

Dedicatória

Dedico esta dissertação a todos aqueles que me apoiaram ao longo desta jornada acadêmica. Aos meus pais, esposa e filhos, que sempre acreditaram em mim e me proporcionaram o incentivo necessário para alcançar este objetivo.

Aos meus orientadores, o Prof. Dr. Ricardo Pezzuol Jacobi e a Profa. Dra. Carla Denise Castanho, e demais professores do Departamento de Ciências da Computação (CIC) da Universidade de Brasília (UnB), cuja sabedoria e orientação desempenharam um papel fundamental no desenvolvimento deste trabalho.

A todos que, de uma maneira ou de outra, contribuíram para o meu crescimento acadêmico e pessoal, dedico esta dissertação como um profundo gesto de gratidão.

Agradecimentos

Primeiramente, quero expressar minha profunda gratidão a Deus por ter me dado saúde, força e inspiração necessárias durante toda esta jornada.

Agradeço aos meus orientadores, o Prof. Dr. Ricardo Pezzuol Jacobi e a Profa. Dra. Carla Denise Castanho, pela dedicação e confiança depositada em mim ao longo de todo o período do mestrado. Valorizo profundamente a oportunidade de aprendizado e o tempo que dedicaram a mim durante esses anos.

Aos professores do Departamento de Ciências da Computação (CIC) da Universidade de Brasília (UnB), agradeço pelo valioso conhecimento adquirido. Tenho absoluta convicção que os ensinamentos transmitidos, contribuíram de maneira significativa para o meu crescimento acadêmico e profissional.

Agradeço ao Prof. Dr. Tiago Barros Pontes e Silva e ao Prof. Dr. Thiago Malheiros Porcino, por fazerem parte da banca avaliadora e pelas valiosas sugestões de aprimoramento. Também estendo meu agradecimento a todos os voluntários que contribuíram nos testes conduzidos para esta pesquisa.

Um agradecimento especial ao meu amigo e colaborador Vinicius Falcone Silveira do Prado, a quem sempre pude contar para garantir o sucesso contínuo da minha empresa. Seu apoio foi fundamental para o avanço dos meus estudos.

Aos meus pais, dedico meus sinceros agradecimentos. O apoio e a compreensão ao longo desse período, desempenharam um papel essencial para o meu equilíbrio e sucesso nesta jornada. Agradeço também aos meus amigos e colegas que contribuíram, tanto de forma direta quanto indireta, para esta pesquisa.

Por fim, gostaria de expressar meu profundo agradecimento à minha esposa, pelo seu apoio incondicional durante este período, e também aos meus filhos, que não apenas suportaram, mas também compreenderam o tempo que o pai teve que dedicar aos estudos e a esta pesquisa. Talvez a frase que vocês mais ouviram durante esse período tenha sido "Não posso, tenho que estudar". O apoio e companheirismo de vocês foram essenciais para o sucesso desta etapa da minha vida. Sou eternamente grato por todos os sacrifícios que vocês fizeram.

O que sabemos é uma gota, o que não sabemos é um oceano.

Isaac Newton

Resumo

A *Cybersickness* (CS) representa um dos principais obstáculos para o uso da Realidade Virtual (RV), frequentemente desencadeada pelo uso de dispositivos *Head-mounted Display* (HMD). Os sintomas associados à CS podem variar entre indivíduos e incluem náusea, vertigem, fadiga ocular e dor de cabeça, podendo persistir por minutos ou até horas após a exposição à VR. Apesar de várias teorias sobre as possíveis causas da CS, ainda não há um método fácil ou sistemático para sua medição e quantificação. Geralmente, os pesquisadores recorrem a medidas subjetivas, como questionários autorrelatados pré e pós-experiência, como o *Virtual Reality Sickness Questionnaire* (VRSQ) [1]. Em estudos anteriores, várias abordagens foram utilizadas para medir a intensidade da CS, incluindo medidas subjetivas e objetivas. De acordo com a literatura, a *Cybersickness* tem um impacto considerável em sinais fisiológicos, como ondas delta no *Electroencephalogram* (EEG), *Heart Rate* (HR), *Heart Rate Variability* (HRV), *Galvanic Skin Response* (GSR) e *Electrogastrography* (EGG), que apresentam correlação significativa com essa condição. Porém, existe uma lacuna significativa em pesquisas que explorem a aplicação da Aprendizagem de Máquina Simbólico para identificar as causas da CS em jogos de Realidade Virtual, com foco em interpretações compreensíveis para os seres humanos. Neste contexto, nossa principal hipótese é que a combinação de avaliações quantitativas (dados de biosinais e do jogo) e subjetivas (dados dos questionários *Cybersickness Profile Questionnaire* (CSPQ)), aplicando técnicas de *Machine Learning* Simbólico, seja eficaz na identificação das causas da CS. Para validar essa hipótese, desenvolvemos um software para registrar os biosinais e autorrelatos dos sintomas pelos participantes, durante os experimentos com 17 voluntários. No decorrer dos experimentos, os participantes ficaram imersos em dois jogos de VR, enquanto seus sinais fisiológicos (ECG, EDA e ACC) e dados do jogo foram capturados. Os resultados de nossa pesquisa confirmaram a eficácia do modelo e abordagem proposta, na elaboração de um ranking dos fatores mais pertinentes para os sintomas da *Cybersickness*.

Palavras-chave: Realidade Virtual, Cybersickness, Biosinais, Dispositivos HMD, Aprendizado de Máquina Simbólico, Árvore de Decisão, Random Forest.

Abstract

Cybersickness (CS) represents one of the main obstacles to the use of *Virtual Reality* (VR), often triggered by the use of *Head-mounted Display* (HMD) devices. Symptoms associated with CS can vary among individuals and include nausea, dizziness, eye fatigue, and headache, which may persist for minutes or even hours after VR exposure. Despite various theories on the potential causes of CS, there is still no easy or systematic method for its measurement and quantification. Researchers typically rely on subjective measures, such as pre and post-experience self-reported questionnaires, such as the *Virtual Reality Sickness Questionnaire* (VRSQ) [1]. In previous studies, various approaches were used to measure the intensity of CS, including both subjective and objective measures. According to the literature, *Cybersickness* has a considerable impact on physiological signals, such as delta waves in *Electroencephalogram* (EEG), *Heart Rate* (HR), *Heart Rate Variability* (HRV), *Galvanic Skin Response* (GSR), and *Electrogastrography* (EGG), which show significant correlation with this condition. However, there is a significant gap in research exploring the application of Symbolic Machine Learning to identify the causes of CS in Virtual Reality games, focusing on interpretations understandable to humans. In this context, our main hypothesis is that the combination of quantitative (biosignal and game data) and subjective assessments (data from *Cybersickness Profile Questionnaire* (CSPQ) questionnaires), applying Symbolic *Machine Learning* techniques, will be effective in identifying the causes of CS. To validate this hypothesis, we developed software to record the biosignals and self-reported symptoms by participants during experiments with 17 volunteers. Throughout the experiments, the participants were immersed in two VR games, while their physiological signals (ECG, EDA, and ACC) and game data were captured. The results of our research confirmed the effectiveness of the proposed model and approach, in developing a ranking of the most relevant factors for the symptoms of *Cybersickness*.

Keywords: Virtual Reality, Cybersickness, Biosignals, HMD Devices, Symbolic Machine Learning, Decision Tree, Random Forest.

Sumário

1	Introdução	1
1.1	Motivação	1
1.2	Objetivo	3
1.3	Metodologia	4
1.4	Organização do Texto	6
2	Fundamentação	7
2.1	Realidade Virtual	7
2.2	Motion Sickness, VIMS e Cybersickness	9
2.3	Abordagens da Cybersickness	12
2.3.1	Teorias da CS	12
2.3.2	Fatores que contribuem para a CS	14
2.4	Métodos de Avaliação em Cybersickness	17
2.4.1	Método Qualitativo	17
2.4.2	Método Quantitativo	18
2.5	Detecção Automática da CS	20
2.5.1	Atividade Elétrica no Cérebro	20
2.5.2	Movimento Ocular e Piscar dos Olhos	22
2.5.3	Frequência e Variabilidade da Frequência Cardíaca	23
2.5.4	Atividade Gástrica	24
2.5.5	Atividade Muscular	25
2.5.6	Condutividade da Pele	26
2.6	Inteligência Artificial	26
2.6.1	Aprendizado de Máquina	27
2.6.2	Classificadores Simbólicos	28
2.6.3	Aprendizado Profundo	30
2.6.4	Rede Neural Convolutacional	31
2.6.5	Redes Neurais Recorrentes	33
2.6.6	Inteligência Artificial Explicável	35

3	Trabalhos Relacionados	37
3.1	Detecção da CS por meio de Biosinais	37
3.1.1	Detectando a CS através de ECG	37
3.1.2	Detectando a CS através de EEG	38
3.2	Detecção e Previsão Automática da CS	40
3.2.1	Detecção da CyberSickness em RV baseada em Biosinais	40
3.2.2	Detecção Automática e Previsão usando DNN	41
3.3	IA Explicável na previsão de AVC usando EEG	42
3.4	Análise da CS com Algoritmos Simbólico de ML	43
4	Método e Experimentos	45
4.1	Softwares e Equipamentos	45
4.1.1	Realidade Virtual e HMD	45
4.1.2	Configurações de Hardware do Computador	46
4.1.3	Bitalino	47
4.1.4	Biosignal Collector	49
4.2	Aquisição dos Dados Qualitativos e Dados do Jogo	51
4.3	Biosinais	51
4.3.1	Eletrocardiograma	52
4.3.2	Atividade Eletrodérmica	53
4.3.3	Acelerômetro	54
4.4	Aquisição dos Biosinais	55
4.5	Participantes	56
4.5.1	Recrutamento	56
4.6	Procedimento Experimental	56
4.6.1	Antes da Sessão	56
4.6.2	Durante a Sessão	57
4.6.3	Após a Sessão	57
4.7	Dados Coletados	58
4.8	Pré-processamento de Dados	61
4.9	Análises de Dados	63
4.9.1	Pontuações do VRSQ	63
4.9.2	Análise dos Níveis de Desconforto dos Usuários	66
4.9.3	Alterações Fisiológicas (Repouso VS <i>Cybersickness</i>)	70
5	Identificação das Causas da CS	73
5.1	Abordagem de Referência	73
5.1.1	Pipeline Referencial	74

5.1.2	Conjunto de Dados	74
5.2	Abordagem Proposta	75
5.2.1	Avaliação dos Classificadores	76
5.2.2	Avaliação dos Atributos	81
5.2.3	Avaliação do Modelo	85
5.2.4	Identificação das Causas	91
5.3	Avaliação dos Resultados	94
5.3.1	Resultado da Identificação das Causas sem Biosinais	95
5.3.2	Resultado da Identificação das Causas com Biosinais	97
6	Conclusão	101
6.1	Considerações Finais	101
6.2	Limitações e Trabalhos Futuros	103
	Referências	105
	Apêndice	118
	A <i>Cybersickness Profile Questionnaire (CSPQ)</i>	119
	B <i>Virtual Reality Sickness Questionnaire (VRSQ)</i>	120
	C Termo de Consentimento Livre e Esclarecido	121

Lista de Figuras

1.1	Fluxo da Metodologia adotada neste trabalho.	4
2.1	RV imersiva usando Head-Mounted Display (HDM) [2].	8
2.2	RV não imersiva - computador com Sistema RV de Desktop [3].	8
2.3	Teoria clássica do Conflito Sensorial (MS) [4].	10
2.4	Comparação de bandas de ondas cerebrais EEG [5].	21
2.5	Movimentos oculares juntamente com as mudanças no potencial elétrico na região periocular. O símbolo 'S' indica a localização de um sensor utilizado para registrar o sinal de EOG, enquanto 'R' indica o local onde um eletrodo de referência é colocado [6].	22
2.6	Eletrodos cutâneos colocados no abdome do participante [7].	24
2.7	Eletrodos posicionados para registrar a atividade eletrodérmica [8].	27
2.8	Árvore de Decisão do Exemplo.	29
2.9	Relação entre Inteligência Artificial, Aprendizado de Máquina e Aprendizado Profundo [9].	30
2.10	A arquitetura geral da CNN (adaptado [10]).	31
2.11	RNN - os círculos denotam as camadas da rede, enquanto as linhas sólidas representam as conexões ponderadas. As setas indicam a direção da propagação direta [11].	34
4.1	Jogo de Corrida de Carro à esquerda (a) e de Voo à direita (b) ([12]).	45
4.2	HMD HTC Vive.	46
4.3	Placa e sensores BITalino.	48
4.4	Conexões dos sensores à Placa Bitalino: a) Sensor ECG ;b) Sensor EDA; c) Sensor ACC.	49
4.5	Arquitetura do BC.	50
4.6	Tela Principal do BC.	50
4.7	Exemplo de um ECG com Intervalo RR em destaque.	52
4.8	Exemplo EDA. Saída típica do sensor não filtrado (enquanto o usuário está em um estado relaxado). Adaptado [13].	53

4.9	Dados brutos típicos do ACC (Z) (adquiridos com o BITalino (r)evolution) realizando um burpee com flexão, começando e terminando em posição de pé, com o sensor colocado no peito[14].	55
4.10	a) Colocação dos Eletrodos (ECG) [15]; b) Fixação dos eletrodos EDA nos dedos da mão [13]; c) ACC localizado na fúrcula supraesternal do usuário.	55
4.11	Fluxo do Experimento.	57
4.12	Procedimento sobre como associar os intervalos RR às instâncias do experimento para um usuário específico.	62
4.13	Resultados das Pontuações VRSQ obtidas do Jogo de Carro.	65
4.14	Resultados das Pontuações VRSQ obtidas do Jogo de Voo.	65
4.15	Percentual de tempo que cada participante vivenciou com desconforto Leve, Moderado e Severo no Jogo de Carro.	66
4.16	Percentuais dos Níveis de Desconforto relatados pelos usuários para o Jogo de Carro, agrupados por Sexo.	67
4.17	Percentuais dos níveis de CS relatados durante o Jogo de Carro, incluindo aqueles sem sintomas.	68
4.18	Percentual de tempo que cada participante vivenciou com desconforto Leve, Moderado e Severo no Jogo de Voo.	69
4.19	Percentuais dos Níveis de Desconforto relatados pelos usuários, para o Jogo de Voo, agrupados por sexo.	69
4.20	Percentuais dos níveis de CS relatados durante o Jogo de Voo, incluindo aqueles sem sintomas.	70
4.21	Média e Desvio Padrão para o Jogo de Carro e Biosinal ACC.	71
4.22	Média e Desvio Padrão para o Jogo de Carro e Biosinal EDA.	71
4.23	Média e Desvio Padrão para o Jogo de Carro e Biosinal ECG.	71
4.24	Média e Desvio Padrão para o Jogo de Voo e Biosinal ACC.	72
4.25	Média e Desvio Padrão para o Jogo de Voo e Biosinal EDA.	72
4.26	Média e Desvio Padrão para o Jogo de Voo e Biosinal ECG.	72
5.1	Método Proposto por Porcino [12].	74
5.2	Método proposto neste trabalho.	77
5.3	Estrutura dos Datasets utilizados na avaliação dos classificadores e atributos.	80
5.4	Profundidade X Pontuação AUC (com os Biosinais).	86
5.5	Comparação dos melhores cenários em termos de pontuações AUC para os algoritmos <i>Decision Tree</i> (DT) e <i>Random Forest</i> (RF).	91

