no sistema de dificuldade incremental (ID) e constante (CD), podemos notar resultados bem intuitivos, nos quais a quantidade de falha é crescente no incremental e bem próximo de constante, no constante. Outro resultado obtido nessa pesquisa foi que a variante que utiliza diálogos se mostrou mais acurada que a que utiliza questionários.

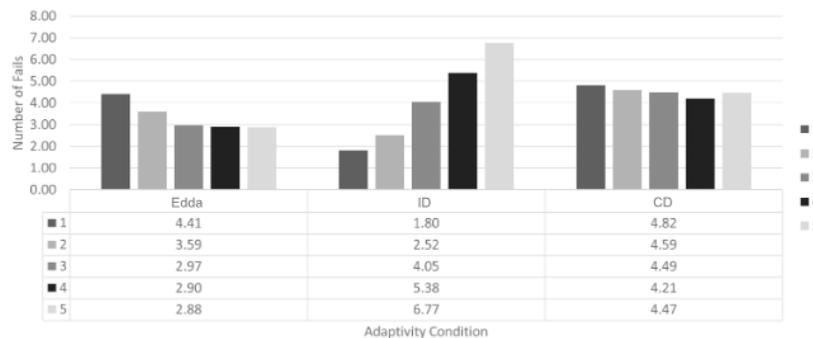


Figura 3.26: Resultados da pesquisa [11]

Com essa pesquisa, é concluído que o DBSR pode ser utilizado para a aquisição de dados, por ter conseguido reduzir o número de falhas ao longo dos níveis do jogo. Porém a pesquisa não foi capaz de verificar se esse método consegue prover uma experiência melhor que o uso de questionários tradicionais ao jogador, que era um dos objetivos da pesquisa, visto que os diálogos ainda representam uma interrupção no fluxo do jogo.

3.10 ADD baseado na Dilatação da Pupila

Strauch et al. [13] sugerem verificar, com essa pesquisa, a viabilidade do uso da dilatação da pupila como fonte de dados sobre o estado emocional do jogador para a implementação de ADD. Para embasar o uso desse método, estudos que trabalham quão sensível à excitação é a pupila são apontados.

Para essa pesquisa, o clássico jogo *Pong* foi adaptado de duas formas a fim de que se terem duas abordagens para o ajuste da dificuldade. Na primeira, a velocidade da bola era variada, enquanto na segunda, o tamanho da raquete. Para cada abordagem, foram geradas 4 dificuldades.

Como sensor, foi utilizado o dispositivo rastreador ocular SMI-RED 120, da *Sensorimotoric Instruments GmbH*, semelhante ao que pode ser visto na Figura 3.27. Como a pupila do jogador foi utilizada para a aquisição de dados, era importante que ela tivesse a menor interferência possível. Portanto, a luminosidade também foi fixada de forma a não interferir nos olhos do jogador.



Figura 3.27: SMI-RED [12]

Foi definido que cada jogador jogaria os 4 níveis de dificuldade em ordem aleatória, sendo coletado a dilatação da pupila a cada instante. Ao fim de cada nível também seria apresentado um questionário de autorrelato, que seria utilizado para correlacionar emoções entre si.

Após a modelagem dos cenários feita, o jogo foi exposto para 52 estudantes. A população exposta a primeira variação foi composta por 30 estudantes, sendo 16 indivíduos do sexo feminino, com idade média de 24,8 anos. Já a população exposta a segunda variação foi composta por 22 estudantes, sendo 18 indivíduos do sexo feminino, com idade média de 24,05 anos.

Após a execução de ambos experimentos foram montados os gráficos presentes na Figura 3.28, que apresenta, na linha superior, o resultado de cada indivíduo separadamente, e, na linha inferior, uma regressão linear que mais se aproxima do resultado obtido. Além desse, também foi montado o gráfico presente na Figura 3.29, que apresenta as correlações entre as emoções (diversão, prazer, prestando atenção, foco, esforço e tédio) a partir das respostas dos questionários.

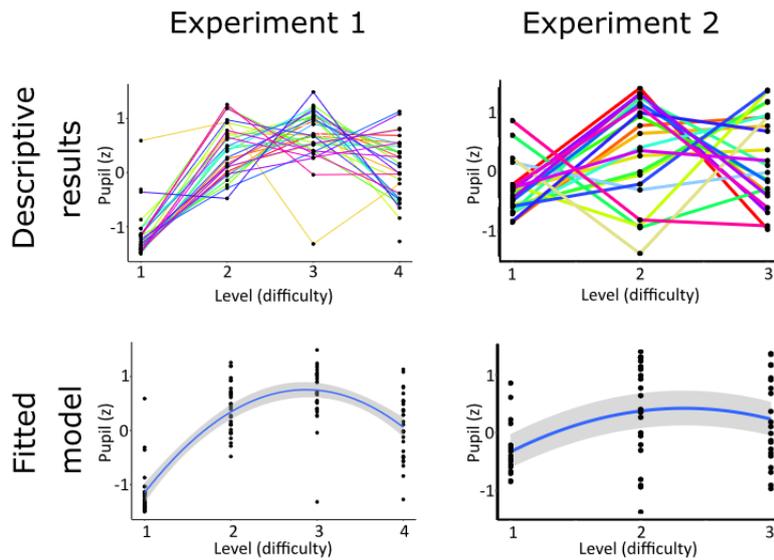


Figura 3.28: Diâmetro da pupila normalizado para cada experimento [13]

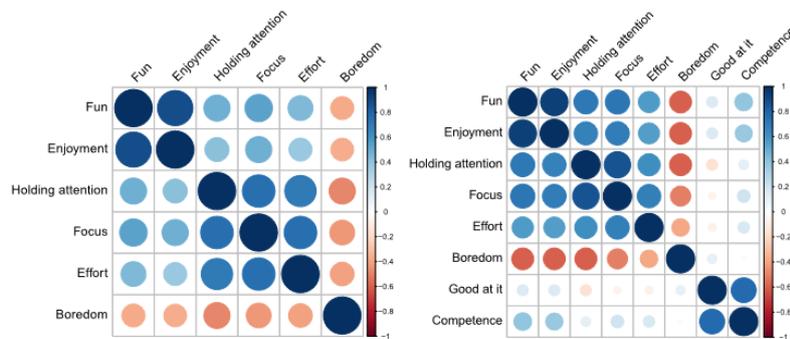


Figura 3.29: Correlação entre as emoções segundo as respostas do questionário. Quanto mais próximo do azul escuro, mais positivamente correlacionado, enquanto quanto mais próximo do vermelho escuro, mais negativamente correlacionado. [13]

Com esses gráficos, pode-se notar que para dificuldades medianas, o diâmetro da pupila se mostrou maior, enquanto nas dificuldades fáceis ou difíceis foram obtidos, em grande maioria, os menores diâmetros. Como a população amostral foi tida como mediana, esse fato é utilizado para fortalecer a hipótese de que o nível de atenção está atrelado a

dilatação da pupila, visto que as dificuldades medianas tendem a ser as mais próximas no nível de habilidade dos participantes.

Os autores concluem apontando que o padrão encontrado na dilatação da pupila reforça o potencial da pupilometria na implementação do ADD em jogos, confirmando a viabilidade do uso, apesar de não ter sido aplicada na prática com um sistema adaptativo.

3.11 Computação Afetiva para adaptação automática em jogos de Reabilitação

Aranha et al. [14] propõem em seu estudo analisar o uso de expressões faciais para a implementação de um *framework* de ADD. Esse estudo será focado em jogos para promover a reabilitação de pacientes dependentes de fisioterapia. Como a ideia é desenvolver um *framework*, o foco não será o jogo em si, mas todo o sistema por trás, que realiza a parte do ADD.

Nesse trabalho, é proposto e desenvolvido um *framework* seguindo a arquitetura descrita na Figura 3.30. A esse framework foi dado o nome de *EasyAfecta*, que vem de *Easy Affective Adaptation*, o que em uma tradução literal do inglês pode ser Adaptação Afetiva Fácil. Observando a figura, pode-se notar facilmente a existência de três módulos principais, que são o de reconhecimento de emoções, o controlador e adaptação (presente dentro do próprio jogo). Também é possível notar que existe a figura de três atores no processo, que são o paciente, o desenvolvedor e o fisioterapeuta.



Figura 3.30: Arquitetura do *framework* desenvolvido [14]

O módulo de reconhecimento de expressões é conectado a uma câmera e é responsável por colher imagens da face do paciente, a fim de determinar qual emoção o paciente está

sentindo naquele determinado momento. Nesse módulo, o desenvolvedor tem o papel de configurar a comunicação da aplicação responsável pelo reconhecimento, que foi utilizada a *Afectiva SDK* [31], enquanto o fisioterapeuta tem a função de monitorar quais emoções estão sendo produzidas no paciente.

O módulo controlador tem como função receber as informações acerca das emoções do paciente, provenientes do módulo de reconhecimento, através do banco de dados. Nesse módulo, o desenvolvedor tem como função apenas registrar os jogos, enquanto o fisioterapeuta, configurar como será feita a adaptação, criar os grupos de perfis de pacientes e classificar quais emoções são desejadas ou não, além de carregar imagens e músicas que serão utilizadas em casos específicos de pacientes.

O módulo de adaptação funciona dentro do jogo recebendo informações do módulo controlador através de um *Webservice*, que realiza a comunicação entre o módulo controlador e de adaptação, e faz ajustes no jogo adaptando a dificuldade. O papel do desenvolvedor nesse módulo é acoplar as adaptações aos jogos, enquanto o fisioterapeuta designa os jogos para cada grupo de perfis.

Observando a arquitetura apresentada na Figura 3.30, pode-se notar que o fluxo durante o jogo funciona na seguinte ordem:

1. O paciente interage com um jogo pré-selecionado para seu grupo de perfis por um fisioterapeuta que analisou previamente a situação do paciente.
2. Então o módulo de reconhecimento captura imagens do rosto do paciente durante o jogo para estimar o estado emocional do paciente.
3. Após o módulo de reconhecimento realizar sua estimativa, os dados sobre cada emoção é escrita em um banco de dados que funcionará como meio de comunicação com o próximo módulo.
4. O módulo controlador, que foi previamente configurado por um fisioterapeuta para classificar corretamente as emoções entre desejáveis e indesejáveis, irá consultar o banco de dados e decidir qual ação deve ser tomada em relação a dificuldade do jogo.
5. Por fim, o módulo de adaptação, que funciona dentro do jogo, irá consultar um *Webservice* que faz a interface com o módulo controlador. Essa consulta trará informações acerca das medidas a serem tomadas pelo jogo para adaptar-se ao paciente.

Visando validar o *framework* desenvolvido, o sistema foi disponibilizado para seis voluntários, todos fisioterapeutas com experiência na área de reabilitação e cinco deles com mais de cinco anos de experiência clínica. Após o uso do *framework*, foi aplicado um

questionário de cinco questões com a finalidade de catalogar e analisar a experiência dos fisioterapeutas voluntários. As questões presentes no questionário eram:

1. **Quais as dificuldades e facilidades encontradas pelos fisioterapeutas enquanto usando o *framework* para adaptar jogos?** Nessa questão, foi solicitado que os voluntários escrevessem sugestões sobre o que poderia ser melhorado no *framework*. Posteriormente, todas as sugestões foram categorizadas e agrupadas.
2. **Os fisioterapeutas acreditam que eles conseguem configurar automaticamente as adaptações sem o auxílio de um desenvolvedor? O *framework* pode promover mudanças na percepção da autoeficácia?** Essa questão foi dividida em 6 questões, sendo elas:
 - (a) Sou capaz de escolher quais adaptações poderão acontecer no jogo.
 - (b) Posso entender quais emoções o paciente pode sentir enquanto estiver jogando o jogo.
 - (c) Posso configurar as mudanças em um jogo sem a ajuda de um profissional de Tecnologia da Informação.
 - (d) Posso entender o perfil do paciente para configurar um jogo afetivo apropriadamente.
 - (e) Posso escolher imagens e áudios que podem influenciar o estado emocional do usuário.
 - (f) Sou capaz de diferenciar emoções entre desejáveis e indesejáveis para um jogo.
3. **Os fisioterapeutas acreditam que o *framework* é útil?** Essa questão foi dividida em 10 questões, sendo elas:
 - (a) É fácil aprender como usar o *framework*.
 - (b) Interagir com o *framework* não requer muito esforço mental.
 - (c) É fácil lembrar como executar atividades no *framework*.
 - (d) Considero o *framework* fácil de usar.
 - (e) Na minha opinião, é melhor usar o *framework* e considerar o uso de jogos afetivos no processo de reabilitação ao invés do uso de jogos digitais sem adaptação.
 - (f) Assumindo que tenho acesso ao *framework*, pretendo utilizá-lo com meus pacientes
 - (g) Acredito que o uso de jogos afetivos irão fazer o uso de jogos digitais na terapia mais efetivo.

- (h) Acredito que pacientes podem apresentar engajamento maior para executar atividades quando utilizando jogos afetivos.
- (i) Acredito que adaptando músicas no jogo pode motivar os pacientes.
- (j) Acredito que adaptando imagens no jogo pode motivar os pacientes.

4. Os fisioterapeutas consideram o *framework* fácil de usar?

5. Os fisioterapeutas querem usar o *framework* futuramente?

Com exceção da primeira questão, que seguiu a metodologia descrita, todas questões utilizaram o modelo de escala *Likert* com valores entre 1 (Discordo completamente) e 6 (Concordo completamente).

De forma geral, os voluntários conseguiram utilizar o *framework* sem dificuldades. Esse fato refletiu nos resultados da primeira questão, que contou somente com críticas sobre a forma de selecionar qual categoria se encaixa cada emoção e a inclusão de mais uma categoria de emoções, as indiferentes.

Com as respostas das questões 2 e 3 foram montados, respectivamente, os gráficos presentes nas Figuras 3.31 e 3.32. Observando ambos os gráficos, pode-se notar que as respostas nos índices na escala *Likert* estão bem próximas do 6, o que indica que o estudo feito possivelmente reflete um impacto positivo no uso do *framework*.

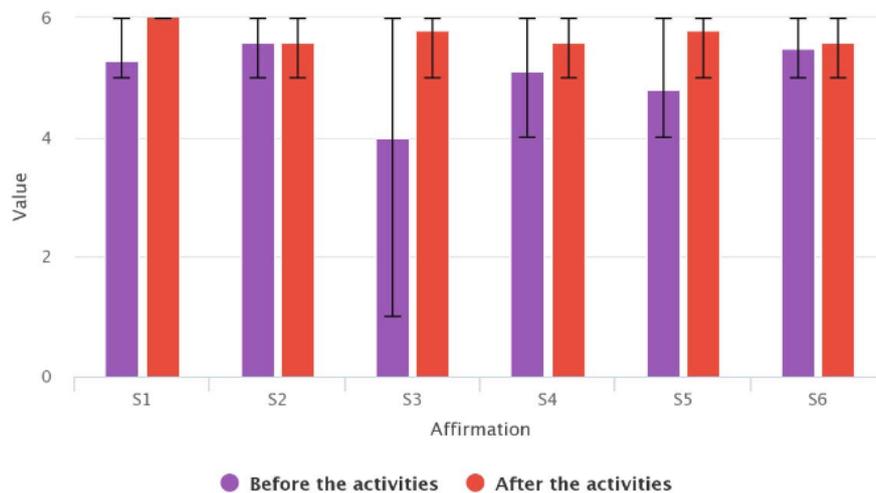


Figura 3.31: Concordância da questão 2 com relação as subquestões antes e depois da execução da validação [14]

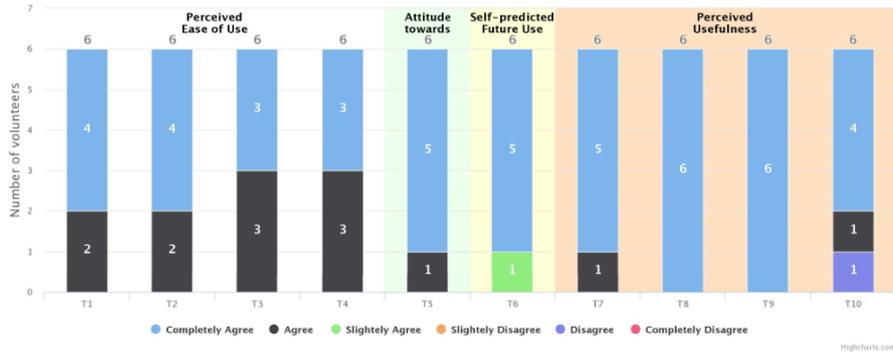


Figura 3.32: Respostas da questão 3 seguindo a escala *Likert*[14]

Concluindo, os autores apontam que as vantagens do uso do *framework* estão na baixa demanda de implementação, visto que o framework demanda apenas que sejam feito o acoplamento das adaptações no jogo enquanto a maior carga recai sobre o sistema já desenvolvido, e por necessitar fortemente da presença de um profissional da saúde, tornando o sistema mais confiável para ser utilizado como objeto auxiliar de uma terapia de reabilitação.

3.12 ADD Híbrido

Rosa et al. [15] propõem nesse trabalho adaptar um jogo de plataforma para contar com um sistema de ADD híbrido. O trabalho se dispõe a utilizar a atividade eletrodermal da pele como fonte de dados fisiológicos do jogador ao mesmo tempo que utiliza o desempenho do mesmo.

Para esse trabalho foi escolhido o jogo *The Explorer: 2D*, que foi desenvolvido pela *Unity Technologies*, para ser adaptado e adicionar suporte ao ADD híbrido. Esse jogo se trata de um jogo de plataforma, no qual o jogador conta com as ações de andar horizontalmente, pular, agachar, atacar e atirar. O jogo segue a estrutura básica de um jogo de plataforma 2D onde o jogador deve alcançar o ponto percorrendo plataformas resolvendo quebra-cabeças no caminho. A pulseira *Empatica E4*, que pode ser visualizada na Figura 3.13, também foi utilizada como sensor de aquisição de dados fisiológicos do jogador.

O sistema de ADD foi proposto para funcionar de três formas diferentes, sendo eles: apenas usando informações de desempenho, apenas usando dados afetivos e utilizando ambas informações em conjunto seguindo o descrito na Figura 3.33. O sistema varia três parâmetros a fim de ajustar a dificuldade, sendo eles: a distância horizontal entre as plataformas (Figura 3.34), a distância vertical entre as plataformas (Figura 3.35) e a altura do pulo do personagem (Figura 3.36).