5.6	a) <i>Decision Tree</i> (DT) simples; o caminho de decisão é destacado em verde; b) neste exemplo, o algoritmo <i>Random Forest</i> (RF) selecionará a classe 1 como a previsão final devido à predominância das previsões para essa classe (em destaque nas cores azul e vermelha).	92
5.7	Valores de <i>Gini</i> para o caminho de decisão, para as instâncias: (1) [0, 60, 80, 81, 82, 95, 96] e (2) [0, 70, 90, 91, 92, 99, 100].	94
5.8	Principais atributos utilizados no processo de identificação da Cybersickness no Jogo de Carro, utilizando o algoritmo <i>Random Forest</i> (RF) e PDI, sem a inclusão dos Biosinais.	99
5.9	Principais atributos utilizados no processo de identificação da Cybersickness no Jogo de Voo, utilizando o algoritmo <i>Random Forest</i> (RF) e PDI, sem a inclusão dos Biosinais. .	99
5.10	Principais atributos utilizados no processo de identificação da Cybersickness no Jogo de Carro, utilizando o algoritmo <i>Random Forest</i> (RF) e PDI, com a inclusão dos Biosinais.	100
5.11	Principais atributos utilizados no processo de identificação da Cybersickness no Jogo de Voo, utilizando o algoritmo <i>Random Forest</i> (RF) e PDI, com a inclusão dos Biosinais. .	100

Lista de Tabelas

4.1	Especificações do Headset e Controlador.	47
4.2	Especificações do Computador.	47
4.3	Especificações do BITalino (r)evolution Plugged.	48
4.4	Experimentos realizados e características dos dados coletados.	58
4.5	Dados válidos coletados para Jogo de Carro, destinados as análises que incluem informações de autorrelatos e biosinais.	59
4.6	Dados válidos coletados para Jogo de Voo, destinados as análises que incluem informações de autorrelatos e biosinais.	59
4.7	Atributos dos dados coletados através dos jogos durante a imersão do usuário no experimento. Tipos: Numérico (N) e Categórico (C).	60
4.8	Estrutura dos biosinais coletados. Atributos Numérico (N) e Lista (L). . .	60
4.9	Atributos com os biosinais incluídos, coletados durante a imersão do usuário no experimento. Tipos: Numérico (N) e Categórico (C).	63
4.10	<i>Virtual Reality Sickness Questionnaire</i> (VRSQ).	64
4.11	VRSQ - Jogo de Carro.	64
4.12	VRSQ - Jogo de Voo.	64
4.13	Totais e percentuais dos níveis de CS relatados por gênero (Jogo de Carro). .	67
4.14	Percentuais dos níveis de CS relatados durante o Jogo de Carro, incluindo aqueles sem sintomas.	67
4.15	Totais dos níveis de CS relatados por gênero (Jogo de Voo).	68
4.16	Percentuais dos níveis de CS relatados durante o Jogo de Voo, incluindo aqueles sem sintomas.	69
4.17	Médias, desvios padrão e testes-t dos biosinais (ACC, EDA e ECG) durante o Jogo de Carro, em condições de linha de base e com sintomas de CS. . .	71
4.18	Médias, desvios padrão e testes-t dos biosinais (ACC, EDA e ECG) durante o Jogo de Voo, em condições de linha de base e com sintomas de CS. . . .	72
5.1	Fatores pesquisados por Porcino [12].	75
5.2	Classificação Multiclasse sem a Inclusão de Dados de Biosinais (Weka). . .	80
5.3	Classificação Multiclasse com a Inclusão de Dados de Biosinais (Weka). . .	81

5.4	Classificação Binária sem a Inclusão de Dados de Biosinais (Weka).	81
5.5	Classificação Binária com a Inclusão de Dados de Biosinais (Weka).	82
5.6	Avaliação dos Atributos (classificação multiclasse, sem biosinais).	83
5.7	Avaliação dos Atributos (classificação binária, sem biosinais).	83
5.8	Avaliação dos Atributos (classificação multiclasse, com biosinais).	84
5.9	Avaliação dos Atributos (classificação binária, com biosinais).	84
5.10	Conjunto de Atributos Selecionados (sem a inclusão dos biosinais).	85
5.11	Conjunto de Atributos Selecionados (com a inclusão dos biosinais).	85
5.12	AUC por usuário sem Biosinais (Jogo de Carro, Profundidade: 7).	87
5.13	AUC por usuário sem Biosinais (Jogo de Voo, Profundidade: 5).	87
5.14	AUC por usuário com EDA (Jogo de Carro, Profundidade: 7).	88
5.15	AUC por usuário com EDA (Jogo de Voo, Profundidade: 5).	88
5.16	AUC por usuário com ACC (Jogo de Carro, Profundidade: 7).	88
5.17	AUC por usuário com ACC (Jogo de Voo, Profundidade: 5).	88
5.18	AUC por usuário com ECG (Jogo de Carro, Profundidade: 7).	88
5.19	AUC por usuário com ECG (Jogo de Voo, Profundidade: 5).	88
5.20	AUC por usuário com ACC e EDA (Jogo de Carro, Profundidade: 7).	89
5.21	AUC por usuário com ACC e EDA (Jogo de Voo, Profundidade: 5).	89
5.22	AUC por usuário com ACC e ECG (Jogo de Carro, Profundidade: 7).	89
5.23	AUC por usuário com ACC e ECG (Jogo de Voo, Profundidade: 5).	89
5.24	AUC por usuário com EDA e ECG (Jogo de Carro, Profundidade: 7).	89
5.25	AUC por usuário com EDA e ECG (Jogo de Voo, Profundidade: 5).	89
5.26	AUC por usuário com ACC, EDA e ECG (Jogo de Carro, Profundidade: 7).	90
5.27	AUC por usuário com ACC, EDA e ECG (Jogo de Voo, Profundidade: 5).	90
5.28	AUC em ordem decrescente para o Jogo de Carro e Algoritmo DT.	90
5.29	AUC em ordem decrescente para o Jogo de Carro e Algoritmo RF.	90
5.30	AUC em ordem decrescente para o Jogo de Voo e Algoritmo DT.	90
5.31	AUC em ordem decrescente para o Jogo de Voo e Algoritmo RF.	90
5.32	Exemplo da Figura 5.7: Soma dos valores <i>Gini</i> , agrupados por atributo.	95
5.33	Exemplo da Figura 5.7: Resultado final da Equação 5.4, ranking dos atributos mais relevantes em ordem de importância.	95
5.34	Ranking das médias percentuais das principais características causadoras da CS, excluindo os biosinais. Nosso estudo emprega algoritmo RF com PDI, enquanto a abordagem de Porcino [12] utiliza RF com PCS.	96

5.35	Ranking das médias percentuais das principais características causadoras da CS, incluindo os biosinais que são indicativos dos sintomas dessa condição. O algoritmo RF com PDI adotado em nosso estudo, enquanto Porcino [12] emprega RF com PCS.	98
A.1	<i>Cybersickness Profile Questionnaire</i> (CSPQ) [12].	119
B.1	Versão em português do <i>Virtual Reality Sickness Questionnaire</i> (VRSQ) [1, 12].	120

Lista de Abreviaturas e Siglas

ACC *Accelerometer.*

ALE plots *Accumulated Local Effects.*

ANN *Artificial Neural Networks.*

AUC *Area under ROC curve.*

AVC *Acidente Vascular Cerebral.*

AVGNN *Average NN interval.*

BC *Biosignal Collector.*

BR *Breathing Rate.*

CAD *Computer-Aided Design.*

CNN *Convolutional Neural Networ.*

CS *Cybersickness.*

CSPQ *Cybersickness Profile Questionnaire.*

CSQ *CyberSickness Questionnaire.*

DL *Deep Learning.*

DNN *Deep Neural Network.*

DoF *Depth of field.*

DT *Decision Tree.*

ECG *Electrocardiogram.*

EDA *Electrodermal Activity.*

EEG *Electroencephalogram.*

EGG *Electrogastrography.*

EMD *Electromechanical Delay.*

EMG *Electromyography.*

EOG *Electrooculogram.*

FC *Frequência Cardíaca.*

FMS *Fast Motion Sickness Scale.*

FoV *Field of View.*

GSR *Galvanic Skin Response.*

HMD *Head-mounted Display.*

HR *Heart Rate.*

HRV *Heart Rate Variability.*

IA *Inteligência Artificial.*

ICE *Individual Conditional Expectation.*

JSON *JavaScript Object Notation.*

LIME *Local interpretable model-agnostic explanations.*

LSTM *Long Short-Term Memory.*

MEMS *Microelectromechanical Systems.*

ML *Machine Learning.*

MS *Motion Sickness.*

MSAQ *Motion Sickness Assessment Questionnaire.*

MSQ *Pensacola Motion Sickness Questionnaire.*

MSSQ *Motion Sickness Susceptibility Questionnaire.*

NLP *Natural Language Processing.*

NN *Neural Network.*

PCS *Potential-Cause Score.*

PDI *Potential Discomfort Indicator.*

PDP *Partial Dependence Plot.*

PI *Permutation Importance.*

RA *Realidade Aumentada.*

RF *Random Forest.*

RGP *Resposta Galvânica da Pele.*

RNN *Recurrent Neural Network.*

RR-I *RR interval.*

RV *Realidade Virtual.*

SDTNN *Standard Deviation of NN intervals.*

SHAP *SHapley Additive exPlanations.*

SS *Simulator Sickness.*

SSQ *Simulator Sickness Questionnaire.*

SVM *Support Vector Machine.*

VE *Virtual Environments.*

VFC *Variabilidade da Frequência Cardíaca.*

VIMS *Visually Induced Motion Sickness.*

VR *Virtual Reality.*

VRSQ *Virtual Reality Sickness Questionnaire.*

XAI *Explainable Artificial Intelligence.*

Capítulo 1

Introdução

Neste capítulo, são apresentados a motivação para a realização deste trabalho, seus objetivos, os procedimentos metodológicos utilizados e a organização geral do texto.

1.1 Motivação

Nos últimos anos, a Realidade Virtual (RV) tem se popularizado cada vez mais como uma tecnologia promissora, permitindo novas formas de interação entre seres humanos e computadores [16, 17]. Entretanto, a exposição prolongada a ambientes virtuais pode resultar no fenômeno chamado *Cybersickness* (CS) [16]. Os sintomas associados à CS podem variar de pessoa para pessoa e incluem: náusea, vertigem, fadiga ocular e dor de cabeça. A duração dos sintomas pode variar de alguns minutos a horas após a exposição à VR, dependendo do indivíduo.

A ocorrência de *Cybersickness* (CS) é uma preocupação crescente, especialmente quando consideramos que ela pode surgir como um efeito indesejado do uso de RV [18]. Essa condição pode afetar negativamente a experiência do usuário em RV, resultando em sintomas como náusea, tontura e mal-estar. De maneira geral, as pessoas tentam evitar ficar doentes e, se a experiência em Realidade Virtual causar náusea, então elas simplesmente param de usar a RV [16]. É crucial que os desenvolvedores de tecnologias de Realidade Virtual levem em consideração essa questão desde o estágio inicial de concepção e design, adotando medidas de precaução e cuidado para prevenir e tratar a CS.

Com o objetivo de compreender e abordar a CS de maneira eficaz, especialistas têm procurado medidas e estratégias para avaliar sua ocorrência e gravidade. Segundo LaViola et al. [16], as três principais teorias para as causas da CS são: (1) teoria do conflito sensorial, que se baseia na discrepância entre as informações sensoriais enviadas ao cérebro, em particular entre as informações visuais e as informações provenientes do sistema vestibular [4, 19]; (2) a teoria da instabilidade postural, descreve uma resposta fisiológica à incapacidade

dade de manter o controle postural corporal [20]; por último, (3) teoria do veneno, sugere que o enjoo em ambientes virtuais ocorre porque a estimulação adversa nesses ambientes pode afetar o sistema visual e vestibular do corpo, levando-o a interpretar erroneamente as informações e a sugerir que o organismo ingeriu uma substância tóxica, o que pode causar sintomas perturbadores [16].

Para Kennedy et al [21], a CS é um problema real que traz implicações médicas e de segurança. Isso sem dúvida dificulta a integração da RV em diversos campos nos quais poderia ser útil, tais como educação, entretenimento, engenharia e videogames. Embora a incidência de CS relatada entre os usuários de RV varie, estudos indicam que uma grande parcela da população, cerca de 40% a 60% podem apresentar sintomas moderados a graves de CS [22]. Mesmo que a maioria dos usuários se adapte ao ambiente após algumas sessões, cerca de 5% não conseguem se adaptar mesmo após várias imersões na Realidade Virtual (RV) [23].

A *Cybersickness* (CS) ocorre com frequência ao utilizar dispositivos como os *Head-mounted Display* (HMD). Os HMDs são dispositivos eletrônicos que se encaixam à cabeça do usuário, proporcionando uma experiência imersiva de exibição em que o conteúdo é exibido diretamente nos olhos. Os avanços recentes na tecnologia HMD podem aumentar a imersão e realismo, mas também podem influenciar a ocorrência do mal-estar na RV [24]. Apesar das melhorias na tecnologia, a prevalência da CS ainda é problemática. No trabalho de Kourtesis et al [25], os autores destacam a importância de levar em consideração os recursos de software, além dos de hardware, na redução da CS.

Apesar de existirem várias teorias sobre as possíveis causas da CS, não há um método fácil ou sistemático para medi-la e quantificá-la [26]. Para estudos nesta área, é comum que os pesquisadores empreguem medidas subjetivas para identificar a intensidade da CS. Ela pode ser medida por meio de questionários autorrelatados pré e pós-experiência, como o *Simulator Sickness Questionnaire* (SSQ), sendo atualmente o método mais popular utilizado para avaliar a CS [27].

O SSQ é composto por 16 questões agrupadas em três categorias, a saber: náusea, oculomotora e desorientação; as quais visam avaliar a gravidade de cada manifestação potencial de CS. As subpontuações obtidas em cada categoria são somadas para gerar uma pontuação total do SSQ, que indica o grau de gravidade da doença [27, 28]. De acordo com Kennedy et al [29], uma pontuação igual ou superior a 10 no SSQ é considerada significativa, enquanto uma pontuação superior a 20 pode indicar um mau *design* do ambiente de RV.

Entretanto, essas medidas subjetivas são frequentemente obtidas após a imersão em RV, o que não permite uma compreensão detalhada o suficiente da gravidade da CS durante o uso de RV. O estudo de Young et al [30], investigou se a realização de um SSQ

antes e depois de uma experiência virtual, poderia afetar a quantidade de sintomas de CS relatados. Os resultados indicam que os relatos de CS são muito maiores quando um SSQ pré e pós são aplicados do que quando apenas um SSQ pós-teste é usado. Isso destaca a importância de buscar métodos de medição mais objetivos, como biosinais.

Em estudos anteriores, foram empregadas diversas abordagens para mensurar a intensidade da CS, por meio da utilização de medidas subjetivas e objetivas [31, 32]. Segundo pesquisadores, a CS tem um impacto significativo sobre os sinais fisiológicos, incluindo onda delta do Eletroencefalograma (EEG), Frequência Cardíaca (FC), Variabilidade da Frequência Cardíaca (VFC), Resposta Galvânica da Pele (RGP) e Eletrogastrografia (EGG) [23, 33], os quais apresentam uma correlação significativa com essa condição. Além disso, estudos descritos na literatura, como os conduzidos Garcia-Agundez et al. [23], Qu et al. [34] e Islam et al. [35], empregaram biosinais na detecção ou previsão da CS, contudo, essas abordagens baseiam-se em modelos de Aprendizado de Máquina Profundo, os quais são de difícil compreensão e interpretação por humanos.

Este estudo fundamenta-se na pesquisa do Porcino [12], que aborda a classificação de possíveis causas de *Cybersickness* (CS) em jogos de Realidade Virtual utilizando *Machine Learning* (ML) Simbólico. A hipótese principal dessa pesquisa, na qual esta dissertação está fundamentada, é que os modelos simbólicos de ML possibilitam a interpretação compreensível e previsível dos resultados. O pesquisador investigou as causas de desconforto nas experiências de RV, resultando no desenvolvimento de estratégias para mitigar os sintomas da CS. Além disso, com intuito de compreender os fatores que impactam o surgimento dos sintomas associados à CS durante as experiências em Realidade Virtual (RV), a pesquisa conduziu uma seleção de atributos, levando à identificação dos elementos mais significativos associados ao surgimento dessa condição. No entanto, na pesquisa realizada pelo Porcino [12], não foram empregados biosinais, de forma que as avaliações basearam-se apenas nas medidas subjetivas e dados do jogo.

1.2 Objetivo

O objetivo deste trabalho é investigar a aplicação de biosinais para identificar as possíveis causas associadas à *Cybersickness* (CS) em jogos de Realidade Virtual (RV), buscando demonstrar a existência de uma correlação significativa entre a ocorrência de CS e os biosinais registrados. Neste contexto, nossa hipótese principal é que a combinação de avaliações quantitativas (dados de biosinais e do jogo) e subjetiva (dados dos questionários CSPQ), usando técnicas de Aprendizado de Máquina Simbólico, seja eficaz na identificação das causas da CS.

Para o treinamento e avaliação do modelo, foram empregados dados obtidos dos questionários *Cybersickness Profile Questionnaire* (CSPQ), juntamente com dados dos jogos e dos biosinais: Eletrocardiograma (ECG), Atividade Eletrodérmica (EDA) e Acelerômetro (ACC). Durante os experimentos, os participantes ficaram imersos em dois jogos de Realidade Virtual (RV), um de corrida de carros e outro de voo.

A clareza dos métodos simbólicos se revela atraente em situações que exigem transparência do modelo, como nesta pesquisa que busca identificar e compreender os elementos que influenciam a manifestação de sintomas associados à *Cybersickness* (CS) em jogos de RV. Assim, neste trabalho, será implementado um classificador de Aprendizado de Máquina Simbólico, baseado no trabalho do Porcino [12], com as devidas modificações para incorporar os biosinais obtidos em nossos experimentos. As contribuições específicas deste trabalho são:

- Realizar uma revisão abrangente da literatura sobre *Cybersickness* (CS);
- Analisar a eficácia dos modelos de Aprendizado de Máquina Simbólico empregados neste estudo na identificação das causas da CS, tanto sem a inclusão de biosinais quanto ao incorporá-los;
- Analisar a presença de uma correlação significativa entre os níveis de CS relatados pelos usuários e os biosinais registrados;
- Propor um conjunto de dados fisiológicos obtidos por meio de: ECG, EDA e ACC;
- Desenvolver uma ferramenta para aquisição de biosinais e autorrelatos dos níveis de CS dos usuários.

1.3 Metodologia

Para alcançar os objetivos previamente mencionados, conforme a Figura 1.1, esta pesquisa é dividida em cinco etapas.




Figura 1.1: Fluxo da Metodologia adotada neste trabalho.

1. A primeira etapa compreende uma revisão da literatura, destinada a explorar os conceitos essenciais envolvidos. Além disso, foram investigados os principais métodos de avaliação da *Cybersickness* (CS) e os sensores empregados na captura de

biosinais, com a finalidade de detecção da CS. Adicionalmente, os princípios fundamentais de Aprendizado de Máquina (*Machine Learning* (ML)) e Aprendizagem Profunda (*Deep Learning* (DL)) são elucidados, englobando Rede Neural Convolutiva (*Convolutional Neural Network* (CNN)), Rede Neural Recorrente (*Recurrent Neural Network* (RNN)), Inteligência Artificial Explicável (*Explainable Artificial Intelligence* (XAI)) e Classificadores Simbólicos.

2. A segunda etapa metodológica envolve uma pesquisa abrangente de estudos anteriores que utilizaram biosinais e Inteligência Artificial (IA) para identificar e analisar a CS em ambientes virtuais. Os tópicos abordados compreendem também a detecção e previsão automatizada da CS, a aplicação da IA Explicável e, por último, a análise da CS com o uso de algoritmos simbólicos de ML.
3. Na terceira etapa deste trabalho, foi realizado o desenvolvimento da ferramenta *Biosignal Collector* (BC), com o objetivo de melhorar o controle na aquisição dos sinais fisiológicos e possibilitar que os participantes dos experimentos relatassem os níveis de *Cybersickness* (CS) que vivenciaram. Além disso, foram conduzidos experimentos, visando adquirir dados do perfil do usuário (através do questionário CSPQ), VRSQ-Pré e VRSQ-Pós, do jogo e também dos biosinais: ECG, EDA e ACC. Durante esses experimentos, os participantes ficaram imersos em dois jogos de realidade virtual: um jogo de corrida de carro e outro jogo de voo. Ainda nesta etapa, foram realizadas as análises preliminares dos experimentos realizados.
4. Na quarta etapa, foi introduzido o método base para este trabalho, conforme proposto pelo Porcino [12]. Essa introdução é fundamental para a compreensão das adaptações necessárias para a incorporação dos biosinais. Durante esta fase, foram realizadas modificações no método original, que envolveram a incorporação de biosinais nos experimentos e nas análises. Além disso, foram realizadas avaliações de classificadores simbólicos com base em árvores de decisão, juntamente com a avaliação dos atributos que desempenham um papel na decisão preliminar sobre a *Cybersickness* (CS).
5. Por fim, na quinta e última fase, os resultados alcançados passaram por uma análise detalhada, com o objetivo de avaliar o desempenho do modelo de Aprendizado de Máquina Simbólico na detecção e classificação das causas da CS, ao incluir os biosinais coletados durante os experimentos. Além disso, foi verificada a existência de uma correlação significativa entre os níveis de CS relatados pelos participantes e os dados fisiológicos registrados.

1.4 Organização do Texto

Além deste capítulo introdutório, este trabalho é composto por mais cinco capítulos, cada um desempenhando um papel fundamental na exposição e análise dos conceitos, da abordagem proposta, dos argumentos e das evidências que constituem esta pesquisa.

- **Capítulo 2:** Neste capítulo, é feita uma introdução à Realidade Virtual, abordando conceitos e princípios relacionados a *Motion Sickness* (MS), *Visually Induced Motion Sickness* (VIMS) e *Cybersickness* (CS). Além disso, são apresentados os dois principais métodos de avaliação utilizados na CS, bem como os principais biosinais utilizados em estudos relacionados à CS. O capítulo também aborda conceitos básicos de *Machine Learning* (ML), *Deep Learning* (DL), *Convolutional Neural Network* (CNN), *Recurrent Neural Network* (RNN) e Classificadores Simbólicos, além das estratégias para mitigar a *Cybersickness* (CS).
- **Capítulo 3:** Apresenta uma revisão da literatura que explora o uso de biosinais para detecção e análise da ocorrência de *Cybersickness* (CS) em ambientes virtuais. Cada seção resume os principais pontos das pesquisas analisadas. Os tópicos abordados incluem: detecção da CS por meio de biosinais, detecção e previsão automática da CS usando técnicas de ML, IA Explicável com EEG e análise da CS com algoritmos simbólico de *Machine Learning* (ML).
- **Capítulo 4:** É apresentada a ferramenta desenvolvida neste estudo para aquisição de biosinais, juntamente com informações sobre os jogos utilizados, os equipamentos e suas configurações, os métodos de coleta de dados qualitativos e quantitativos, bem como os procedimentos para a realização dos experimentos. Por fim, ainda neste capítulo, são apresentadas as análises dos dados coletados.
- **Capítulo 5:** Contextualiza o método base proposto por Porcino [12], com uma apresentação minuciosa de seu aprimoramento, o qual é essencial para a incorporação dos biosinais. Além disso, são apresentadas as avaliações de classificadores simbólicos, com ênfase em algoritmos baseados em árvores de decisão, e a análise dos atributos que desempenharam um papel fundamental na identificação das causas *Cybersickness* (CS). Por fim, também detalhamos o procedimento empregado para identificar as causas da CS, assim como os resultados alcançados nesta pesquisa.
- **Capítulo 6:** Aborda as considerações finais, destacando suas principais contribuições e limitações, além de identificar possíveis direções para trabalhos futuros.

Capítulo 2

Fundamentação

Neste capítulo, serão apresentados os princípios que orientaram e fundamentaram a elaboração desta pesquisa, com a explanação dos principais conceitos envolvidos no desenvolvimento desse projeto.

2.1 Realidade Virtual

A Realidade Virtual (RV) é uma tecnologia que tem o poder de transformar nossa maneira de interagir com o mundo digital e físico. Segundo LaValle [36], a RV é a indução de comportamento direcionado de um indivíduo por meio de estimulação sensorial artificial, mesmo quando o indivíduo possui uma percepção limitada ou nula da interferência. Ela possibilita aos usuários, mergulharem em um ambiente computacional simulado, utilizando dispositivos eletrônicos, como óculos de Realidade Virtual, capacetes, luvas ou outros dispositivos de interface.

Segundo Jerald [37], a RV é um "ambiente digital gerado computacionalmente que pode ser experimentado e interagido como se esse ambiente fosse real". A RV também pode ser considerada um oxímoro, como apontado por alguns estudiosos, pois representa uma "realidade que não existe"[38]. Esta tecnologia possibilita uma experiência imersiva sensorial e perceptiva, na qual os usuários podem interagir e explorar um ambiente virtual tridimensional em tempo real. Pode ser aplicada em diversas áreas, como: jogos, simulações, terapia, educação, treinamentos, entretenimento, entre outros. Um sistema de RV é composto pela combinação de hardware e software, que permite aos desenvolvedores criar aplicativos de RV [37].

A sensação de presença na RV, é uma característica fundamental que permite aos usuários se envolverem de forma profunda e realista com ambientes virtuais, criando uma experiência imersiva [38]. É a sensação de estar presente no mundo virtual como se fosse real, mesmo sendo uma experiência simulada. Por exemplo, o uso de um headset de RV

permite ao usuário ver imagens em 3D ao redor, ouvir sons direcionais e interagir com objetos virtuais usando controles ou gestos, contribuindo para a sensação de presença.

Outro aspecto relevante, está relacionado à possibilidade da Realidade Virtual ser imersiva ou não imersiva, com base na característica importante da imersão e nos tipos de interfaces ou componentes utilizados no sistema [38]. O sistema RV não imersivo, também chamado de sistema Desktop RV, conforme a Figura 2.2, é o menos imersivo e o mais barato, pois requer componentes menos sofisticados. A bola espacial, teclado e as luvas de dados, são dispositivos de entrada frequentemente utilizados em sistemas de realidade virtual não imersiva [39]. Esses componentes são amplamente aplicados em áreas como modelagem e sistemas CAD, permitindo aos usuários criar e interagir com objetos virtuais em ambientes tridimensionais.

Em contraste, o sistema de RV imersivo, conforme a Figura 2.1, é geralmente mais caro mas proporciona o mais alto nível de envolvimento e imersão para os usuários [38]. Seus componentes incluem *Head-mounted Display* (HMD), ou óculos de RV, dispositivos de rastreamento, luvas de dados e outros dispositivos que envolvem o usuário em animações 3D geradas por computador, criando uma sensação de fazer parte do ambiente virtual. Quando o usuário é totalmente imerso em um mundo virtual por meio de dispositivos multisensoriais, como HMDs e salas de multiprojeção, a realidade virtual é denominada "imersiva" [40]. Ela possui aplicações em diversos setores, como: jogos, educação, simulação, turismo e arquitetura.



Figura 2.1: RV imersiva usando Head-Mounted Display (HMD) [2].



Figura 2.2: RV não imersiva - computador com Sistema RV de Desktop [3].

Nos últimos anos, a tecnologia de Realidade Virtual tem se tornado cada vez mais popular, impulsionada pelo constante desenvolvimento dos HMDs [32]. Dispositivos de visualização usados na RV que são colocados na cabeça do usuário, semelhante a óculos ou capacetes, para oferecer uma experiência imersiva. A popularização desses dispositivos, tem sido um marco significativo na história da RV. Até o lançamento do Oculus Rift em

2013 [41], a tecnologia de RV era amplamente utilizada em aplicações comerciais e de pesquisa, mas ainda era relativamente cara e inacessível para o consumidor médio. Ao longo dos anos seguintes, uma série de concorrentes lançou seus próprios HMDs, tornando essa nova tecnologia acessível ao público em geral.

Este estudo faz uso dos conceitos de Realidade Virtual (RV) imersiva, explorando especificamente a análise e resolução de problemas relacionados à CS. Em outras palavras, os sintomas investigados estão exclusivamente ligados à manifestação de desconforto em ambientes de RV com o uso de dispositivos HMDs.

2.2 Motion Sickness, VIMS e Cybersickness

Amplamente conhecida como *Motion Sickness* (MS) ou "enjoo de movimento", é uma condição em que uma pessoa experimenta sintomas desagradáveis quando exposta a movimentos constantes e repetitivos, como qualquer sensação de mal-estar que ocorre devido a um movimento provocativo, que pode ser produzido por viagens de barco, aviões e carros [42, 4], e até mesmo brinquedos de parques de diversões. Esses sintomas podem variar de leves a graves, tais como: náusea, vômitos, tontura, palidez, sudorese e sensação geral de mal-estar.

O termo "doença (sickness)", geralmente implica em estar afligido por uma condição patológica ou enfermidade. Portanto, segundo Johnson et al [43], o uso da palavra "doença" em relação ao MS é inadequado. MS não é uma doença ou enfermidade, mas sim uma resposta normal do organismo de um indivíduo saudável, sem distúrbios orgânicos ou funcionais, quando exposto por um período de tempo suficiente a um movimento desconhecido de gravidade significativa. Segundo Gianaros et al [44], os sintomas de MS podem ser categorizados em quatro dimensões distintas: gastrointestinais (consciência do estômago, náusea, vômito), central (desmaio, tontura, visão turva, desorientação, tontura, sensação de girar), periférico (suor, sensação de calor) e sonolência/apatia (aborrecimento, sonolência, cansaço, mal-estar). Conforme essa classificação, as pessoas podem vivenciar níveis variados de sintomas em cada uma dessas dimensões.

De acordo com Reason et al[4], conforme a Figura 2.3, geralmente a MS ocorre quando há conflitos entre sinais sensoriais, como aqueles relacionados a acelerações percebidas pelo sistema visual (vis), como o movimento percebido pelos olhos; somatossensorial (som), percepção de mudanças no equilíbrio e na posição do corpo; vestibular (vest), relacionados ao equilíbrio; auditivo (aud), relacionadas ao som e ruído; e experiencial (exp), que envolve as expectativas e memórias anteriores. Essa discordância entre os diferentes sinais sensoriais é uma das principais teorias que explicam a ocorrência do MS, sendo a explicação mais amplamente aceita e citada pelos pesquisadores.

Essa teoria postula que o MS é resultado do conflito entre os sinais sensoriais, que normalmente transmitem informações consistentes, como os sinais visuais e vestibulares [4]. Quando há uma discrepância entre as informações visuais, que indicam que o corpo está em movimento, e os sinais vestibulares, que indicam que o corpo está em repouso, ocorre um conflito sensorial, desencadeando os sintomas da MS [42].




Figura 2.3: Teoria clássica do Conflito Sensorial (MS) [4].