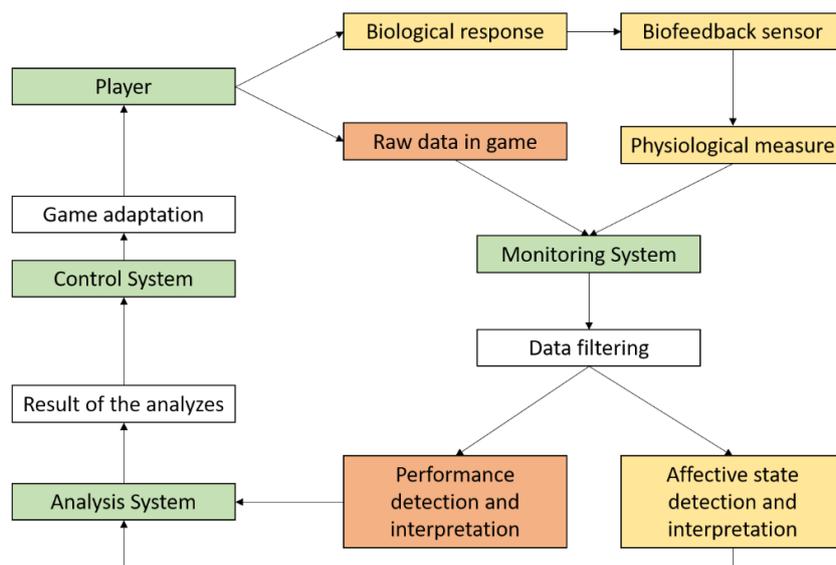


Figura 3.33: Fluxo dos dados na implementação híbrida do ADD [15]

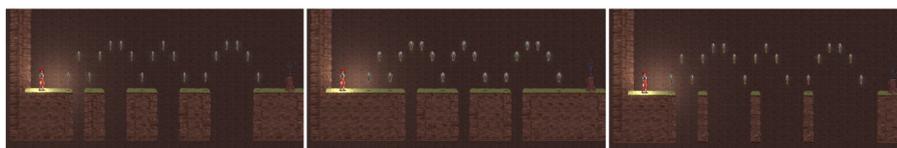


Figura 3.34: Capturas de tela mostrando a alteração da distância horizontal entre as plataformas [15]

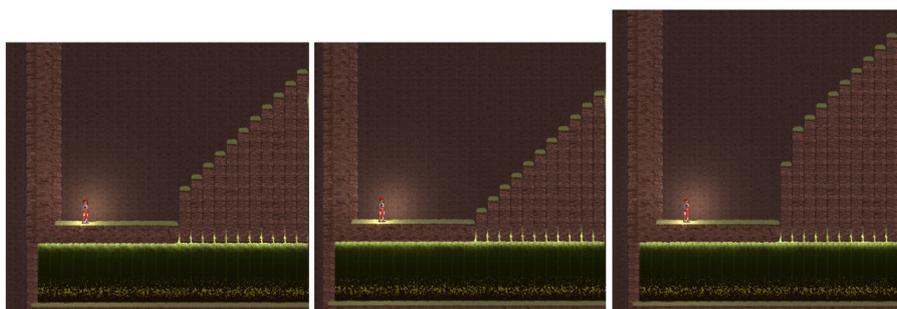


Figura 3.35: Capturas de tela mostrando a alteração da distância vertical entre as plataformas [15]

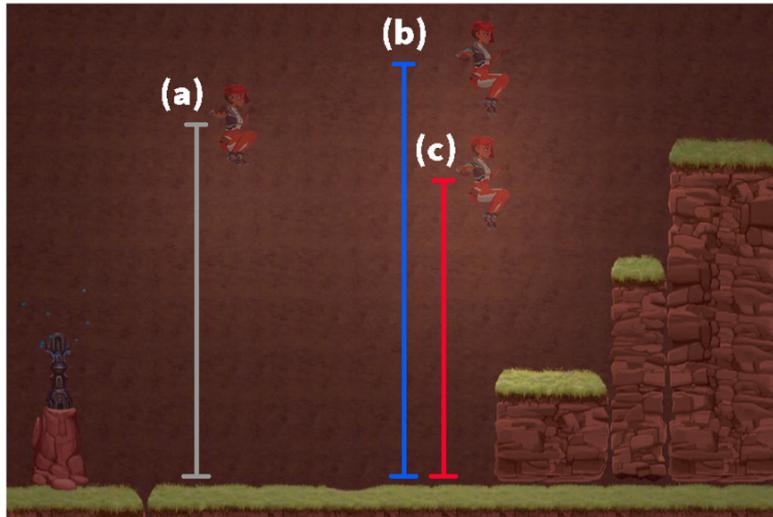


Figura 3.36: Capturas de tela mostrando a alteração da altura do pulo [15]

O sistema de análise (*Analysis System*), que pode ser visto no fluxograma na Figura 3.33, é responsável por receber as informações do desempenho e do estado afetivo do jogador e gerar um valor para a dificuldade global do jogo. Para o desempenho, o sistema diminui a dificuldade a cada vez que o jogador falha em um local no qual ele já tenha passado previamente e ao final do nível, caso ele tenha falhado alguma vez durante ele. Porém, o sistema aumenta a dificuldade conforme o jogador avança no nível. Já o sistema para análise dos dados afetivos foi feito baseando-se no *Project Rage* [38].

Os experimentos foram conduzidos em três baterias de testes com doze níveis cada. Em cada bateria, o jogador poderia pausar, revisar os controles e desistir do nível. As vidas eram infinitas e cada nível era dividido em segmentos de mesmo tamanho com a presença de pontos de checagem ao fim de cada segmento que realizava o salvamento do progresso do jogador. Na primeira bateria, cada nível foi separado em um ou dois segmentos e a dificuldade era incrementada constantemente. A finalidade dessa bateria era validar se os níveis de dificuldade estavam acurados, sendo assim, uma bateria referência. Na segunda bateria, os níveis seguiam a seguinte sequência repetindo o padrão até completar os doze níveis: sem nenhum ajuste, com ajuste utilizando desempenho, com ajuste utilizando dados afetivos e com ambos ajustes. Na terceira bateria, foi escolhido aleatoriamente um sistema de controle de adaptação, sendo eles: sem adaptação, com ajustes de plataformas (Figuras 3.34 e 3.35) baseados somente no desempenho, com ajuste na altura do pulo (Figura 3.36) baseado somente no desempenho e ambos ajustes baseados no desempenho.

Visando a validação dos testes, questionários foram aplicados antes, durante e depois da sessão de jogo. O questionário aplicado antes visava apenas obter dados sociodemográficos sobre os participantes. O questionário aplicado durante visava verificar a percepção de dificuldade a cada nível pelo participante. O questionário aplicado depois visava veri-

ficar a percepção da dificuldade pelo participante durante o jogo inteiro e se o estado de *Flow* se mantinha mesmo após o fim da sessão.

As informações sobre a população participante de cada bateria pode ser vista na Tabela 3.5. Vale ressaltar que 16 participantes da primeira bateria de testes voltaram para a segunda. Outra informação importante é que, na terceira bateria, os resultados de 23 participantes foram descartados, 12 participantes por não terem completado a sessão e 11 participantes por serem categorizados como atípicos. Como o sistema de adaptação seria randomizado entre os participantes na terceira bateria, 37 participantes ficaram sem adaptação, 29 participantes ficaram com adaptações nas plataformas, 35 participantes ficaram com adaptação na altura do pulo e 31 participantes ficaram com ambas adaptações.

Bateria	Quantidade de participantes	Faixa etária	Percentual masculino	Nível de dificuldade favorito		
				Fácil	Médio	Difícil
1	20	18-24	70%	45%	30%	25%
2	36	18-25	61,1%	50%	33,3%	16,7%
3	155	15-65	81,69%	16,20%	51,41%	32,39%

Tabela 3.5: Tabela montada com as informações sociodemográficas retiradas do trabalho [15]

Com os resultados da segunda bateria e separando os 12 níveis em 3 conjuntos de dificuldade, foi montado o gráfico mostrado na Figura 3.37. A divisão dos níveis foi fácil (1-4), médio (5-8) e difícil (9-12). Observando o gráfico gerado, pode-se notar que, para dificuldades maiores, a percepção da dificuldade foi bem menor com o uso do ADD afetivo e híbrido quando comparados aos outros modos utilizados na segunda bateria.

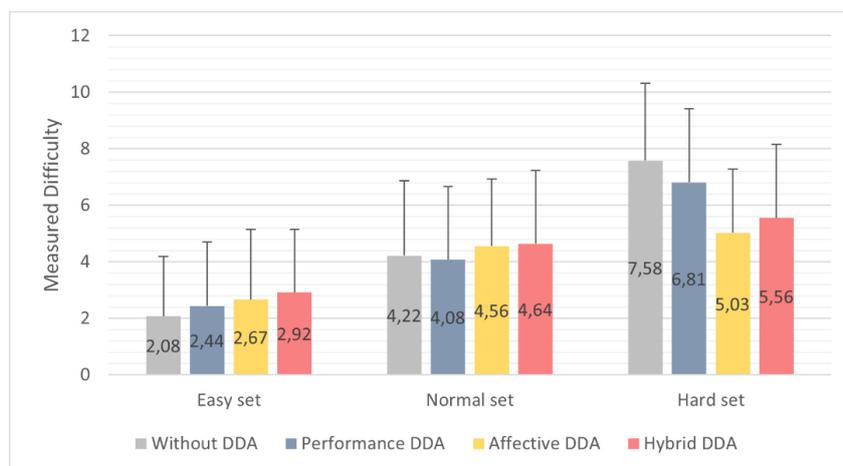


Figura 3.37: Média e desvio padrão para o valor de dificuldade medido pelo questionário na segunda bateria e dividido entre os três conjuntos de dificuldade [15]

O trabalho é concluído apontando que estudos sobre a eficiência do uso de sensores ainda são escassos, apesar que os estudos em ADD estão crescendo. Outro ponto é que, apesar de existirem vários estudos que abordam o ADD por desempenho e o ADD afetivo, poucos se propõem a combinar ambos.