A compreensão da suscetibilidade individual ao MS, é um aspecto importante para entender e gerenciar esse distúrbio. Nesse contexto, o Questionário de Susceptibilidade a MS de Reason et al [4] *Motion Sickness Susceptibility Questionnaire* (MSSQ), é amplamente reconhecido e utilizado como uma ferramenta confiável para avaliar a suscetibilidade à MS. Além do *Pensacola Motion Sickness Questionnaire* (MSQ) [45], poucos questionários têm a mesma validação de pesquisa que o MSSQ. Embora haja vários questionários relatados na literatura, ele continua sendo amplamente reconhecido como uma referência nos estudos em MS.

Com o crescente avanço das tecnologias de realidade virtual e outras tecnologias digitais imersivas, a preocupação com os efeitos colaterais, como o MS, tem se tornado cada vez mais relevante. Um tipo específico de Motion Sickness relacionado a estímulos visuais é conhecido *Visually Induced Motion Sickness* (VIMS), o qual ocorre em resposta a estímulos visuais gerados por dispositivos de RV, simulações virtuais, jogos de vídeo-game ou outras tecnologias digitais [46, 47].

A sensação de VIMS é composta por componentes psicológicos e fisiológicos, sendo muitas das vezes, difíceis de quantificar objetivamente, como por exemplo: náusea, desorientação, fadiga, e fadiga ocular[48]. Atualmente, há uma carência de métodos confiáveis

e objetivos para prever e mensurar o início e a gravidade do VIMS. A maioria dos estudos ainda se baseia principalmente em escalas subjetivas de avaliação, como o *Simulator Sickness Questionnaire* (SSQ) de Kennedy et al[27]. A busca por estratégias eficazes de prevenção e mitigação dos sintomas do VIMS, pode contribuir significativamente para proporcionar uma experiência mais confortável e segura aos usuários de dispositivos de realidade virtual e outras tecnologias digitais imersivas.

O *Visually Induced Motion Sickness* (VIMS) e a *Cybersickness* (CS), são termos que descrevem o desconforto visualmente induzido, geralmente experimentado durante ou após a exposição a Ambientes Virtuais ou estímulos visuais. No entanto, possuem origens e contextos distintos. O VIMS é um termo mais abrangente, referindo-se não apenas a ambientes de RV, mas também a jogos de vídeo-game, filmes 3D e outras tecnologias digitais que proporcionam estímulos visuais. A *Cybersickness*, por outro lado, é uma subcategoria do VIMS.

A ocorrência de CS é uma questão preocupante, que pode surgir como um efeito indesejado do uso de ambientes virtuais (*Virtual Environments* (VE)), demandando cuidados e precauções adequadas [18]. A CS é uma condição que pode ocorrer durante ou após a exposição a VE, como realidade virtual, realidade aumentada ou simuladores virtuais. É caracterizada por sintomas semelhantes aos do MS [18], os quais LaViola [16] descreve os principais: tensão ocular (sensação de desconforto nos olhos), dor de cabeça, palidez (perda de cor na pele), suor, boca seca, sensação de estômago cheio, desorientação (confusão ou perda de orientação no espaço ou no tempo), vertigem (tontura ou instabilidade), ataxia (dificuldade de coordenação motora ou movimentos desajeitados), náusea (sensação de desconforto no estômago as vezes acompanhada de uma vontade de vomitar) e vômito.

Apesar do MS e CS compartilharem os mesmos sintomas, eles não são necessariamente a mesma condição. No caso do MS, a estimulação vestibular pode ser suficiente para desencadear os sintomas, embora a visão também possa contribuir. Já no CS, a condição pode ser desencadeada exclusivamente por estímulos visuais e vestibulares [49, 16]. Em suma, *Cybersickness* (CS) é um tipo de desconforto sensorial que ocorre em ambientes virtuais ou de Realidade Aumentada (RA), embora seja menos comum na RA. O *Motion Sickness* (MS) é um tipo de desconforto sensorial que acontece em resposta a movimentos reais do corpo. Por outro lado, o *Visually Induced Motion Sickness* (VIMS) é uma forma específica de MS que ocorre em resposta a estímulos visuais em ambientes onde não há movimento real do corpo. Todas essas condições envolvem discrepâncias sensoriais, mas têm causas e contextos distintos.

2.3 Abordagens da Cybersickness

A *Cybersickness* (CS) pode trazer diversas implicações e efeitos colaterais, sendo um dos principais riscos o desenvolvimento de sintomas posteriores que podem durar várias horas [16]. Um caso extremamente raro e preocupante foi relatado, no qual um piloto experimentou a inversão de sua percepção visual em 180 graus, enquanto dirigia um carro, várias horas depois de interagir em VE. Esse exemplo ilustra a gravidade dos efeitos que a CS pode ter no corpo humano [50].

2.3.1 Teorias da CS

De acordo com LaViola [16], dentre as causas da cybersickness, três teorias principais se destacam: a Teoria do Conflito Sensorial, a Teoria do Veneno e a Teoria da Instabilidade Postural. Embora ainda haja muito a ser descoberto sobre as causas específicas da CS, a compreensão dessas teorias pode ajudar a prevenir e tratar seus sintomas.

Teoria do Conflito Sensorial

A Teoria do Conflito Sensorial, é uma das principais teorias relacionadas à *Cybersickness* (CS). Ela sugere que a CS é causada por uma incompatibilidade entre os sistemas sensoriais envolvidos na percepção do movimento [51], ou seja quando a informação sensorial não é o estímulo que o sujeito esperava com base em sua experiência física. Por exemplo, quando a visão sugere que a pessoa está em movimento, mas o equilíbrio do corpo indica que ela está parada, ocorre um conflito sensorial que pode gerar uma sobrecarga sensorial, desencadeando sintomas como desconforto, náusea e tontura. É a mais antiga e mais aceita das teorias relacionadas ao enjôo e a *Cybersickness* [4].

Existem limitações na capacidade de prever a ocorrência e gravidade da CS em determinadas situações, além de outros fatores associados ao mal-estar que não são considerados. A teoria do conflito sensorial carece de poder preditivo para determinar a gravidade dos sintomas CS em relação a qualquer experiência virtual. Explicar por que alguns indivíduos são mais suscetíveis à CS do que outros, apesar de receberem estímulos semelhantes, também é um desafio [16]. No entanto, a Teoria do Conflito Sensorial é amplamente reconhecida como uma das causas da *Cybersickness*.

A Teoria do Veneno

A estimulação adversa em certos ambientes virtuais pode confundir o sistema visual e vestibular, fazendo com que o corpo interprete erroneamente as informações e sinta como se tivesse ingerido uma substância tóxica, levando a sintomas perturbadores que podem

resultar em náusea e vômito [16]. Essa resposta é explicada pela Teoria do Veneno, que propõe que a CS é causada por uma resposta emética do corpo a estímulos visuais ou vestibulares conflitantes. Ela tenta fornecer uma explicação de por que o enjôo e a *Cybersickness* (CS) ocorrem de um ponto de vista evolutivo [52].

A Teoria do Veneno apresenta uma hipótese intrigante para explicar a ocorrência da CS e existem algumas pesquisas que corroboram essa teoria [52]. Entretanto, esta teoria não possui poder preditivo e não é capaz de explicar por que algumas pessoas que estão em ambientes virtuais não apresentam a resposta emética. Ainda há muito a ser descoberto sobre a CS e os mecanismos subjacentes que a causam. Infelizmente, é difícil determinar se essa teoria é válida.

A Teoria da Instabilidade Postural

A Teoria da Instabilidade Postural procura explicar a *Cybersickness* (CS) por meio de mudanças no controle postural do indivíduo. Nessa perspectiva, segundo Riccio et al. [20], a estabilidade postural é definida como o estado em que os movimentos descontrolados dos sistemas de percepção e ação são minimizados. Para LaViola [16], a estabilidade do equilíbrio corporal é influenciada pelas características do ambiente em que se encontra. Se houver mudanças abruptas ou significativas no ambiente, o controle postural pode ser perdido, especialmente se as estratégias de controle não estiverem disponíveis por falta de experiência. Tomando como exemplo caminhar sobre diferentes superfícies como grama e areia, é comum que as pessoas adotem diferentes formas de andar em cada uma delas, e se alguém tentar andar na areia da mesma maneira que na grama, é provável que perca o equilíbrio e caia.

A questão agora é como a teoria da instabilidade postural se aplica à CS. De acordo com Riccio et al. [20], são várias as situações ambientais que ocorrem e que podem induzir a instabilidade postural. Existem quatro categorias distintas que incluem: vibração de baixa frequência, ausência de peso, variações nas relações entre o vetor de força gravito-inercial e a superfície de suporte, juntamente com a especificidade alterada. A *Cybersickness* (CS) está incluída na categoria de especificidade alterada [16]. Devido à presença de acelerações e movimentos rotacionais que são percebidos visualmente, mas que não são causados pelo movimento real do corpo do indivíduo em muitos *Virtual Environments* (VE), as estratégias para controle postural visando estabilidade não surtirão efeito. Por exemplo, um sujeito pode alterar a posição dos pés para se estabilizar em resposta a uma sensação de movimento visual. Como não há movimento físico, o sujeito cria uma discrepância não intencional de uma posição estável, causando instabilidade postural.

2.3.2 Fatores que contribuem para a CS

Existem vários outros fatores que influenciam o surgimento da CS, e que não estão diretamente relacionados a nenhuma das três teorias discutidas na seção anterior.

Fatores Individuais

Gênero: Segundo Koohestani et al. [53], a questão de gênero é um fator que influencia a susceptibilidade à *Cybersickness* (CS). De acordo com estudos, as mulheres são mais propensas a apresentar sintomas de CS do que os homens, já que elas não possuem a mesma percepção espacial [54]. Uma das explicações para isso é que as mulheres costumam ter campos de visão mais amplos que os homens. Um campo de visão mais amplo aumenta a chance de percepção de Flicker [22, 16].

Idade: Reason et al. [4] afirmam que idade é um fator significativo a ser considerado. Segundo Lawther et al [55], a susceptibilidade ao MS é mais alta em indivíduos com menos de 15 anos e diminui à medida que a idade aumenta. Para LaViola Jr [16], as crianças com faixa etária dos 2 aos 12 anos, são mais propensas a CS, com queda rápida entre os 12 e 21 anos e redução mais gradual a partir daí. Ademais, conforme o estudo, a partir dos 50 anos de idade, a ocorrência de *Cybersickness* (CS) é praticamente nula. Também há estudos contraditórios [56].

Condição de Saúde: A condição de saúde pode aumentar a suscetibilidade à CS/MS quando os indivíduos são expostos ao ambiente virtual. Qualquer sensação, como dor de estômago, náusea, infecção no ouvido, ressaca, estresse, dor de cabeça, fadiga, falta de sono ou doenças respiratórias pode levar a uma MS [50, 53].

Ativação Individual: A importância da ativação individual em ambiente virtual é importante pelo fato de que participantes que assumem papéis ativos, como dirigir ou jogar, tendem a sofrer menos com CS em comparação com jogadores passivos [57]. Esse resultado pode ser atribuído à expectativa de que os pilotos ou jogadores ativos sejam capazes de antecipar seu próprio desempenho [53]. Conforme observado por Lackner [57], os usuários que controlam ativamente a simulação são menos suscetíveis aos sintomas do que os participantes passivos.

Posição no Simulador: A posição do usuário em ambientes virtuais (VE) desempenha um papel na suscetibilidade de CS. Em geral, ao fazer uso de VE, as pessoas ficam sentadas ou em pé. De acordo com a teoria da instabilidade postural, a posição sentada é mais eficaz na redução dos sintomas de CS, devido à diminuição dos requisitos de controle postural [16]. Além disso, a posição do usuário pode aumentar a suscetibilidade à CS em simulações de VE com múltiplos participantes.

Experiência de Jogo: A experiência de jogo pode influenciar a suscetibilidade à *Cybersickness* (CS). Segundo Kemeny [51], pessoas com menos experiência em informática, tecnologia e jogos podem ser mais propensas a sentir CS. Isso pode levar a um maior nível de estresse durante uma tarefa, o que pode aumentar a probabilidade de sentir cybersickness. Jogadores experientes, por outro lado, têm maior probabilidade de se adaptarem a ambientes virtuais e, portanto, são menos propensos a sentirem náuseas, tontura e outros sintomas de CS.

Tempo de Exposição: O tempo que um indivíduo passa em um ambiente virtual pode influenciar a probabilidade de experimentar sintomas de CS. No estudo de Porcino [12], o tempo de exposição foi identificado como a causa mais comum de desconforto.

Causas Geradas por Software

Flicker: O flicker em estímulos visuais, pode causar fadiga ocular [16] e sintomas de CS [53]. Sua percepção varia entre indivíduos e é mais perceptível na visão periférica. A RV busca cercar todo o campo de visão do usuário, o que pode aumentar a suscetibilidade ao flicker. Para evitá-lo, é necessário aumentar a taxa de atualização do sistema, especialmente na periferia [16]. Com o avanço da tecnologia, exibições visuais com alta taxa de atualização devem se tornar mais acessíveis.

Lag: Quando um usuário está imerso em um Realidade Virtual (RV), ele pode mover sua cabeça para olhar em torno do ambiente virtual. Esses movimentos da cabeça são capturados por um rastreador de cabeça e as informações são enviadas para o computador. O computador, então, processa essas informações e atualiza a exibição visual para o usuário. No entanto, a demora que pode ocorrer entre essas etapas, também conhecida como "lag", pode ser especialmente problemática em situações que exigem movimentos rápidos, como observar um objeto em movimento. Esse atraso pode não apenas atrapalhar a experiência do usuário, mas também desencadear sintomas de *Cybersickness*, tais como enjoo, tontura e desorientação [16].

Locomoção: Aplicativos de RV que buscam uma experiência realista, exigem que os controles de locomoção sejam naturais e intuitivos para o usuário. Para isso, geralmente são utilizados sistemas de rastreamento que mapeiam os movimentos do usuário no mundo real para o ambiente virtual [58]. Contudo, quando o usuário é submetido à estimulação contínua do movimento visual, mesmo durante o repouso (conhecida como *vecção*), isso pode resultar em sensações desconfortáveis [12].

Aceleração: O sistema vestibular, responsável pelo equilíbrio e orientação, demonstrou ser particularmente sensível às variações na velocidade. Quando o sistema vestibular detecta discrepâncias entre os movimentos percebidos pelo corpo e aqueles apresentados aos olhos, isso pode desencadear sintomas de CS. Estudos [59, 60] demonstraram que

exibições com alta frequência de aceleração e desaceleração tendem a induzir sintomas mais acentuados de CS, quando comparadas a apresentações que mantêm um movimento de aceleração constante.

Imprecisão na Detecção da Posição: A capacidade de rastrear a posição da cabeça e demais membros do usuário, é fundamental para a tecnologia de ambientes virtuais, de modo que uma representação precisa do usuário possa ser feita no espaço virtual. No entanto, o rastreamento da posição não é absoluta e pode variar, afetando a possibilidade de desencadear sintomas da CS. Considerando, por exemplo, um rastreador fixado na cabeça do usuário, se este for utilizado para atualizar a visão do usuário, a imagem exibida pode apresentar movimentos constantes e incontroláveis, mesmo quando o usuário mantém a cabeça e o corpo imóveis [16]. Esses problemas podem resultar em sintomas de tontura e falta de concentração [61].

Campo de Visão: O campo de visão (*Field of View* (FoV)) desempenha um papel importante na imersão em ambientes de Realidade Virtual (RV). Um FoV mais amplo, permite que o usuário veja mais do ambiente virtual, contribuindo para uma sensação de maior realismo e envolvimento. Por outro lado, um FoV expandido também pode aumentar a sensação de desconforto. Para mitigar esse efeito, alguns sistemas de RV restringem o FoV, o que pode afetar negativamente a experiência do usuário [62].

Profundidade de Campo: A profundidade de campo (*Depth of field* (DoF)) em RV, é uma técnica eficaz para direcionar a atenção do usuário para objetos específicos em Ambientes Virtuais. Estudos indicaram que a aplicação de efeitos de desfoque de profundidade contribui para a fusão de conteúdo estereoscópico, reduzindo a fadiga visual e desconforto [63, 64].

Quadros de Descanso: O conceito de quadros de descanso se fundamenta na constatação de que os seres humanos possuem uma notável sensibilidade em relação a objetos que permanecem imóveis [65]. No contexto da CS, quando houver dificuldade em selecionar um quadro de repouso consistente, as pessoas têm uma maior suscetibilidade de experimentar CS, porque recebem informações conflitantes sobre o que permanece imóvel no ambiente virtual e o que não permanece [16].

Rotação da Câmera: A inclusão de rotações em ambientes virtuais utilizando dispositivos de Realidade Virtual (RV) com HMDs, pode aumentar a probabilidade de conflitos sensoriais [66]. No estudo conduzido por Bonato [67], observou-se que a utilização de dois eixos em rotações resulta em uma percepção de rotação mais intensa, em comparação com a utilização de apenas um eixo.

2.4 Métodos de Avaliação em Cybersickness

A estimativa da CS, tem despertado interesse crescente em pesquisa nos setores acadêmico e industrial [34]. Para entender e abordar de forma eficaz a CS, os pesquisadores têm buscado medidas e estratégias para avaliar sua ocorrência e gravidade. Uma maneira de classificar as medidas é dividindo-as em duas categorias: (a) qualitativa, por meio da coleta de feedback subjetivo; e (b) quantitativa, através de sinais fisiológicos, durante ou logo após a exposição dos usuários a um ambiente digital imersivo [28].

2.4.1 Método Qualitativo

A coleta de feedback subjetivo é realizada por meio de questionários, como o *Simulator Sickness Questionnaire* (SSQ), sendo uma das ferramentas utilizada pelos pesquisadores para avaliar os sintomas da CS [27]. A interpretação subjetiva das respostas dos participantes pode ser desafiadora, uma vez que os sintomas podem variar em intensidade e podem ser influenciados por fatores como a suscetibilidade individual e a duração da exposição à simulação.

Segundo Kennedy et al [27], a maioria dos estudos de *Simulator Sickness* (SS), utilizavam o *Pensacola Motion Sickness Questionnaire* (MSQ) ou alguma de suas variantes para avaliar a gravidade dos sintomas. O MSQ apresentava várias deficiências nas medições de SS, além de alguns sintomas incluídos na pontuação de MS serem irrelevantes para o SS. Diante disso, Kennedy et al [27] desenvolveu o *Simulator Sickness Questionnaire* (SSQ), derivado do MSQ, usando uma série de análises fatoriais, e ilustra seu uso no monitoramento de desempenho com dados de uma pesquisa SSQ computadorizada.

Além do MSQ, o questionário *Potential Discomfort Indicator* (PDI) é um dos questionários mais utilizados para avaliação de MS [44]. Uma limitação desse índice é a pontuação única que depende da magnitude composta dos sintomas: náusea, tontura, dor de cabeça, calor, sudorese e sonolência. Segundo Gianaros et al. [44], a MS pode ser quantificada como uma síndrome multidimensional, não apenas como um sintoma isolado. Análises fatoriais exploratórias e confirmatórias foram usadas para derivar e verificar quatro dimensões da MS: gastrointestinais, centrais, periféricas e relacionadas ao sono. Essas dimensões foram utilizadas para construir o MSAQ, um questionário de avaliação administrado a indivíduos expostos a um tambor optocinético rotativo.

No estudo conduzido por Kim et al. [1], foi proposto o questionário denominado *Virtual Reality Sickness Questionnaire* (VRSQ), com base no questionário SSQ, tradicional e amplamente utilizado. O SSQ foi modificado para atender aos critérios específicos do ambiente de RV. O SSQ original era composto por 16 itens, divididos em três componentes: náusea, oculomotor e desorientação. No entanto, o novo questionário chamado de *Virtual*

Reality Sickness Questionnaire (VRSQ), é composto por apenas 9 itens, divididos em dois componentes: oculomotor e desorientação. De acordo com Sevinc et al. [68], o *CyberSickness Questionnaire* (CSQ) [69] e o VRSQ têm as melhores qualidades para avaliar o *Cybersickness* (CS) em aplicativos de RV baseados em *Head-mounted Display* (HMD), além de fornecer uma abordagem completa para medir seus sintomas e calcular seu aspecto subjetivo.

Os questionários apresentam limitações, uma vez que não podem ser administrados durante a experiência do usuário, o que dificulta a análise das sequências cronológicas dos estímulos apresentados. Keshavarz & Hecht [70] propuseram a adoção de uma escala de 20 pontos para avaliações verbais da *Motion Sickness* (MS). O *Fast Motion Sickness Scale* (FMS), é uma escala única de autoavaliação verbal, variando de zero (sem enjoo) a 20 (enjoo intensos). As respostas no FMS podem ser registradas durante a experiência do usuário, em intervalos regulares. No estudo (Keshavarz, 2011 [70]), o FMS foi aplicado a cada minuto e comparado com as pontuações do SSQ, revelando uma correlação significativa entre os dois métodos. Vários estudos incorporaram o uso do FMS [31, 71, 72].

No estudo conduzido pelo Porcino [12], foi introduzido o questionário *Cybersickness Profile Questionnaire* (CSPQ), contendo 9 questões relacionadas ao perfil do usuário, como gênero, idade, experiência, sensibilidade ao flicker, pré-sintomas, uso de óculos de grau, deficiências visuais, postura de jogo e olho dominante. A escolha dessas informações de perfil foi embasada na literatura e na experiência adquirida durante os testes-piloto do estudo. Na pesquisa (Porcino [12]), assim como no presente estudo, os experimentos foram iniciados solicitando que os participantes preenchessem primeiro o questionário CSPQ, seguido pelo VRSQ.

A utilização de avaliações subjetivas, é uma abordagem comum para medir os sintomas de CS. No entanto, há uma preocupação adicional em relação à precisão dos sintomas relatados pelos participantes após o experimento. A falta de precisão na recordação dos sintomas pode resultar em avaliações distorcidas ou inadequadas dos efeitos do CS. Os participantes podem subestimar ou superestimar a intensidade ou frequência dos sintomas que vivenciaram, o que pode prejudicar a validade dos resultados obtidos.

2.4.2 Método Quantitativo

É importante utilizar métodos adicionais à medição subjetiva, como avaliações quantitativas por meio de biosinais dos participantes durante a exposição a CS [34]. Esses dados podem fornecer uma visão mais precisa e confiável dos sintomas experimentados, complementando as avaliações subjetivas. Os biosinais são medidas fisiológicas obtidas do corpo humano e incluem: *Electroencephalogram* (EEG), *Heart Rate* (HR), *Heart Rate Variabi-*

lity (HRV), *Galvanic Skin Response* (GSR), *Electrogastrography* (EGG) e *Electrodermal Activity* (EDA), entre outros.

Os sinais fisiológicos são amplamente utilizados em diversas áreas da saúde. São aplicados no diagnóstico de doenças neurológicas, cardíacas e musculares, no monitoramento de pacientes durante cirurgias, reabilitação, estudo do sono, monitoramento de atletas, entre outros. Muitas patologias podem ser diagnosticadas com base nas informações contidas nos biosinais [73]. Além disso, os biosinais também são usados em pesquisa científica, como ferramenta importante para coleta de dados.

Uma abordagem mais objetiva, requer a obtenção contínua de estatísticas que mensurem o impacto da CS no tempo de reação do usuário e no desconforto físico ao longo do tempo [34]. Nesse sentido, os sensores de biosinais se destacam em relação aos questionários tradicionais, uma vez que podem oferecer uma medição mais objetiva e precisa do estado fisiológico dos usuários durante toda a experiência. Ao integrar a avaliação subjetiva com dados objetivos, é possível obter uma compreensão mais abrangente e confiável dos sintomas associados ao CS.

Além disso, a capacidade de prever precocemente os sintomas, possibilitaria a aplicação antecipada de técnicas de redução da *Cybersickness* (CS). Por exemplo, com base na gravidade prevista da CS obtida por meio de análises de biosinais, seria possível inserir quadros estáticos de repouso na cena virtual, diminuir o campo de visão ou borrar o movimento rotacional [74, 75, 76], como estratégias preventivas. Ao adotar essas estratégias de forma proativa com base nas previsões de CS, seria possível aliviar o desconforto relacionado à CS antes mesmo de sua ocorrência, tornando a experiência de RV mais confortável e agradável para os usuários. Essa abordagem preventiva, poderia melhorar significativamente a experiência de uso dessas tecnologias e facilitar sua aplicação em diversos contextos, como jogos, treinamentos, terapias e outras aplicações que utilizem Realidade Virtual (RV).

Diversos estudos [23, 34, 28] têm demonstrado com sucesso a aplicação de biosinais na detecção de CS, utilizando uma variedade de métodos como: EEG, GSR, EGG, HR, entre outros. Detectar automaticamente a gravidade da CS ou prever sua ocorrência, podem ser alternativas mais eficazes. Os sinais fisiológicos, podem ser utilizados como entrada em técnicas de *Machine Learning* (ML), possibilitando a identificação automática de padrões a partir dos dados coletados. Isso permite a atribuição de pontuações com base em um modelo de ML predefinido, facilitando a análise e interpretação dos dados, a partir dos biosinais em estudo.

2.5 Detecção Automática da CS

Geralmente, as medições subjetivas [27, 1, 69] são obtidas antes/após a experiência imersiva. Para coletar medidas subjetivas durante a experiência, é preciso recorrer a intervenções disruptivas, como a intervenção humana ou o uso de software de autorrelato [3, 26]. No entanto, uma abordagem mais eficaz, seria a detecção precoce da gravidade da CS, por meio da previsão de sua ocorrência [28]; o que possibilitaria intervenções rápidas e apropriadas, gerando melhores resultados para os usuários. Com os recentes progressos no campo do *Deep Learning* (DL), é possível treinar uma *Deep Neural Network* (DNN) [77] para detectar a gravidade da CS atual ou prever sua gravidade futura [35]. Além disso, há diversos estudos [28, 34, 35] que têm explorado com sucesso a aplicação das RNN-LSTM [78, 79], para a detecção e previsão da gravidade da CS.

Os pesquisadores observaram que a CS tem um impacto significativo nos sinais fisiológicos, incluindo a onda delta do eletroencefalograma (*Electroencephalogram* (EEG)), frequência cardíaca (*Heart Rate* (HR)), variabilidade da frequência cardíaca (*Heart Rate Variability* (HRV)) e a resposta galvânica da pele (*Galvanic Skin Response* (GSR)), apresentando uma correlação significativa com a ocorrência de *Cybersickness* (CS) [34]. Além desses, outros biosinais, como o movimento ocular, piscar dos olhos, atividade gástrica (EGG), taxa de respiração, entre outros; também podem ser usados como indicadores para investigar as causas da CS. Com a análise desses biosinais, os pesquisadores podem identificar padrões e correlações que podem facilitar uma compreensão aprofundada sobre os mecanismos subjacentes à CS, permitindo o desenvolvimento de estratégias para mitigar seus sintomas.

2.5.1 Atividade Elétrica no Cérebro

Considerando os possíveis impactos da CS no estado físico dos usuários, a análise de dados fisiológicos tornou-se uma abordagem importante. A atividade elétrica do cérebro (EEG) pode ter um papel significativo na CS, uma vez que os conflitos entre os sinais visuais e vestibulares podem causar modificações na atividade neural [80]. Segundo Bli-nowska et al [81], a eletroencefalografia é um campo dedicado ao registro e interpretação do eletroencefalograma (EEG), que é uma representação gráfica do sinal elétrico gerado pela atividade cooperativa das células cerebrais. Mais especificamente, o EEG registra a variação temporal das mudanças elétricas geradas pela ação sincronizada das células cerebrais. A palavra "eletroencefalograma" deriva das palavras gregas "enkephalo" (cérebro) e "graphein" (escrever). De acordo com Binnie et al. [82], o *Electroencephalogram* (EEG) é uma representação gráfica da atividade elétrica do cérebro, que é registrada em forma de

um espectro de frequências, podendo ser medido através de eletrodos colocados no couro cabeludo ou diretamente no córtex cerebral.




Figura 2.4: Comparação de bandas de ondas cerebrais EEG [5].

A atividade cerebral é composta por ondas cerebrais, conforme Figura 2.4, que são representadas como uma onda fundamental comum, que pode ser subdividida em diferentes bandas de frequência [83], como Alfa, Beta, Teta, Delta e Gama. Essa subdivisão em diferentes bandas de frequência no EEG, permite a análise e interpretação das características das ondas cerebrais, fornecendo informações valiosas sobre o funcionamento cerebral e o estado mental do indivíduo em estudo. Apesar dos desafios relacionados aos ruídos

presentes no EEG, estudos têm buscado o uso de redes neurais como uma abordagem para avaliar a *Cybersickness* (CS) com base nos sinais EEG [34].

2.5.2 Movimento Ocular e Piscar dos Olhos

Pesquisas têm sido realizadas para investigar a possível relação entre o movimento ocular, o piscar dos olhos e a ocorrência de *Cybersickness* (CS) em ambientes virtuais. O estudo de Lopes et al. [84] examinou as variações na posição da pupila e taxa de piscadas em relação à intensidade da CS. Os resultados sugerem que o rastreamento ocular e a taxa de piscadas pode ser um bom indicador da CS. Recentemente, o uso de HMD com recursos de rastreamento ocular, tem possibilitado a gravação dos movimentos oculares dos usuários durante suas experiências de RV [85].

Diversos estudos têm registrado os sinais de Eletrooculograma (*Electrooculogram* (EOG)) dos participantes para caracterizar os movimentos oculares. Dado que a fadiga ocular é um dos principais sintomas do SSQ [86], é pertinente investigar esses fatores como uma possível variável para a detecção da CS [87]. De acordo com Brown et al. [88], o EOG é um registro dos potenciais elétricos gerados pelos movimentos oculares, medidos entre a córnea e a retina do olho. Para Chang e Won-Du [6], o EOG é um sinal que muda de acordo com os movimentos oculares; as alterações são causadas pelo potencial estacionário entre a retina e a córnea dos olhos [89]. O potencial aumenta quando a córnea se aproxima de um eletrodo e diminui quando a córnea se move na direção oposta.