Apesar das limitações encontradas ao comparar todos os sistemas utilizados, foi observado que o ADD pode equilibrar bem a dificuldade para jogadores com diversos perfis. E, por fim, é afirmado que o uso do modelo híbrido foi capaz de gerar dificuldades mais adequadas para cada jogador, o que torna a experiência mais agradável.

3.13 ADD baseado em atividade eletrodermal e expressões faciais

Bontchev e Vassileva [16] sugerem avaliar o nível de engajamento dos jogadores em um jogo afetivo, que utiliza a atividade eletrodermal e expressões faciais.

O jogo utilizado se chama *Rush for Gold*. Nele é aplicado a medição da atividade eletrodermal com a finalidade de avaliar o nível de excitação do jogador. Para isso, é utilizado o recurso do *Project RAGE* [38], que visa avaliar os níveis de excitação de um indivíduo utilizando algum dispositivo capaz de medir EDA. Além disso, o jogo conta com um módulo de reconhecimento de emoções utilizando a *Affective SDK* [31].

É apontado que o ADD foi introduzido no jogo com foco na hipótese de que isso iria diminuir o tempo de jogo dos jogadores e aumentar a eficiência e a dificuldade das tarefas feitas. Com esse intuito, o jogo se adapta em três parâmetros, como podem ser vistos nas figuras sendo eles: a velocidade do ouro que deve ser capturado, a dificuldade dos quebra-cabeças dentro do jogo e a iluminação ambiente do jogo.



Figura 3.38: Captura de tela do jogo para níveis fáceis de dificuldade (excitação baixa) [16]

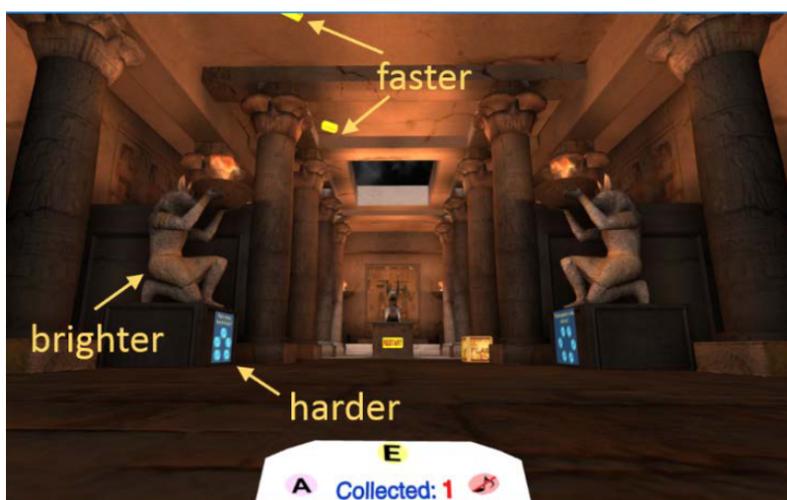


Figura 3.39: Captura de tela do jogo para níveis difíceis de dificuldade (excitação alta) [16]

Os experimentos desse estudo contaram com uma população de 30 voluntários, com média de 31 anos e 60% de participação masculina. Visando evitar ruídos nas leituras dos dados da EDA, os voluntários foram instruídos a não usarem os dedos que continham os eletrodos. Além disso, todos os voluntários, antes de jogar, ficaram com os eletrodos conectados a alguns dedos, enquanto ouvem música calma e assistem as instruções sobre o jogo por dois minutos. Após esse tempo de preparação, cada participante joga três sessões do jogo, sendo a primeira apenas para treino e as outras duas, aleatoriamente, com e sem adaptação afetiva. Completando as três sessões, cada participante era transferido do jogo *Rush for Gold* para um jogo de labirinto educacional com aprendizagem para

reconhecimento do estilo individual do participante. Finalizando o experimento, cada participante deveria responder um questionário contendo 92 itens de forma online, contendo um questionário de engajamento no jogo, que visa obter cinco parâmetros relacionados com o engajamento no jogo (presença, absorção, *flow*, imersão e engajamento), além de compartilhar suas impressões pessoais com relação todas as fases do experimento.

Agrupando os resultados dos sensores durante o jogo com o questionário aplicado, duas tabelas de correlações foi montada (Tabelas 3.6 e 3.7) mostrando as correlações entre os estados fisiológicos e a excitação com as emoções e com os itens do questionário de engajamento no jogo. Nessa tabela foi colocado em negrito os pontos com uma significativa correlação positiva. Além das tabelas, também foi feito um gráfico 3.40, que representa a frequência com a qual os participantes sentiram cada elemento do questionário.

Estado/Excitação	Questionário de Engajamento no jogo				
	Presença	Absorção	<i>Flow</i>	Imersão	Engajamento
Atenção	0,3878	0,0645	0,1779	0,0139	0,1978
Engajamento	0,0087	-0,0510	0,1871	-0,0532	0,0221
Fechamento do olhos	0,3818	0,08858	0,3711	0,1737	0,1554
Excitação tônica	0,1341	-0,1312	0,0459	-0,1067	-0,0318
Excitação fásica	-0,0119	-0,0558	-0,2177	0,10429	-0,0674

Tabela 3.6: Correlação dos estados fisiológicos e excitação inferidos pelas expressões faciais com os itens do questionário de engajamento no jogo [16]

Estado/Excitação	Emoções					
	Tristeza	Desgosto	Raiva	Surpresa	Medo	Diversão
Atenção	-0,0226	0,3712	0,2329	0,1835	-0,1677	0,2040
Engajamento	0,0782	0,7049	0,1653	0,4296	0,1013	0,8346
Fechamento do olhos	-0,1257	0,2293	0,0918	0,4657	0,1713	0,3196
Excitação tônica	0,0226	-0,1484	-0,0759	0,3873	0,3007	-0,0027
Excitação fásica	-0,0275	0,3616	-0,0307	0,1285	-0,0959	0,4008

Tabela 3.7: Correlação dos estados fisiológicos e excitação com as emoções inferidas pelas expressões faciais [16]

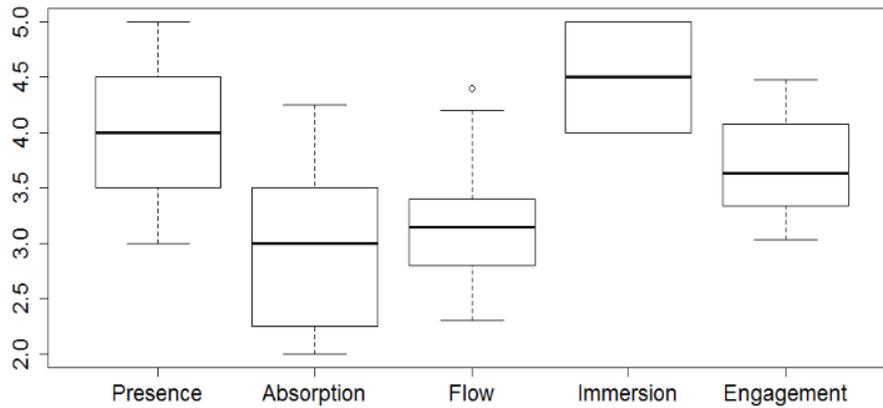


Figura 3.40: *Box plots* dos itens do questionário de engajamento no jogo medidos [16]

Observando os gráficos e tabelas gerados, os autores concluem apontando que atingiram a meta de avaliar o engajamento dos jogadores em um jogo afetivo, visto que a maioria das emoções tido como boas estão acima da média nos resultados apresentados no trabalho.

3.14 ADD baseado em Eletromiografia

Reidy et al. [17] sugerem utilizar a detecção de expressões faciais em seu estudo. Entretanto, ao invés de utilizar câmeras, como alguns estudos já abordados, é proposto o uso de eletromiografia (EMG) facial. Para coletar os dados afetivos provenientes dessa fonte foi utilizado um óculos de realidade virtual *HTC Vive* da HTC foi utilizado de forma conjunta com um protótipo do sensor *Faceteq*, como demonstrado na Figura 3.41. O estudo também é focado em analisar o uso de jogos no treinamento cognitivo de pessoas.



Figura 3.41: *HTC Vive* sendo utilizado de forma conjunta com uma versão protótipo do sensor *Faceteq* [17]

Foram desenvolvidos dois ambientes de realidade virtual, um supermercado (Figura 3.42) e um museu com várias salas (Figura 3.43), com algumas tarefas a serem realizadas. Ambas as salas visam treinar o que chamam de *working memory*, que é uma pequena parte da cognição responsável por guardar informações que podem ser utilizadas durante a execução de tarefas, e *episodic memory*, que trata sobre tornar mais fácil enfrentar certos eventos por estar experienciando novamente, respectivamente. Para o ambiente do supermercado, uma lista de compras era passada ao início para o participante, o qual deveria memorizar e buscar todos os itens colocando-os na cesta de compra. Já no ambiente do museu, existem alguns marcadores que o participante deve interagir em um primeiro momento. Após interagir com todos os marcadores presentes no mapa, os marcadores desaparecem e o participante deve interagir com os locais onde acredita que estavam os marcadores inicialmente. Após completar a segunda fase, uma mensagem é mostrada ao participante solicitando que ele indique qual é o mais velho ou o mais novo, visando analisar sua *long-term memory*, ou seja, a memória de longo prazo, visto que pessoas com melhores resultados tendem a ter desempenho melhor ao longo de várias sessões repetidas.