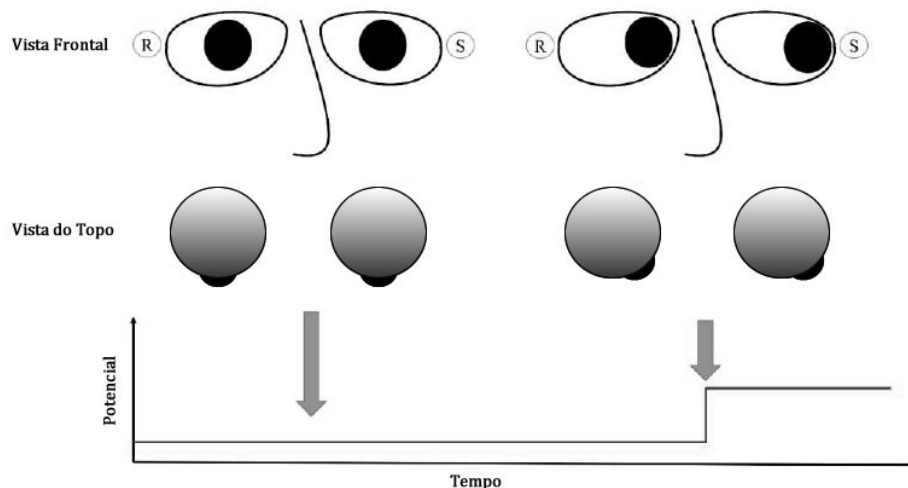


Figura 2.5: Movimentos oculares juntamente com as mudanças no potencial elétrico na região periocular. O símbolo 'S' indica a localização de um sensor utilizado para registrar o sinal de EOG, enquanto 'R' indica o local onde um eletrodo de referência é colocado [6].

O procedimento padrão aplicado aos biosinais, incluindo o EOG, pode ser dividido em cinco fases: medição, processamento de sinal, extração de recursos, reconhecimento de padrões e comunicação. A medição envolve a escolha do tipo de dispositivo e a colocação dos eletrodos. O processamento de sinal é realizado para extrair e separar os sinais relacionados aos olhos, eliminando sinais indesejados. A seleção de recursos é feita considerando as tarefas de reconhecimento e os modelos a serem treinados. Finalmente, o sinal processado é classificado usando técnicas como algoritmos *Support Vector Machine* (SVM) e *Recurrent Neural Network* (RNN) [6].

Além disso, existem outros métodos de rastreamento ocular que permitem a captura de dados enquanto o usuário está imerso em ambientes de RV, como através do uso de dispositivos como: HTC Vive Pro Eye [90], HP Reverb G2 Omnicept Edition [91] e Pupil Labs (VR/AR) [92]. Esses dispositivos têm a capacidade de coletar dados precisos sobre o movimento ocular dos participantes, incluindo fixação, saccades (movimentos rápidos dos olhos) e outras métricas oculares relevantes. Essas informações são valiosas para entender a relação entre o rastreamento ocular e a ocorrência de CS, possibilita aos pesquisadores investigar as causas e os efeitos dessa condição e desenvolver estratégias para mitigá-la.

2.5.3 Frequência e Variabilidade da Frequência Cardíaca

De acordo com pesquisas recentes [23, 34, 28], a exposição a ambientes virtuais imersivos pode resultar em alterações na atividade elétrica do coração registrada pelo *Electrocardiogram* (ECG), incluindo aumento na frequência cardíaca (*Heart Rate* (HR)) e modificações na variabilidade da frequência cardíaca (*Heart Rate Variability* (HRV)). O eletrocardiograma (*Electrocardiogram* (ECG)) é "o registro na superfície corporal da atividade elétrica gerada pelo coração" [93], sendo amplamente utilizado na avaliação de doenças cardíacas e distúrbios do ritmo cardíaco.

Durante a coleta de dados de ECG, a presença de ruídos e artefatos é comum e pode interferir na precisão da análise. A presença de ruídos pode levar a avaliações equivocadas por parte dos pesquisadores, diminuindo a precisão dos resultados [94]. Nesse contexto, o pré-processamento é uma etapa crucial na análise de ECG [95], pois tem como objetivo reduzir esses ruídos e artefatos, a fim de identificar com maior precisão os pontos fiduciais, que são pontos específicos encontrados em um traçado de ECG. Esses pontos fiduciais são importantes referências para a análise de diferentes parâmetros, como duração de segmentos, intervalos e amplitude de ondas; sendo essenciais para a interpretação correta e obtenção de resultados confiáveis na análise de ECG.

A análise de ECG tem sido amplamente utilizada em diversas áreas, indo além do diagnóstico de doenças cardiovasculares, evidenciando um notável aumento em sua aplicação. Os cientistas realizam medições de sinais de ECG em momentos críticos, como

em situações de estresse, durante um exame oral, após um feriado para estudantes, em ambientes de escritório para funcionários e durante uma tarefa de direção para motoristas [94]. Os resultados desses estudos mostram que as características do ECG são úteis para distinguir entre diferentes cargas de trabalho mental e níveis de estresse [93]. Além disso, há outros estudos, como o trabalho realizado por Reyer Lobo et al. [96], que propõe uma análise da Variabilidade da Frequência Cardíaca (*Heart Rate Variability* (HRV)) como uma forma de monitorar o *Cybersickness* (CS), a fim de superar as limitações dos atuais escores subjetivos na detecção dos efeitos adversos que a imersão em um ambiente virtual pode causar aos usuários de Realidade Virtual (RV).

2.5.4 Atividade Gástrica

Segundo Yin et al. [97], a técnica de Eletrogastrografia (*Electrogastrography* (EGG)) foi inicialmente introduzida por Alvarez em 1922 [98], redescoberta por RC Davis (1957) e popularizada na década de 1990. Devido à sua natureza não invasiva, o EGG tem recebido significativa atenção por parte de pesquisadores e clínicos. A EGG é a técnica de mensuração da atividade mioelétrica gástrica em células musculares lisas do estômago, sendo realizada por meio de eletrodos de superfície (Figura 2.6) posicionados na região abdominal do corpo [97]. A frequência normal do EGG em indivíduos saudáveis durante o jejum, geralmente varia entre 2 e 4 ciclos por minuto (cpm), sendo uma média de 3 cpm, dentro de uma faixa ampla de variação [99, 100]. Wolpert et al. em seu estudo [7], também menciona que a definição de normogastria varia entre diferentes autores, sendo geralmente estabelecida na faixa de 2 a 4 cpm (ciclos por minuto).

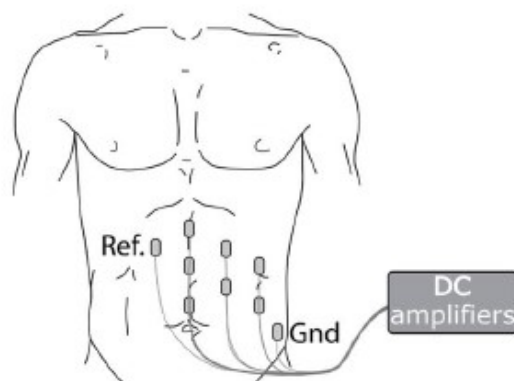


Figura 2.6: Eletrodos cutâneos colocados no abdome do participante [7].

Segundo Jakus et al. [101], os parâmetros obtidos a partir do EGG, como a amplitude média e a frequência dominante, têm sido utilizados para avaliar a presença de náuseas

em diversos contextos, incluindo em simuladores de condução automatizados. Durante episódios de náusea, é observada uma alteração na amplitude e no conteúdo da frequência do EGG, o que pode ser indicativo desse sintoma. Ao longo de mais de uma década, o *Electrogastrography* (EGG) tem sido utilizado como uma ferramenta objetiva para avaliar os sintomas epigástricos e náuseas experimentados em *Motion Sickness* (MS). Alguns trabalhos têm demonstrado que durante o curso desses sintomas, ocorre uma alteração na atividade elétrica basal predominante do trato gastrointestinal[102]. De acordo com Hu et al. [103], as atividades mioelétricas gástricas são indicadores de MS. Por ser um procedimento não invasivo, a EGG não apresenta contra-indicações e pode ser utilizado para investigar diversos distúrbios relacionados à função gástrica [104]. Embora seja considerada uma técnica importante e uma ferramenta de pesquisa valiosa, ainda é necessário estabelecer seu papel clínico [105]. Além disso, outros estudos têm utilizado o EGG como uma ferramenta para detectar a CS [106, 107], enjoo causado por ambientes virtuais, simulações ou experiências em ambientes digitais.

2.5.5 Atividade Muscular

De acordo com Merletti et al.[108], a Eletromiografia (*Electromyography* (EMG)) é uma técnica de medição da atividade elétrica dos músculos. A atividade muscular é registrada em forma de sinais eletromiográficos, que são obtidos através da colocação de eletrodos na superfície da pele sobre o músculo de interesse ou por meio de eletrodos implantados diretamente no músculo. Esses sinais podem ser amplificados, processados e analisados para avaliar a função muscular, monitorar a atividade física em tempo real e auxiliar no diagnóstico de condições neuromusculares.

A utilização de previsões de movimento da cabeça, é uma solução para reduzir a latência em sistemas de Realidade Virtual (RV). Essas previsões podem ser desenvolvidas usando diferentes tipos de sensores e algoritmos, como sensores inerciais ou utilizando biosinais, como a Eletromiografia (*Electromyography* (EMG)). O conceito por trás do uso do sinal EMG como preditor do movimento da cabeça, é baseado no fenômeno do Atraso Eletromecânico (*Electromechanical Delay* (EMD)), que é o atraso entre o potencial de ação gerado e as contrações musculares [109]. O EMD sugere que o movimento humano pode ser antecipado pela detecção do sinal EMG de superfície.

No estudo de Recentì et al. [110], foi demonstrado que durante o processo de seleção de variáveis, os parâmetros musculares (EMG) foram os mais significativos, em contraste com os parâmetros EEG, no contexto de *Motion Sickness* (MS) e RV. Além disso, os resultados podem ter implicações práticas no desenvolvimento de estratégias para reduzir o CS em experiências de RV. A consideração dos parâmetros musculares de EMG em

conjunto com outras medidas, pode levar ao desenvolvimento de abordagens mais eficazes na minimização dos sintomas da *Cybersickness* (CS).

2.5.6 Condutividade da Pele

De acordo com o estudo de Islam et al. [28], a *Galvanic Skin Response* (GSR) é um dos principais indicadores de CS, já que reflete as alterações fisiológicas do sistema nervoso autônomo durante a exposição a essas tecnologias. A GSR é uma medida fisiológica que pode ser obtida a partir da superfície da pele e reflete principalmente a atividade dos nervos simpáticos sudomotores nos canais secretores das glândulas sudoríparas écrinas [111]. A condutividade da pele humana pode fornecer uma indicação de alterações no sistema nervoso simpático humano [112]. Se ocorrer um aumento na porosidade dessas glândulas, haverá também um aumento na condutância elétrica, que pode ser detectado por meio da GSR [111]. Segundo Dawson et al. [8], a condutância da pele é medida por meio de eletrodos, e a sua medição pode ser realizada em locais comumente encontrados nas palmas das mãos. Existem várias opções aceitáveis de colocação de eletrodos para a medição da condutância da pele (conforme a Figura 2.7).

Outro termo frequentemente utilizado é a Atividade Eletrodérmica (*Electrodermal Activity* (EDA)), que engloba diversas medidas relacionadas à atividade elétrica da pele, tais como: condutância de longo prazo, resposta fásica e a resposta tônica [113, 8]. A EDA é um termo mais abrangente que inclui várias medidas de atividade elétrica da pele. Por outro lado, a GSR é apenas uma medida específica de atividade elétrica da pele que reflete a condutância elétrica da pele em resposta à atividade do sistema nervoso autônomo. Essa distinção é importante para evitar confusão e garantir a precisão dos resultados em estudos que usam essas medidas.

A aplicação de EDA, que envolve a medição da GSR, pode fornecer informações valiosas em pesquisas sobre CS. A GSR é capaz de registrar a resposta do sistema nervoso autônomo em relação a ambientes de Realidade Virtual (RV), Realidade Aumentada (RA) e outros estímulos sensoriais; possibilitando a identificação de períodos de maior tensão emocional e desconforto físico. No estudo conduzido por Jung et al. [114], foi constatada uma relação positiva entre a GSR e a CS.

2.6 Inteligência Artificial

A Inteligência Artificial (IA) é um campo interdisciplinar que envolve a ciência e a engenharia, com foco na compreensão computacional do que é conhecido como comportamento inteligente e na criação de artefatos que possam exibir esse comportamento [115, 116]. De acordo com Nilsson e Nils J [117], a IA, preocupa-se com o comportamento inteligente




Figura 2.7: Eletrodos posicionados para registrar a atividade eletrodérmica [8].

em artefatos, tendo como um dos seus objetivos de longo prazo, desenvolver máquinas capazes de executar essas tarefas tão bem quanto, ou talvez até melhor do que, os seres humanos.

Para Rouhiainen e Lasse [118], IA é a habilidade das máquinas de utilizar algoritmos, aprender com dados e empregar esse aprendizado na tomada de decisões, tal como um ser humano faria. Diferentemente das pessoas, dispositivos baseados em Inteligência Artificial (IA) não requerem descanso e são capazes de processar grandes volumes de informação de uma só vez. Ademais, a taxa de erros é consideravelmente inferior em máquinas desempenhando as mesmas atividades que seus correspondentes humanos.

2.6.1 Aprendizado de Máquina

O Aprendizado de Máquina (*Machine Learning* (ML)) tem sido empregado como uma ferramenta com o objetivo de melhorar a experiência do usuário e minimizar os efeitos indesejados da CS. Para identificar padrões relacionados à CS, modelos de ML são treinados utilizando dados coletados durante a utilização de dispositivos de RV. Com base nessas informações, é possível desenvolver estratégias mais efetivas para mitigar os sintomas, tornando a experiência de uso de dispositivos de RV mais agradável.

Machine Learning (ML) é um subcampo da inteligência artificial que se dedica ao desenvolvimento de algoritmos capazes de permitir que sistemas computacionais aprendam e se adaptem a partir de dados, ao invés de serem programados de forma explícita para executar tarefas específicas [119]. Para Molnar e Christoph [120], ML é um conjunto de métodos que os computadores usam para fazer e melhorar previsões ou comportamen-

tos com base em dados. Segundo Bochie et al. [121], os algoritmos de aprendizado de máquina podem ser divididos em supervisionado, não supervisionado e por reforço.

- **Aprendizado supervisionado:** os algoritmos têm acesso a um conjunto de dados rotulados, contendo exemplos de entradas com suas respectivas saídas conhecidas. Ao expor o algoritmo a um grande volume de dados durante o processo de treinamento, ele ajusta seus parâmetros para ser capaz de prever corretamente as saídas para novas entradas não vistas anteriormente [121].
- **Aprendizado não supervisionado:** em vez de receber um conjunto de dados com entradas e saídas predefinidas, a máquina recebe apenas um conjunto de entradas (x_1, x_2, \dots, x_n) [122]. Isso significa que não há um mapeamento pré-estabelecido entre as entradas e as saídas desejadas. O objetivo desse tipo de abordagem de aprendizado de máquina é encontrar padrões e estruturas ocultas nos dados que possam ser úteis para a tarefa em questão.
- **Aprendizado por reforço:** nessa abordagem, os algoritmos utilizam um modelo de recompensas e punições à medida que interagem com o ambiente [121]. O agente aprende a tomar decisões por tentativa e erro, aprimorando seu comportamento ao longo do tempo por meio de uma política de ações que visa maximizar sua recompensa numérica.

2.6.2 Classificadores Simbólicos

Os métodos simbólicos de aprendizado de máquina são caracterizados por induzir modelos explicitamente representados em formato simbólico a partir dos dados. Diferentemente de abordagens como redes neurais, que frequentemente resultam em modelos "caixa preta", os métodos simbólicos resultam em modelos cujas representações são explícitas e facilmente interpretáveis [123]. A legibilidade dos métodos simbólicos os torna especialmente atraentes em aplicações em que a transparência do modelo é fundamental, como em sistemas de diagnósticos médicos, suporte à decisão, ou tarefas que requerem a compreensão do raciocínio por trás das decisões tomadas pelo modelo.