Foi utilizado uma implementação híbrida do ADD. As regras definidas para os ajustes podem ser vistas na Tabela 3.8.

Estado afetivo	Desempenho	Influência na dificuldade
Calmo com valência negativa	Perfeito	+2
Calmo com valência negativa	Imperfeito	+1
Valência positiva	Perfeito	+1
Valência positiva	Imperfeito	0
Valência positiva	Negativo	-1
Energético com valência negativa	Imperfeito	-1
Energético com valência negativa	Negativo	-2

Tabela 3.8: Tabela com as regras do ADD implementado montada com informações do estudo [17]



Figura 3.42: Supermercado criado em realidade virtual para a realização das tarefas tratando da *working memory* [17]



Figura 3.43: Museu criado em realidade virtual para a realização das tarefas tratando a *episodic memory* [17]

Inicialmente, cada participante era exposto a três dificuldades fixas do jogo para que fosse deduzido o intervalo de respostas emocionais do participante e preparar um conjunto de parâmetros balanceados. As dificuldades foram desenvolvidas variando o tamanho da lista de compras no supermercado (2 itens, 7 itens e 12 itens) e a quantidade de localizações no museu a serem lembradas. A cada 45 segundos, o jogo pausa para que seja as informações da EMG facial sejam registradas, caracterizando um bloco. Enquanto isso, um *slider* afetivo é mostrado ao participante para que ele responda o quão feliz estavam com o último bloco do jogo. Então essa informação será registrada juntamente as informações da EMG facial.

Os experimentos iniciais desse estudo contaram com uma população de 18 participantes, com 72,22% de participação de indivíduos do sexo masculino com idades entre 20 e 37 anos. Desses participantes, 6 foram utilizados como base para um estudo preliminar.

Cada ciclo consistia em uma introdução sobre as metas do estudo e os significados de excitação e valência. Após essa introdução, cada participante jogava por seis sessões (uma em cada dificuldade em cada um dos dois ambientes) de 3 minutos e 45 segundos. Metade dos participantes seguiram a sequência natural de dificuldade (fácil, médio e difícil), enquanto a outra metade jogou na ordem inversa. Essa medida foi tomada para que fosse evitado um possível enviesamento dos resultados. Entre cada sessão, os participantes recebiam uma pausa de 2 minutos com a finalidade de devolver a eles o estado afetivo neutro, para que uma sessão não interferisse na outra. Concluindo todas as sessões, o participante era submetido a um questionário com as seguintes questões:

1. Qual dos dois ambientes você iria preferir gastar seu tempo?
2. Em qual das duas tarefas você se sentiu mais engajado?
3. Você experienciou algum desconforto durante a sessão e, se você teve outra experiência com a realidade virtual, a adição do sensor *Faceteq* foi desconcertante de alguma forma?
4. Para qual extensão, se alguma, o esquema de anotação afetou sua experiência no jogo?

Com esse questionário, uma maioria que prefere o ambiente virtual do museu, com 10 dos 12 participantes, foi constatada. É apontado que muitas respostas leva a crer que essa preferência é proveniente do fato que o supermercado parece uma experiência da vida real, enquanto há um distanciamento da realidade no museu. Também é apontado que o uso do sensor foi positivo, visto que nenhum participante se sentiu desconfortável durante as sessões de jogo utilizando realidade virtual e alguns mal notaram a presença do sensor. E, por último, é apontado que uma grande maioria, formada por 7 dos 12 participantes, afirmam que a forma do questionário dentro do jogo acerca da emoção que sentiam interrompeu a experiência em jogo de forma mediana, enquanto dois participantes afirmaram que interrompia de forma muito intensa. Os outros três participantes não sentiram influência do questionário na experiência em jogo.

Após a validação dos estudos iniciais, experimentos visando a validação do sistema adaptativo que foi desenvolvido. Esse estudo contou com uma população de seis participantes, com 66,6% de participação de indivíduos do sexo feminino, com idades entre 60 e 100 anos e sem histórico de doença congênita. Desses participantes, nenhum jogava regularmente e apenas um teve experiências anteriores com realidade virtual. Todos participantes jogaram a versão adaptativa e a versão não-adaptativa com dificuldade linearmente crescente em sessões de 15 minutos, sendo 7 minutos e meio para ambos ambientes

em uma versão. Evitando enviesamento, metade dos jogadores jogaram a versão adaptativa primeiro, enquanto a outra metade começou pela versão não-adaptativa. Cada sessão encerrava com uma entrevista informal com o mesmo conteúdo do primeiro estudo, exceto a última pergunta, que fala sobre o impacto do questionamento durante o jogo. Além disso, após jogar cada versão, cada participante informou seus sentimentos sobre a competência, imersão sensorial e imaginativa, *flow*, tensão, desafio e afetos positivos e negativos.

Com as informações fornecidas pelos participantes após jogar cada versão, a Tabela presente na Figura 3.44 foi montada relacionando cada um dos sentimentos citados anteriormente, em ordem, com a resposta fornecida pelo participante em um valor de 0 a 4. Em geral, os resultados são tidos como positivos. Entretanto, é destacado o aumento do sentimento de competência e a diminuição do sentimento de desafio. Com isso, os autores concluem que o ADD híbrido utilizando a eletromiografia facial como fonte de dados afetivos possui um resultado encorajador para novas pesquisas, adicionando que a capacidade de classificação da valência teve uma acurácia de 64,1% e do nível de excitação, 76,2%, através da EMG.

PID	P1		P2		P3		P4		P5		P6		Mean	
	Ad	NAd	Ad	NAd										
Game Version	2	1	3	2.5	2.5	0.5	3	2	2	2	3	2	2.58	1.67
Competence	2	1	3	2.5	2.5	0.5	3	2	2	2	3	2	2.58	1.67
Sensory and Imaginative Immersion	4	3	4	4	3	2	3	3	2	3	4	4	3.33	3.17
Flow	3.5	3.5	4	3.5	3	2	3	3	2	3	3.5	2	3.17	2.83
Tension	2	3.5	0.5	0.5	0	2	0	0.5	2	0	0.5	1.5	0.83	1.33
Challenge	4	4	2.5	3	3	4	3.5	4	1	3	2	3.5	2.67	3.58
Negative Affect	1.5	3	0	0.5	0	1	0	0	0.5	0	0	0	0.33	0.75
Positive Affect	2.5	1.5	3.5	3.5	3	2	2.5	2	1.5	3	3	2.5	2.67	2.42

Figura 3.44: Tabela montada com as respostas dos participantes sobre cada versão com índices que vão de 0 a 4 [17]

Capítulo 4

Discussão

Após analisar todos os trabalhos relatados neste estudo, foram montadas as Tabelas 4.1, que visa relacionar cada trabalho abordado com a sua fonte de dados afetivos utilizadas, e 4.2, que visa relacionar cada trabalho com alguns aspectos dos jogos utilizados em seus experimentos. Essas tabelas foram construídas com o intuito de auxiliar na resposta às perguntas da pesquisa. Além disso, serão apontados algumas observações interessantes obtidas da análise dos trabalhos.

Seção	Referência	HR	EEG	FE	EDA	fNIRS	MS	DBSR	PD
3.2	[3]	✓							
3.3	[4]		✓						
3.3	[29]		✓						
3.4	[5]			✓					
3.5	[37]	✓	✓		✓				
3.6	[6]				✓				
3.7	[9]						✓	✓	
3.8	[10]					✓			
3.9	[11]							✓	
3.10	[13]								✓
3.11	[14]			✓					
3.12	[15]				✓				
3.13	[16]			✓	✓				
3.14	[17]			✓					
Total		2	3	4	4	1	1	2	1

Tabela 4.1: Relação entre trabalhos e tipos de biofeedback utilizados

Seção	Nome	Propósito	Gênero	Parâmetros ajustados	Fonte de dados afetivos
3.2	NC	A	<i>Point-n-Click</i>	Número de ocorrências	HR
3.3	NC	E	Plataforma 2D	Quantidade e dificuldade dos inimigos	EEG
3.4	NC	E	Plataforma 2D	Distância entre obstáculos Tamanho da abertura Velocidade da rolagem	FE
3.5	NC	A	<i>Puzzle VR</i>	Ajustava o andar	EEG, EDA e HR
3.6	Asteroids in 2nd and 1/2th dimension	E	<i>Space Shooter</i>	Velocidade dos asteróides	EDA
3.7	NC	A	<i>Exergames</i>	Parâmetros definidos para cada jogo específico	MS e DBSR
3.8	NC	E	Simulador	Número de UAVs	fNIRS
3.9	Space Jump	E	Plataforma 2D	Número de obstáculos Movimento das plataformas Velocidade das plataformas	DBSR
3.10	Pong	E	<i>Arcade 2D</i>	Tamanho da raquete Velocidade da bola	PD
3.11	NC	A	<i>Exergames</i>	Parâmetros a serem definidos por terapeuta	FE
3.12	The Explorer: 2D	E	Plataforma 2D	Distância vertical das plataformas Distância horizontal das plataformas Altura do pulo	EDA
3.13	Rush for Gold	E	<i>Puzzle 3D</i>	Luminosidade Velocidade dos objetivos Dificuldade dos quebra-cabeças	EDA e FE
3.14	NC	A	<i>Puzzle VR</i>	Quantidade de itens a serem lembrados	EMG

Tabela 4.2: Relação entre o trabalho, o nome do jogo (NC=Não consta), o propósito do jogo utilizado (A=Aplicado, E=Entretenimento), seu gênero, os parâmetros ajustados e o sensor empregado

4.1 Tipos de jogos mais utilizados nos estudos de ADD

Observando a Tabela 4.2, é notável que os jogos de plataforma 2D são os mais utilizados para a realização das adaptações. Uma hipótese a ser levantada para esse acontecimento pode ser a facilidade que os autores têm em desenvolver jogos desse gênero, visto que todos os jogos utilizados que são desse gênero foram desenvolvidos dentro da própria pesquisa e não somente adaptados para contar com recursos de adaptação. Ainda observando a tabela, pode-se notar que os parâmetros a serem ajustados para que ocorra o ADD seguem um padrão dentro deste gênero, pois todos ajustam ou com a dificuldade dos obstáculos ou inimigos [4, 29, 5], e/ou ajustam a dinâmica do jogo, seja a velocidade de auto rolagem [5, 11], seja a relação entre pulo e distância necessária [15].

O uso de jogos aplicados é outro fato a ser destacado, pois, apesar de não representar a maior parte dos jogos utilizados nos estudos, representam um crescente interesse no aumento do bem-estar humano, como apontado por Aranha et al. [14], que afirma que jogos aplicados, principalmente em terapias, devem ser aprimorados juntamente a terapeutas. Ou seja, pode-se inferir, que o intuito é que os jogos supram, gradativamente, a necessidade de uma presença tão próxima de um fisioterapeuta ao acompanhar um paci-

ente, mas mantendo seus fundamentos nos estudos destes profissionais. Além de terapias e treinamentos cognitivos [17], pode-se observar o uso de jogos também para o tratamento de fobias [37], reforçando o relacionamento entre jogos digitais e a saúde e contrariando o estigma de que jogos digitais não trazem saúde física [39, 40].

4.2 Fonte de dados afetivos mais utilizada

Observando a Tabela 4.1, que relaciona o trabalho realizado com as fontes de dados afetivos empregada, podemos notar uma grande presença do uso de expressões faciais e a atividade eletrodermal, contando com quatro trabalhos relatados em cada.

A maioria dos trabalhos que envolvem expressões faciais (todos com exceção do realizado por Reidy et al. [17]) fazem o uso de câmeras, que são dispositivos bem comuns no dia-a-dia das pessoas em geral, quando comparados com pulseiras utilizadas para medição da atividade eletrodermal ou os eletrodos utilizados no eletroencefalograma, por exemplo. Além disso, é o único método empregado nos trabalhos relatados que não faz o uso de sensores que estão diretamente em contato com o jogador. Essa fácil acessibilidade pode ser interpretada como o motivo de estudos utilizando esse meio de aquisição de dados serem mais abundantes, visto que os testes podem ser conduzidos remotamente, se necessário, de uma forma mais fácil e possui requisitos mais fáceis de serem encontrados no dia-a-dia. Outro dado interessante a ser destacado é que todos os trabalhos que empregaram câmeras como fonte de aquisição de dados utilizaram a *Affective Affdex SDK* [31]. Na Figura 3.30, podemos ver que se trata de um módulo a parte do jogo, ou seja, a integração feita entre o jogo e o módulo de reconhecimento requer interfaces e, seguindo a figura citada, temos que essa interface é feita através de um serviço Web, visto que, nessa arquitetura, um servidor centralizado que é responsável por realizar a análise das emoções e tomar decisões acerca das alterações da dificuldade para um determinado paciente. Entretanto, como visto no trabalho de Bonchev e Vassileva [16], o módulo pode ter uma comunicação direta com o jogo sem a necessidade que as informações sejam enviadas para um servidor, ou seja, o próprio jogo deve conter algoritmos para analisar as emoções e ajustar a dificuldade. Sendo assim, utilizando a *Affective Affdex SDK*, pode ser feito tanto uma computação centralizada em um servidor quanto a implementação direta no computador.

Entretanto, em pesquisas feitas para o presente trabalho, foram encontrados três repositórios [41, 42, 43] contendo códigos referentes a um *asset* para o *Unity Engine* com o intuito de fazer o reconhecimento de emoções baseando-se nas expressões faciais. Esses repositórios são pertencentes ao *Project RAGE* e provenientes do estudo realizado por Bahreini et al. [32], cujo site se encontra fora do ar no presente momento da escrita dessa monografia. Com o fato do site pertencente ao projeto estar fora do ar, muita in-

formação sobre os códigos contidos nesses repositórios podem ter sido perdidas. Porém, foi encontrado um vídeo no Youtube [44], que mostra o uso do código contido nesses três repositórios realizando, nativamente dentro do *Unity Engine*, a tarefa de adquirir imagens do usuário pela câmera conectada ao computador e estimar as suas emoções com base nas expressões faciais. O uso desses códigos pode ser uma alternativa ao uso da *Affective Affdex SDK*, visto que esses códigos se encontram sob a licença *Apache License*, o que os torna de código aberto e livres uso e distribuição, desde que incluam um aviso de *copyright* e um *disclaimer* informando o uso da ferramenta desenvolvida por outros.

O uso da atividade eletrodermal também se mostrou bastante presente nas pesquisas relacionadas ao ADD afetivo. Entretanto, esse método mostrou que é suscetível a ruídos na leituras, como no estudo feito por Bontchev e Dessileva [16], quando foi recomendado que os participantes não utilizassem os dedos utilizados para leitura da EDA. Além desse fator, vale ressaltar que a pulseira utilizada por Bandeira et al. [6] e Rosa et.al [15], a pulseira *Empatica E4*, que pode ser vista na Figura 3.13, está sendo anunciada, no momento da produção desse trabalho, 1690 dólares americanos [45]. Esse valor pode ser demasiadamente elevado para determinados projetos, além de inviabilizar algumas ações como conduzir os testes remotamente, visto que uma das maiores queixas dentre os trabalhos é a falta de população para amostragens (fenômeno algumas vezes atribuídos à pandemia, que limitou a possibilidade que os estudos fossem realizados com outras pessoas). Entretanto, como visto no trabalho de Balan et al. [37], ainda é um sensor de considerável acurácia.

4.3 Resultados obtidos pelos trabalhos relatados

Os trabalhos relatados neste estudo apontaram, no geral, resultados positivos. Vale ressaltar que no estudo feito por Ninaus et al. [3] apresentou uma piora na porcentagem de pessoas que conseguiram completar o jogo e o tempo restante quando conseguiram concluir, como pode ser visto na Tabela 3.2, que demonstra que a versão não-adaptativa foi encarada como mais fácil que a adaptativa pelos participantes. Esse comportamento distoa de todos os outros resultados, visto que todos demonstraram uma diminuição na percepção da dificuldade pelo usuário, como, por exemplo, pode ser visto na Figura 3.37, que pertence ao trabalho de Rosa et al. [15] e visava justamente comparar o uso do ADD Afetivo, tanto sozinho quanto combinado ao ADD por desempenho, com a ausência de sensores. Entretanto, como apontado por Ninaus et al. [3], o intuito era que os participantes fossem expostos ao maior tempo possível treinando para situações estressantes do dia-a-dia às quais poderão ser expostos futuramente.

Portanto, pode-se notar que o ADD afetivo pode ser utilizado também para induzir emoções no jogador e não somente adaptar a dificuldade tornando a experiência mais agradável. Fato esse que corrobora com a hipóteses de trabalhos que visam induzir emoções em seus jogadores, como o feito por Lara-Álvarez et al. [46] e Moschovitis e Denisova [47]. Esse fato também reforça a hipótese de que diferentes emoções podem ser desejadas em diferentes ocasiões com diferentes objetivos.

Observando as Tabelas 4.1 e 4.2, pode-se notar também que tem-se muitas linhas de abordagem que possuem apenas um trabalho, como o uso do fNIRS [10] e a dilatação da pupila [13], o que demonstra que até mesmo o conhecimento que se tem hoje se encontra separado em várias vertentes e, às vezes, de forma homogênea. Esse fato pode apontar uma grande necessidade da criação de estudos de replicação, para que o mesmo paradigma dentro do ADD Afetivo seja estudado de outro ponto de vista, o que pode permitir novas constatações e fortalecer o que já foi descoberto. E observando outros resultados e conclusões dos trabalhos relatados, é notável o fato de que todos os estudos prévios sobre esse assunto são bastante motivadores para que haja cada vez mais estudos sobre, visto que todos autores demonstram isso em seus resultados enquanto deixam novos caminhos a serem seguidos em suas conclusões, normalmente, ampliando a população experimental e o uso de novos sensores.

4.4 Estudos e aprimoramentos com sensores

Observando os trabalhos relatados e alguns outros, é possível notar que muitos querem apenas testar a viabilidade de utilizar determinado sensor como fonte de aquisição de dados afetivos, ou ainda validar o uso deste sensor na implementação de ADD afetivo, como foi o caso de Ninaus et al. [3], Strauch et al. [13] e Bontchev e Dessileva [16]. Isso demonstra que até mesmo os sensores vêm sendo aprimorados e estudados, como no estudo feito por Frommel et al. [35], por exemplo, que visa estudar a viabilidade de utilizar a pressão realizada por um jogador em uma mesa digitalizadora para determinar quais eram os níveis de excitação e valência em tempo real e, conseqüentemente, suas emoções. Ou seja, além dos sensores que já foram utilizados nos trabalhos relatados, estudos com novos sensores para detectar emoções estão sendo realizados, o que encoraja que mais sensores sejam utilizados no ADD afetivo.

Também é importante ressaltar a necessidade de estudos como o realizado por Balan et al. [37], que teve como objetivo confrontar e analisar a acurácia de alguns sensores com a finalidade de estabelecer quais demonstram acurácia maiores quando comparados com outros.