Os classificadores simbólicos operam com símbolos e regras lógicas para descrever os padrões presentes nos dados de treinamento, cuja linguagem de descrição pode ser composto por um conjunto de N_R regras posicionais if-then, exemplo: $\mathbf{h} = \{R_1, R_2, \dots, R_{N_R}\}$ [124]. Cada regra é formulada a partir da análise dos dados de treinamento e pode ser adaptada ou ampliada conforme novas informações são assimiladas pelo sistema.

Uma regra é uma disjunção de conjunções de testes de atributos na forma $X_i \text{ op Valor}$, onde X_i é o nome de um atributo, op é um operador pertencente ao conjunto $\{=, \neq, <$

, \leq , $>$, \geq } e *Valor* é um valor válido para o atributo X_i . Cada regra R assume a forma **if B then H** ou simbolicamente $B \rightarrow H$, onde H é a cabeça, ou conclusão da regra, e B é o corpo, ou condição da regra. H e B são ambos conjuntos de testes de atributos sem nenhum atributo em comum. Em uma regra de classificação, a cabeça da regra H assume a forma $\text{class} = C_i$, onde $C_i \in \{C_1, \dots, C_{N_{Cl}}\}$ [124].

Um exemplo de Árvore de Decisão

Vamos considerar uma árvore de decisão composta por sete nós e os atributos: Gênero, Idade, Experiência, Tempo de Jogo, Velocidade Média, FPS (*Frames Per Second*) e Nível de Desconforto (conforme a Figura 2.8. Neste contexto específico, as regras desse modelo de árvore de decisão são aplicadas para classificar o nível de desconforto dos jogadores durante uma simulação de jogo de carro em realidade virtual. Os critérios de decisão do modelo são: "Velocidade Média", "Tempo de Jogo" e "Idade". O resultado é a classificação do "Nível de Desconforto", que pode ser 0 (Nenhum), 1 (Leve), 2 (Moderado) e 3 (Severo).

Conforme apresentado na Figura 2.8, no primeiro nível, a divisão é feita com base na condição da "Velocidade Média", indicando assim o atributo mais relevante neste modelo. Se este atributo for menor ou igual a 109.0, avança para a próxima condição "Tempo de Jogo"; se maior que 109.0, resulta na classificação "Severo". Para o ramo "Velocidade Média \leq 109.0", se "Tempo de Jogo" for menor ou igual a 2100.0, a idade é avaliada, resultando em "Moderado" se for menor ou igual a 22.5 e "Nenhum" caso contrário. Se "Tempo de Jogo" for maior que 2100.0, o resultado é "Moderado". Neste exemplo, os círculos azuis indicam um único caminho de decisão para uma instância prevista como "Moderado".

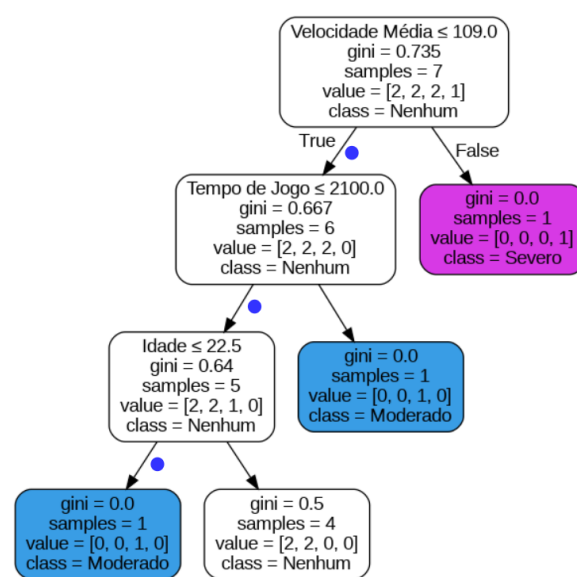


Figura 2.8: Árvore de Decisão do Exemplo.

As regras apresentadas neste exemplo foram geradas por um script implementado em Python, que utiliza a biblioteca scikit-learn. A classe `sklearn.tree`, é uma implementação do algoritmo CART, desenvolvido por Leo Breiman [125].

2.6.3 Aprendizado Profundo

Os fundamentos teóricos do *Deep Learning* (DL) têm suas raízes na literatura clássica das *Neural Network* (NN) [126]. O DL é uma técnica de *Machine Learning* (ML) que visa aprender abstrações em dados utilizando redes neurais profundas compostas por várias camadas [127]. Conforme mostrado na Figura 2.9, Aprendizado de Máquina e Aprendizado Profundo, são um subconjunto de Inteligência Artificial (IA).

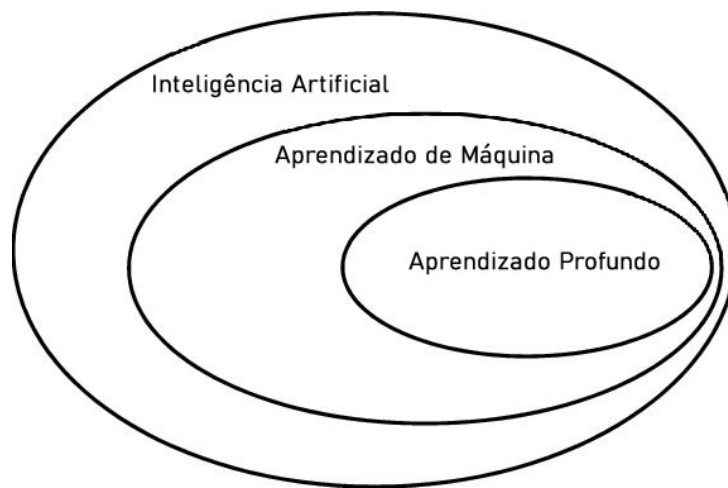


Figura 2.9: Relação entre Inteligência Artificial, Aprendizado de Máquina e Aprendizado Profundo [9].

A ideia por trás da DL, é emular o processo de aprendizagem humana em que um especialista ensina um iniciante a realizar uma tarefa. Nessa abordagem, o modelo é alimentado com uma grande quantidade de dados rotulados e, com base nesses dados, é capaz de aprender a fazer previsões [128]. Bengio et al. [129], afirmam que o DL revigorou a pesquisa em redes neurais, tornando mais fácil o treinamento de redes mais profundas com a introdução de GPUs e grandes conjuntos de dados. Plataformas de software, como Caffe, TensorFlow e PyTorch, foram desenvolvidas para melhorar esses recursos. A adição de mais camadas permitiu incorporar mais informações e características na rede, levando a resultados mais precisos e robustos em tarefas de percepção, interpretando os dados de entrada, de maneira similar a como os seres humanos fazem. Algumas dessas tarefas são: reconhecimento de fala, reconhecimento de imagens, análise de sentimento e tradução automática.

2.6.4 Rede Neural Convolucional

A *Convolutional Neural Network* (CNN) é uma arquitetura de aprendizagem profunda bem conhecida, que se inspira no mecanismo de percepção visual natural dos seres vivos [130]. Segundo Li et al. [131], a CNN é uma rede neural do tipo feed-forward que pode extrair recursos de dados utilizando estruturas de convolução. Ela é inspirada na percepção visual [131, 132]. Graças às suas conquistas impressionantes, a CNN se estabeleceu como uma das redes neurais mais proeminentes no campo da aprendizagem profunda. A visão computacional baseada em CNNs permitiu que tarefas consideradas impossíveis por séculos, como reconhecimento facial, veículos autônomos, supermercados self-service e tratamento médico inteligente, se tornassem realidade [131].

O ImageNet Large Scale Visual Recognition Challenge (LSVRC) de 2012 foi um marco significativo no desenvolvimento da CNN e da visão computacional. Nessa competição, Krizhevsky et al. [133], alcançaram o melhor resultado de classificação da época utilizando uma CNN profunda. Esse feito atraiu a atenção de muitos pesquisadores e impulsionou significativamente o desenvolvimento da CNN moderna. Desde então, as CNNs se tornaram uma técnica padrão para uma ampla variedade de tarefas de visão computacional, incluindo reconhecimento de imagem, detecção de objetos e segmentação de imagens.

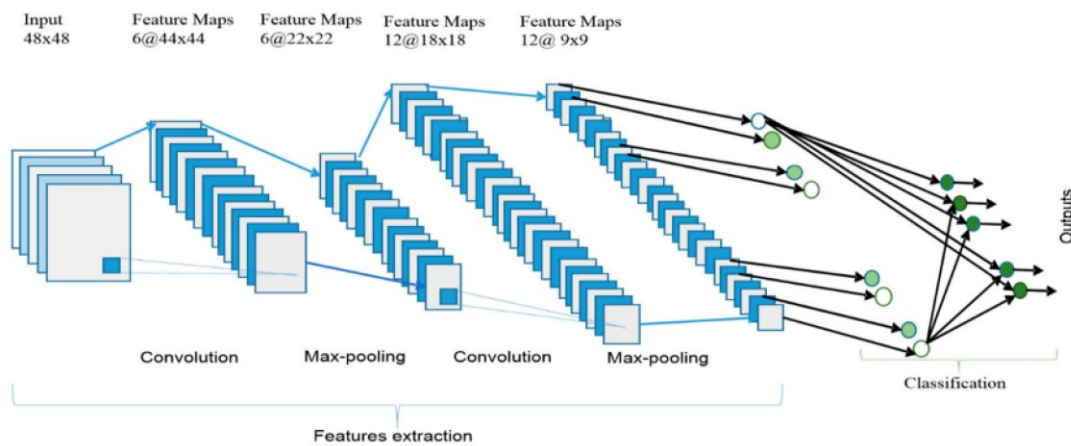


Figura 2.10: A arquitetura geral da CNN (adaptado [10]).

Segundo Alom et al. [10], a arquitetura geral das CNNs é composta por extratores de características e um classificador, como ilustrado na Figura 2.10. Cada camada da rede recebe como entrada a saída da camada imediatamente anterior e passa sua saída como entrada para a próxima camada. Nas camadas de baixo e médio nível da rede, existem duas camadas principais: convolucionais e max-pooling. As camadas de convolução e max-pooling possuem agrupamentos de um plano 2D com mapeamento de recursos, que são disponibilizados como nós de saída. Os nós de um plano são conectados a uma

pequena região de cada plano da camada anterior, onde cada camada de convolução extrai recursos das imagens de entrada através de operações de convolução nos nós de entrada. A camada de convolução é responsável por extrair recursos da entrada por meio de filtros de convolução, enquanto a camada max-pooling reduz a dimensionalidade dos mapas de recursos. A camada de classificação é responsável por conectar todos os recursos extraídos pelas camadas anteriores para gerar uma saída final.

De acordo com Li et al. [131], uma CNN é composta por quatro componentes básicos, que trabalham em conjunto para extrair recursos das imagens de entrada e classificá-las corretamente.

- **Camada de convolução:** é encarregada de extrair características da entrada por meio da aplicação de filtros de convolução. Cada filtro é aplicado a uma região específica da entrada e produz um mapa de características correspondente.
- **Camada de ativação:** é aplicada após a camada convolucional ou a camada totalmente conectada, e é responsável por determinar quais recursos serão ativados e quais serão suprimidos, com base nos valores de entrada e nos pesos da rede. Isso permite introduzir não-linearidade ao modelo. Algumas das funções de ativação comuns incluem ReLU (conforme a Eq 2.1), sigmoid, tanh e softmax (conforme a Eq 2.2).
- **Camada de pooling:** é responsável por reduzir a dimensionalidade dos mapas de recursos produzidos pela camada de convolução. A operação mais comum é o max-pooling, que mantém o valor máximo de um filtro em uma área definida.
- **Camada totalmente conectada:** é responsável por conectar todos os recursos extraídos pelas camadas anteriores para gerar uma saída final.

$$f(x) = \max(0, x) \tag{2.1}$$

Rectified Linear Units (ReLU), ou Unidades Lineares Retificadas é uma função de ativação com forte sustentação biológica e matemática [134]. É uma função de ativação utilizada em redes neurais profundas, incluindo as CNNs. Basicamente esta função produzirá 0 quando $x < 0$ e, gerará a própria entrada para $x \geq 0$. Tornou-se a função de ativação padrão para muitos tipos de redes neurais, porque é mais fácil de treinar e geralmente obtém melhor desempenho.

A função softmax é frequentemente utilizada na camada de saída da CNN para normalizar a saída em um vetor de probabilidades. A função softmax pode ser expressa

conforme a Equação 2.2, onde x_1, x_2, \dots, x_N são os valores de entrada da camada softmax e o valor de saída $f(x_i)$ representa a probabilidade de que a amostra pertença à i -ésima categoria [135]. Portanto, antes de usar a função softmax, alguns conjuntos vetoriais podem ser < 0 ou > 1 ; pode também não somar 1; após aplicação do softmax, cada conjunto estará no intervalo de $(0,1)$, tendo todos os conjuntos somando 1, assim interpretados como probabilidade.

$$f(x_i) = \frac{e^{x_i}}{\sum_{j=1}^N e^{x_j}} \quad \text{for } i = 1, 2, \dots, N \quad (2.2)$$

Para ilustrar de forma mais clara o uso da função softmax, vamos tomar como exemplo o *array* $x = [1, 3, 2, 7, 4]$. Inicialmente calculamos a soma exponencial dos elementos do vetor x , denotada como `exp_sum`, utilizando a função softmax: `exp_sum = e1 + e3 + e2 + e7 + e4`. Em seguida, calculamos cada elemento do *array* resultante, `softmax_xi`, aplicando a função softmax a cada x_i , onde:

$$\text{softmax_x}_i = \frac{e^{x_i}}{\text{exp_sum}}$$

Assim, o *array* resultante após a aplicação da função softmax é aproximadamente:

$$\text{softmax_x} \approx [0.00230085, 0.01700112, 0.00625436, 0.92822982, 0.04621384]$$

A soma dos elementos desse *array* totaliza 1, o que representa a probabilidade total.

2.6.5 Redes Neurais Recorrentes

As *Recurrent Neural Network* (RNN) são modelos de aprendizado de máquina usados em tarefas sequenciais, como processamento de linguagem natural (*Natural Language Processing* (NLP)), reconhecimento de fala, reconhecimento de manuscritos, entre outros [136, 137, 138]. Diferentemente de outras redes neurais, as RNNs têm loops que permitem passar informações entre camadas ao longo do tempo. Haykin e Simon [139] as definem como modelos supervisionados de neurônios artificiais com loops de feedback. Para treinar uma RNN de maneira supervisionada, é necessário um conjunto de dados de treinamento que contenha pares de entrada e saída desejada. O objetivo do treinamento é minimizar a diferença entre as saídas geradas pela rede e as saídas desejadas, ajustando os pesos da rede.