Analisando de uma forma geral, todos trabalhos relatados apontaram uma forte correlação entre as estimativas feitas pelos sensores e as emoções experienciadas pelos participantes dos experimentos. Fato que encoraja ainda mais o aprofundamento e aperfeiçoamento do uso dos sensores citados em novas pesquisas, bastando que seja feita a escolha do sensor levando em consideração os sensores e suas características demonstradas no decorrer desse trabalho, visto que todos tiveram resultados positivos, porém nenhum com 100% de acurácia.

Com isso, pode-se inferir que não basta evoluir somente o *software* empregado, mas essa evolução deve ser acompanhada pela evolução do *hardware* para que tenha-se sensores cada vez mais precisos, embora, por se tratar de emoções humanas, dificilmente será possível atingir os 100% de acurácia.

Capítulo 5

Conclusão

O ajuste dinâmico de dificuldade afetivo apresenta-se como um assunto com vários caminhos a serem seguidos. Seja utilizando apenas os dados afetivos, seja utilizando-o de forma híbrida combinando dados de desempenho também, existem muitas abordagens a serem trabalhadas. Visto que as ferramentas que permitem a implementação de sistemas adaptativos evoluem com o passar do tempo, tanto se tratando de hardwares melhores, que podem ser sensores novos ou, até mesmo, computadores com maior capacidade de processamento, quanto do ponto de vista de software, com novas técnicas, por exemplo.

Para um melhor desenvolvimento do assunto é necessário um estudo o quanto mais holístico possível com o intuito que sejam reunidas informações. Tais estudos também podem ter como objetivo facilitar futuras pesquisas a serem desenvolvidas. Visto que vários estudos existem abordando o ajuste dinâmico de dificuldade afetivo podendo levar a vários pontos de partidas diferentes. Entretanto, cada estudo atém-se somente a conversar sobre o necessário para que se chegar ao resultado da pesquisa. Com isso, todo o conhecimento fica separado e isso dificulta o início de algumas pesquisas, algumas tomadas de decisão, entre outros acontecimentos que são possíveis dentro de uma pesquisa.

É possível observar que os estudos tendem a modelar o *flow* como sendo uma definição única a qual todos indivíduos irão responder da mesma forma. Entretanto, é importante ressaltar que, como aponta Chen ao definir o *flow* em jogos, diferentes perfis de jogadores podem ter diferentes canais de *flow*. Entretanto, os estudos também ressaltam a adaptação do conceito de *flow* de acordo com sua necessidade, visto que pode-se notar que diferentes estudos mensuraram o *flow* de diferentes formas com a finalidade de provar apenas o que é proposto por ele.

Outro notável aspecto nos estudos apresentados é a presença dos chamados jogos sérios (*serious games*), visto que tem vários trabalhos buscando aplicar o ajuste dinâmico de dificuldade a jogos utilizados em fisioterapias, treinamentos cognitivos e aprendizados. Jogos sérios já existiam há bastante tempo, entretanto, muito voltados para o aprendizado

do jogador. Porém, alguns estudos analisados mostraram que os jogos podem ir além e serem agentes na reabilitação de pessoas e, com a adição do ajuste dinâmico de dificuldade, fazer terapias cada vez mais adaptadas à necessidade do paciente. Essas investigações também mostraram que, apesar de ainda necessário, o papel do fisioterapeuta é reduzido, diminuindo a necessidade de um acompanhamento tão próximo, aumentando a capacidade de atendimento e buscando não ocasionar a perda de qualidade. Além disso, os gastos com uma instalação para que os pacientes realizem suas sessões de fisioterapia podem ser reduzidos, uma vez que os pacientes podem realizar os exercícios diretamente de seu domicílio sem a necessidade de se deslocar até uma unidade de saúde.

A análise dos trabalhos relatados e a criação das Tabelas 4.1 e 4.2 possibilitou o conhecimento de que as expressões faciais compõem a fonte de biosinais mais utilizadas nos trabalhos mais recentes que abordam ADD. Observando esses dados, também foi possível constatar que a atividade eletrodermal é um meio bastante utilizado e com acurácia considerável, apesar de ser caro. Os parâmetros adaptados em cada jogo, bem como seu gênero, é outra informação a ser destacada utilizando as tabelas, as quais permitiram que fosse constatado que Plataforma 2D é o gênero mais utilizado para adaptações. E todos os trabalhos apresentaram uma forte correlação entre o uso dos sensores e certas emoções durante o jogo, encorajando novas pesquisas.

Por fim, vale frisar que essa área está em constante desenvolvimento, apesar de ter se observado uma redução de produção científica acerca do tema durante a pandemia. Assim, sugere-se que levantamentos sobre os estudos mais recentes, seja uma constante nesta área que ainda encontra-se em fase prematura. Acredita-se que estudos como este aqui é apresentado podem servir como um ponto de partida para avanços das pesquisas em ADD Afetivo. Talvez seja bastante válido tentar isolar pequenas partes para um estudo mais aprofundado, pois esse estudo demonstrou que há diversas abordagens e novas abordagens estão sendo desenvolvidas, fato que pode dificultar uma padronização e uma análise holística na população amostral como um todo. A diminuição da complexidade ao isolar uma emoção para ser estudada, como foi o caso do nível do medo, corrobora essa hipótese. Esse estudo também mostrou a necessidade de estudos de replicação dos trabalhos já feitos, visto que os estudos abordam o mesmo assunto de formas bem variadas de forma que impossibilita comparações e mais comprovações.

Referências

- [1] Russell, James: *A Circumplex Model of Affect*. Journal of Personality and Social Psychology, 39:1161–1178, dezembro 1980. ix, 3, 4
- [2] Chen, Jenova: *Flow in games (and everything else)*. Commun. ACM, 50(4):31–34, abril 2007, ISSN 0001-0782. ix, 1, 5, 6, 7
- [3] Ninaus, Manuel, Katerina Tsarava e Korbinian Moeller: *A Pilot Study on the Feasibility of Dynamic Difficulty Adjustment in Game-Based Learning Using Heart-Rate*. Em Liapis, Antonios, Georgios N. Yannakakis, Manuel Gentile e Manuel Ninaus (editores): *Games and Learning Alliance*, páginas 117–128, Cham, 2019. Springer International Publishing, ISBN 978-3-030-34350-7. ix, xii, 7, 12, 13, 14, 15, 60, 63, 64
- [4] Fernandez B., Henry D., Koji Mikami e Kunio Kondo: *Adaptable Game Experience Based on Player’s Performance and EEG*. Em *2017 Nicograph International (NicoInt)*, páginas 1–8, junho 2017. ix, 7, 16, 17, 19, 20, 21, 22, 60, 61
- [5] Burns, Andrew e James Tulip: *Detecting flow in games using facial expressions*. Em *2017 IEEE Conference on Computational Intelligence and Games (CIG)*, páginas 45–52, agosto 2017. ix, 7, 8, 23, 24, 25, 26, 60, 61
- [6] Bandeira, Ian Nery, Vitor F. Dullens, Thiago V. Machado, Rennê Ruan A. Oliveira, Carla D. Castanho, Tiago B. P. e Silva e Mauricio M. Sarmet: *Dynamic Difficulty Adjustment in digital games: Comparative study between two algorithms using electrodermal activity data*. 2022. ix, x, 7, 9, 28, 29, 30, 31, 60, 63
- [7] Antunes, Felipe: *Plug and blast: Balance board (wii)*, junho 2011. <https://www.nintendoblast.com.br/2011/06/plug-and-blast-balance-board-wii.html>, acesso em 22-12-2022. x, 32
- [8] Bohrer, Marcio: *Como funciona o kinect*, julho 2013. <https://www.oficinadanet.com.br/post/11069-como-funciona-o-kinect>, acesso em 22-12-2022. x, 33
- [9] Pezzera, Manuel e N. Alberto Borghese: *Dynamic difficulty adjustment in exer-games for rehabilitation: A mixed approach*. Em *2020 IEEE 8th International Conference on Serious Games and Applications for Health (SeGAH)*, páginas 1–7, agosto 2020. x, 9, 32, 34, 60
- [10] Afergan, Daniel, Evan M. Peck, Erin T. Solovey, Andrew Jenkins, Samuel W. Hincks, Eli T. Brown, Remco Chang e Robert J.K. Jacob: *Dynamic difficulty using brain*

- metrics of workload.* Em *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, CHI '14, páginas 3797–3806, New York, NY, USA, abril 2014. Association for Computing Machinery, ISBN 978-1-4503-2473-1. x, 1, 8, 35, 36, 37, 60, 64
- [11] Frommel, Julian, Fabian Fischbach, Katja Rogers e Michael Weber: *Emotion-based Dynamic Difficulty Adjustment Using Parameterized Difficulty and Self-Reports of Emotion.* Em *Proceedings of the 2018 Annual Symposium on Computer-Human Interaction in Play*, CHI PLAY '18, páginas 163–171, New York, NY, USA, outubro 2018. Association for Computing Machinery, ISBN 978-1-4503-5624-4. x, xii, 9, 38, 39, 40, 41, 60, 61
- [12] iMotions: *Smi-red*, novembro 2022. <https://imotions.com/products/hardware/smi-red/>, acesso em 20-01-2023. x, 42
- [13] Strauch, Christoph, Michael Barthelmaes, Elisa Altgassen e Anke Huckauf: *Pupil Dilation Fulfills the Requirements for Dynamic Difficulty Adjustment in Gaming on the Example of Pong.* Em *ACM Symposium on Eye Tracking Research and Applications*, ETRA '20 Adjunct, páginas 1–9, New York, NY, USA, junho 2020. Association for Computing Machinery, ISBN 978-1-4503-7135-3. x, 9, 42, 43, 60, 64
- [14] Aranha, Renan Vinicius, Leonardo Souza Silva, Marcos Lordello Chaim e Fatima de Lourdes dos Santos Nunes: *Using Affective Computing to Automatically Adapt Serious Games for Rehabilitation.* Em *2017 IEEE 30th International Symposium on Computer-Based Medical Systems (CBMS)*, páginas 55–60, Thessaloniki, junho 2017. IEEE, ISBN 978-1-5386-1710-6. x, 1, 44, 47, 48, 60, 61
- [15] Rosa, Marcos P. C., Eduardo A. dos Santos, Iago L. R. de Moraes, Tiago B. P. e Silva, Mauricio M Sarmet, Carla D. Castanho e Ricardo P Jacobi: *Dynamic Difficulty Adjustment Using Performance and Affective Data in a Platform Game.* 2021. x, xii, 7, 9, 48, 49, 50, 51, 60, 61, 63
- [16] Bontchev, Boyan e Dessislava Vassileva: *Assessing engagement in an emotionally-adaptive applied game.* Em *Proceedings of the Fourth International Conference on Technological Ecosystems for Enhancing Multiculturality*, TEEM '16, páginas 747–754, New York, NY, USA, novembro 2016. Association for Computing Machinery, ISBN 978-1-4503-4747-1. x, xii, 6, 7, 8, 52, 53, 54, 55, 60, 62, 63, 64
- [17] Reidy, Lorcan, Dennis Chan, Charles Nduka e Hatice Gunes: *Facial Electromyography-based Adaptive Virtual Reality Gaming for Cognitive Training.* Em *Proceedings of the 2020 International Conference on Multimodal Interaction*, ICMI '20, páginas 174–183, New York, NY, USA, outubro 2020. Association for Computing Machinery, ISBN 978-1-4503-7581-8. xi, xii, 1, 8, 9, 55, 56, 57, 59, 60, 62
- [18] Ang, Dennis e Alex Mitchell: *Comparing Effects of Dynamic Difficulty Adjustment Systems on Video Game Experience.* 2017. 1, 7
- [19] Robb, Nigel e Bo Zhang: *Empirical Evaluation of Player Experience Using a Machine-Learning Approach to Dynamic Difficulty Adjustment in Video Games.* junho 2020. 1, 7

- [20] Guo, Han Wen, Yu Shun Huang, Jen Chien Chien e Jiann Shing Shieh: *Short-term analysis of heart rate variability for emotion recognition via a wearable ECG device*. Em *2015 International Conference on Intelligent Informatics and Biomedical Sciences (ICIIBMS)*, páginas 262–265, novembro 2015. 1, 8
- [21] Eesee, Abdulrahman K.: *The suitability of the Galvanic Skin Response (GSR) as a measure of emotions and the possibility of using the scapula as an alternative recording site of GSR*. Em *2019 2nd International Conference on Electrical, Communication, Computer, Power and Control Engineering (ICECCPCE)*, páginas 80–84, fevereiro 2019. 1, 9
- [22] Izard, C.E. e Brian Ackerman: *Motivational, organizational, and regulatory functions of discrete emotions*. *Handbook of Emotions*, páginas 253–264, janeiro 2000. 3
- [23] Ekman, P., E. R. Sorenson e W. V. Friesen: *Pan-cultural elements in facial displays of emotion*. *Science*, 164(3875):86–88, abril 1969, ISSN 0036-8075. 3, 4
- [24] Hupont Torres, Isabelle, Sandra Baldassarri e Eva Cerezo: *Facial emotional classification: From a discrete perspective to a continuous emotional space*. *Formal Pattern Analysis & Applications*, 16:41–54, fevereiro 2013. 3
- [25] Hudlicka, Eva: *Affective computing for game design*. 4th International North-American Conference on Intelligent Games and Simulation, Game-On 'NA 2008, páginas 5–12, janeiro 2008. 3, 4
- [26] Mehrabian, A. e J. Russell: *An approach to environmental psychology*. 1974. 3, 4
- [27] Csikszentmihalyi, Mihaly: *Flow: The Psychology of Optimal Experience*. Harper Collins e-Books, 1990, ISBN 978-0-06-133920-2. 4
- [28] Sweetser, Penelope e Peta Wyeth: *GameFlow: A model for evaluating player enjoyment in games*. *Comput. Entertain.*, 3(3):3, julho 2005. 6
- [29] Fernandez, Henry, Koji Mikami e Kunio Kondo: *Adaptable game experience through procedural content generation and brain computer interface*. Em *ACM SIGGRAPH 2016 Posters*, SIGGRAPH '16, páginas 1–2, New York, NY, USA, julho 2016. Association for Computing Machinery, ISBN 978-1-4503-4371-8. 7, 15, 60, 61
- [30] Nogueira, Pedro A., Vasco Torres, Rui Rodrigues, Eugénio Oliveira e Lennart E. Nacke: *Vanishing scares: Biofeedback modulation of affective player experiences in a procedural horror game*. *Journal on Multimodal User Interfaces*, 10(1):31–62, março 2016, ISSN 1783-8738. 7
- [31] Affectiva: *Humanizing technology*, setembro 2022. <https://www.affectiva.com>, acesso em 27-01-2023. 8, 23, 45, 52, 62
- [32] Bahreini, Kiavash, Wim van der Vegt e Wim Westera: *A fuzzy logic approach to reliable real-time recognition of facial emotions*. *Multimed Tools Appl*, 78(14):18943–18966, julho 2019, ISSN 1573-7721. 8, 62

- [33] Emayavaramban, G., A. Amudha, M. Siva Ramkumar, S. Divyapriya e P. Nagaveni: *Surface Eletromyography Feature Extraction Techniques – A Review*. Em *2020 4th International Conference on Electronics, Communication and Aerospace Technology (ICECA)*, páginas 441–446, novembro 2020. 8
- [34] Gevins, A.S., C.L. Yeager, S.L. Diamond, J. Spire, G.M. Zeitlin e A.H. Gevins: *Automated analysis of the electrical activity of the human brain (EEG): A progress report*. *Proceedings of the IEEE*, 63(10):1382–1399, outubro 1975, ISSN 1558-2256. 8
- [35] Frommel, Julian, Claudia Schrader e Michael Weber: *Towards Emotion-based Adaptive Games: Emotion Recognition Via Input and Performance Features*. 2018. 9, 64
- [36] Dobesova, Z. e M. Malcik: *Workflow diagrams and pupil dilatation in eye-tracking testing*. Em *2015 13th International Conference on Emerging eLearning Technologies and Applications (ICETA)*, páginas 1–6, novembro 2015. 9
- [37] Bălan, Oana, Gabriela Moise, Alin Moldoveanu, Florica Moldoveanu e Marius Leordeanu: *Does automatic game difficulty level adjustment improve acrophobia therapy? differences from baseline*. Em *Proceedings of the 24th ACM Symposium on Virtual Reality Software and Technology, VRST '18*, páginas 1–2, New York, NY, USA, novembro 2018. Association for Computing Machinery, ISBN 978-1-4503-6086-9. 27, 60, 62, 63, 64
- [38] Vassileva, Dessislava: *Real-time arousal detection using galvanic skin response asset*, março 2018. <https://github.com/ddessy/RealTimeArousalDetectionUsingGSR>, acesso em 25-01-2023. 50, 52
- [39] de Vasconcellos, Marcelo Simao e Inesita Soares de Araujo: *Video games and participation in health - How online games can foster population's participation in public health policies*. Em *2014 IEEE 3rd International Conference on Serious Games and Applications for Health (SeGAH)*, páginas 1–8, maio 2014. 62
- [40] Sawyer, Ben: *From Cells to Cell Processors: The Integration of Health and Video Games*. *IEEE Computer Graphics and Applications*, 28(6):83–85, novembro 2008, ISSN 1558-1756. 62
- [41] Applied Gaming Eco-system, Project RAGE(Realising an: *Emotion detection asset*, fevereiro 2019. <https://github.com/rageappliedgame/EmotionDetectionAsset>, acesso em 05-02-2023. 62
- [42] Applied Gaming Eco-system, Project RAGE(Realising an: *Asset manager*, janeiro 2019. <https://github.com/rageappliedgame/AssetManager>, acesso em 05-02-2023. 62
- [43] Applied Gaming Eco-system, Project RAGE(Realising an: *Emotion detection asset unity demo*, julho 2017. https://github.com/rageappliedgame/EmotionDetectionAsset_UnityDemo, acesso em 05-02-2023. 62

- [44] Project RAGE(Realising an Applied Gaming Eco-system): *Real-time emotion detection (recognition) from facial expressions in unity3d - how to guide.*, janeiro 2018. <https://www.youtube.com/watch?v=1sIJVrmI94Y>, acesso em 05-02-2023. 63
- [45] Store, Empatica: *E4 wristband*. <https://www.empatica.com/en-int/store/e4-wristband/>, acesso em 05-02-2023. 63
- [46] Lara-Álvarez, Carlos, Hugo Mitre-Hernandez, Juan J. Flores e Humberto Pérez-Espinosa: *Induction of Emotional States in Educational Video Games Through a Fuzzy Control System*. IEEE Transactions on Affective Computing, 12(1):66–77, janeiro 2021, ISSN 1949-3045. 64
- [47] Moschovitis, Paraschos e Alena Denisova: *Keep Calm and Aim for the Head: Biofeedback-Controlled Dynamic Difficulty Adjustment in a Horror Game*. IEEE Transactions on Games, páginas 1–1, 2022, ISSN 2475-1510. 64