Segundo Salehinejad et al. [140], o objetivo do treinamento é minimizar a diferença entre as saídas geradas pelo modelo e as saídas desejadas, ajustando os pesos da rede. As RNNs pertencem a uma classe de Redes Neurais Artificiais (ANNs) em que as conexões

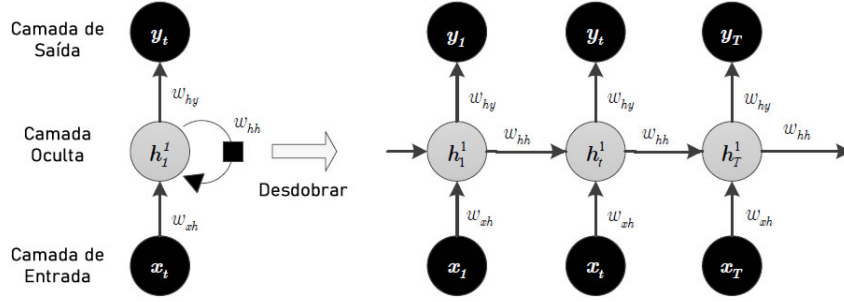


Figura 2.11: RNN - os círculos denotam as camadas da rede, enquanto as linhas sólidas representam as conexões ponderadas. As setas indicam a direção da propagação direta [11].

entre os nós formam um grafo direcionado ao longo de uma sequência, permitindo que a rede exiba um comportamento dinâmico temporal em uma sequência de tempo. Na Figura 2.11, é apresentada uma RNN e sua computação direta ao longo do tempo, na qual os neurônios recebem entradas de outros neurônios em momentos temporais anteriores. Dado um conjunto de sequências de entrada $x = (x_1, \dots, x_T)$, as RNNs padrão iteram as equações para calcular a sequência vetorial oculta $h = (h_1, \dots, h_T)$ e a sequência vetorial de saída $y = (y_1, \dots, y_T)$ [11].

$$h_t = \mathcal{H}(W_{xh} \cdot x_t + W_{hh} \cdot h_{t-1} + b_h) \quad (2.3)$$

$$y_t = w_{hj} \cdot h_t + b_y \quad (2.4)$$

O primeiro termo da Equação 2.3, é a multiplicação da matriz de pesos W_{xh} pela entrada x no tempo t . O segundo termo é a multiplicação da matriz de pesos W_{hh} pelo estado oculto anterior h_{t-1} . Essa matriz define como o estado oculto anterior é transformado e atualizado para o instante de tempo atual. O terceiro termo é o vetor de polarização oculta, denotado por b_h , que é adicionado aos resultados da multiplicação de matrizes. O resultado dessas operações é então passado por uma função de ativação \mathcal{H} , que geralmente é uma aplicação elementar da função sigmoide, a fim de introduzir não-linearidade na rede e gerar o estado oculto atual h_t . Esse estado oculto h_t é usado como entrada para calcular o próximo estado oculto h_{t+1} , e assim por diante.

Na Equação 2.4, o termo h_t é o vetor oculto no tempo t , que contém informações da entrada atual e das entradas anteriores da sequência; w_{hj} é uma matriz de pesos que define como a informação oculta é transformada para gerar a saída y_t ; e por último, b_y é um vetor de bias, que é adicionado à soma ponderada da matriz de pesos e do vetor

oculto, permitindo que a rede neural capture tendências gerais nos dados de entrada.

2.6.6 Inteligência Artificial Explicável

A interpretabilidade dos modelos de Inteligência Artificial (IA) é um princípio fundamental em diversos setores, incluindo saúde, indústria e transportes, conforme destacado por Islam et al [141]. Um modelo que age como uma 'caixa preta', sem fornecer informações claras sobre suas operações internas, pode gerar desconfiança, especialmente em áreas críticas como a saúde, tornando essencial o uso de modelos que possam ser compreendidos e avaliados por profissionais.

Os sistemas explicáveis surgiram na década de 1980 com o propósito de elucidar as decisões tomadas pelos sistemas especialistas. Depois, evoluíram para apoiar interações humano-computador, como tutores inteligentes. O interesse atual em Inteligência Artificial Explicável (Em inglês: *Explainable Artificial Intelligence* (XAI)) é impulsionado pelos avanços recentes em IA/ML, amplamente aplicados em várias áreas, e crescentes preocupações éticas sobre transparência e preconceitos nos modelos [141]. Conforme mencionado por [142, 143, 144], a XAI engloba sistemas ou ferramentas de *Machine Learning* (ML) ou IA, que têm como objetivo desvendar os aspectos internos de modelos 'caixa preta', revelando, por exemplo, o que os modelos aprenderam e/ou fornecendo explicações para previsões individuais.

As explicações na área da XAI, podem ser divididas em duas perspectivas: local e global [142]. A perspectiva local tem o foco na explicação das decisões do modelo em um nível de instância, ou seja, oferece explicações para uma amostra específica de dados. Por outro lado, a visão global proporciona uma compreensão mais ampla, apresentando o comportamento geral do modelo em todo o conjunto de dados.

Adicionalmente, os métodos de explicabilidade podem ser categorizados com base no momento de aplicação ao longo do ciclo de vida do modelo, seja antecipadamente (ante-hoc) ou após o treinamento (post-hoc) [145]. O enfoque ante-hoc aplica técnicas explicativas durante o pré-treinamento do modelo, enfatizando a interpretabilidade desde o início como requisito fundamental na criação do modelo. Já a abordagem post-hoc busca tornar modelos complexos, como redes neurais profundas ('caixas-pretas'), mais interpretáveis após o treinamento, sem prejudicar significativamente o desempenho.

No trabalho de Islam et al [142], os autores classificam a XAI em três tipos: Métodos Intrinsecamente Interpretáveis, Modelos Agnósticos e Explicações Baseadas em Exemplos.

- **Métodos Intrinsecamente Interpretáveis:** esses métodos referem-se a modelos de IA/ML, projetados para serem compreendidos pelos seres humanos, integrando a interpretabilidade em sua estrutura. Isso assegura transparência, exibindo de forma

clara o processo de tomada de decisões. No entanto, normalmente, esta explicabilidade natural tem um custo de desempenho. Os exemplos incluem Regressão Linear, Regressão Logística, Modelos baseados em Árvore de Decisão e Regras de Decisão;

- **Métodos Independentes de Modelo (Model-Agnostic Methods):** esses métodos geram explicações compreensíveis para qualquer modelo de *Machine Learning* (ML), mesmo os não interpretáveis, como *Deep Neural Network* (DNN). Essas abordagens não modificam o modelo, fornecendo explicações externas que facilitam a compreensão de seu comportamento complexo. Entre os métodos de interpretação independentes do modelo estão: *Local interpretable model-agnostic explanations* (LIME), *SHapley Additive exPlanations* (SHAP), *Permutation Importance* (PI), *Partial Dependence Plot* (PDP), *Accumulated Local Effects* (ALE plots) e *Individual Conditional Expectation* (ICE) [146];
- **Explicações Baseadas em Exemplos:** são métodos que selecionam instâncias do conjunto de dados para elucidar o funcionamento dos modelos de aprendizado de máquina ou para explicar a distribuição dos dados subjacente [142]. Eles evidenciam o processo pelo qual o modelo chega a uma previsão específica, destacando a influência e relevância das diferentes características do exemplo. Podem ser expressos da seguinte maneira: "X é semelhante a Y e Y causou Z, então a previsão indica que X causará Z"[146]. De acordo Morais [146], os principais tipos de métodos de explicações baseadas em exemplos são: Explicações contrafatuais (*Counterfactual Explanations*), Instâncias contraditórios (*Adversarial examples*), Protótipos e críticas (*Prototypes and criticism*) e Instâncias influentes (*influential examples*).

Capítulo 3

Trabalhos Relacionados

Neste capítulo, é realizada uma revisão da literatura que aborda o uso de biosinais para detecção e análise da *Cybersickness* (CS) em ambientes virtuais. Cada seção resume os principais pontos das pesquisas analisadas. Os temas abordados incluem a detecção automatizada da CS por meio de biosinais, detecção e previsão automática da CS, IA Explicável com EEG e análise da CS com algoritmos simbólico de ML.

3.1 Detecção da CS por meio de Biosinais

Além das medidas subjetivas, é importante utilizar métodos adicionais, como avaliações quantitativas por meio de biosinais dos participantes durante a exposição ao CS. Esses dados podem fornecer uma visão mais precisa e confiável dos sintomas experimentados, complementando as avaliações subjetivas. Dessa forma, é possível obter uma compreensão mais completa dos efeitos do CS no organismo humano e avaliar com maior precisão os possíveis riscos associados a sua exposição. Os biosinais mais comuns incluem: o Eletroencefalograma (EEG); Eletrocardiograma (ECG), do qual é possível extrair a Frequência Cardíaca (*Heart Rate* (HR)) e a Variabilidade da Frequência Cardíaca (*Heart Rate Variability* (HRV)); Resposta Galvânica da Pele (*Galvanic Skin Response* (GSR)) e Eletrogastrografia (*Electrogastrography* (EGG)).

3.1.1 Detectando a CS através de ECG

No estudo conduzido por Garcia-Agundez et al. [23], foi avaliado o uso de um ECG de 2 derivações para detectar a presença de *Cybersickness* (CS) em jogadores de realidade virtual. Um grupo composto por 13 participantes foi submetido a uma sessão de jogo de 15 minutos em um ambiente virtual, durante a qual seus ECGs foram registrados. Além disso, eles responderam ao questionário SSQ. Quatro participantes precisaram interromper

o experimento devido à ocorrência de CS, ao passo que os ECGs dos usuários 3 e 13 foram descartados por causa de sudorese e artefatos de movimentação excessiva.

O trabalho utilizou um Oculus Rift Developer Kit 2 conectado a um PC com CPU Intel Core i7 6700k, placa gráfica Nvidia GTX 980 e 16 GB de RAM, para garantir a taxa máxima de quadros e resolução. O ECG foi realizado usando um amplificador de biosinal USBamp de 2 derivações da g.Tec e o sinal foi capturado no Matlab, amostrado a 256 Hz e filtrado para remover o efeito de movimento e suor.

Os resultados obtidos apontaram para uma diferença estatisticamente significativa nas pontuações do SSQ e nos registros do ECG desses participantes, com um aumento médio de 8 pontos nas pontuações do SSQ. De maneira surpreendente, em comparação a outras pesquisas, os usuários que apresentaram maiores níveis de CS tiveram frequências cardíacas mais baixas. Os dados do ECG foram analisados em suas formas normalizadas e não normalizadas, e a duração média dos intervalos NN e o desvio padrão foram comparados com as pontuações do SSQ em áreas específicas e globais.

Foi constatado ainda uma correlação mais significativa entre os scores SDTNN e SSQ quando comparados com AVGNN e SSQ. Os coeficientes de regressão entre SDTNN e os sintomas de oculomotor ($r = 0,47$) e desorientação ($r = 0,38$) foram maiores. Em relação aos sintomas oculomotores, a correlação é ligeiramente superior à encontrada em um estudo anterior ($r = 0,43$) (Kim et al. [106]) para o período cardíaco. Esse resultado é particularmente interessante, já que estudos anteriores relataram correlações mais altas entre os sintomas oculomotores e a frequência cardíaca, embora os sintomas de desorientação sejam considerados predominantes na *Cybersickness* (CS).

3.1.2 Detectando a CS através de EEG

O *Simulator Sickness Questionnaire* (SSQ) possui uma limitação que requer interromper o usuário durante a experiência, afetando a experiência e portanto os resultados. Esta abordagem é incapaz de fornecer medições quantitativas em tempo real. O estudo de Krokos et al. [26], utilizou sinais de Eletroencefalograma (EEG) para investigar a CS induzida porvection em ambientes virtuais imersivos. Os resultados mostraram uma correlação entre a CS relatado pelos participantes (por movimentos de um joystick) e os sinais cerebrais de EEG, especificamente um aumento nas ondas Delta, Theta e Alfa. A pesquisa anterior (Kolasinski [22]) indicou que a CS pode afetar uma grande parte da população em ambientes virtuais. O estudo sugere que a correlação encontrada pode ser o primeiro passo para mitigar a CS em ambientes virtuais imersivos. O ambiente utilizado envolveu uma passagem aérea de um espaçoporto virtual com movimentos da câmera virtual.

Para este estudo, utilizou-se um Emotiv EPOC EEG de 14 canais com frequência de amostragem de 128 Hz, juntamente com um Head-mounted display HTC Vive. Foi criado um ambiente virtual personalizado usando um mecanismo de renderização 3D desenvolvido em C++ e OpenGL, que foi sincronizado com o processo de gravação EEG. A cena foi renderizada em estéreo 3D no head-mounted display, que simulava uma passagem aérea através de um espaço virtual com movimentos de torção, giro, aceleração e desaceleração da câmera virtual. Para o registro manual do nível atual da CS dos participantes durante o giro da câmera, foi utilizado um joystick Thrustmaster. Para execução, foi utilizado um computador com Windows 8, processador Intel Xenon de 2.6 GHz e uma GPU NVIDIA GTX 1080.

O experimento contou com a participação de 44 indivíduos, sendo 31 do sexo masculino e 13 do sexo feminino. Primeiro, o dispositivo EEG foi colocado na cabeça do participante e ajustado manualmente até que todos os eletrodos registrassem um bom contato com a cabeça. Em segundo lugar, o participante colocou o HMD e a distância interpupilar (IPD) foi ajustada para que pudesse visualizar confortavelmente a renderização estéreo 3D no HMD. Em seguida, o participante recebeu um joystick e foi instruído a empurrá-lo com base em como se sentia em relação à CS. O usuário foi orientado a relatar qualquer desconforto que sentisse, bem como sua intensidade, utilizando o joystick. A duração do experimento (*fly-through*) foi de 61 segundos. Cada participante foi solicitado a relatar brevemente qual aspecto da experiência os deixou com mais sintomas de CS. Eles relataram que as mudanças abruptas na direção e velocidade do movimento foram mais problemáticas em comparação com o movimento suave. Além disso, relataram que a antecipação do movimento da câmera aumentava sua reação. Finalmente, eles expressaram que se estivessem no controle da câmera, em vez da câmera ser movida automaticamente, poderiam se sentir menos enjoados devido ao conhecimento prévio e preparação mental.

O administrador do teste observou que aproximadamente 70% dos participantes inclinavam seus corpos, em graus variados (em alguns casos, quase alarmantes), de acordo com o movimento da câmera. Cerca de 32% dos participantes já tinham experiência anterior com head-mounted display. Os autores apontam que, para uma melhor compreensão das fontes da CS, seria interessante explorar o efeito que o desempenho de tarefas tem sobre a CS. Neste estudo, os participantes não foram solicitados a realizar uma tarefa específica. Por fim, os autores destacaram ainda, que é altamente desejável avançar na criação de padrões de avaliação para a CS e utilizá-los para avaliar tanto o hardware (como fones de ouvido, rastreadores e monitores) quanto o conteúdo (jogos, performances e outras experiências imersivas). Além disso, observaram também a importância de investigar como a duração da imersão, a idade e o sexo afetam a *Cybersickness* (CS).

3.2 Detecção e Previsão Automática da CS

Para compreender melhor a CS, vários estudos têm investigado os biosinais e dados de auto-relato de usuários que experimentaram os sintomas da *Cybersickness* (CS). Essas análises indicam que os usuários podem apresentar efeitos significativos e que há mudanças importantes nos dados fisiológicos durante a exposição à tecnologia imersiva. Com base nesses dados, pesquisadores têm investigado se é possível desenvolver modelos automatizados de detecção e previsão de CS. Essa abordagem pode ser útil para identificar usuários em risco de desenvolver esta condição, bem como para desenvolver estratégias de prevenção e mitigação dos sintomas associados.

3.2.1 Detecção da CyberSickness em RV baseada em Biosinais

Apesar da RV proporcionar uma experiência imersiva aos usuários, ainda há efeitos colaterais que afetam negativamente a experiência do usuário, sendo o cybersickness um deles. Qu et al. [34] realizaram um estudo sobre o uso de sensores fisiológicos para quantificar os fatores de influência do CS por meio de um modelo de Aprendizado Profundo. Eles também criaram uma plataforma experimental de RV e uma atividade de navegação passiva para induzir o *Cybersickness* (CS) nos usuários. Durante o experimento, foram coletados biosinais em tempo real do usuário, incluindo EDA, ECG e dados de posição e rotação do avatar virtual dos usuários, a fim de treinar o modelo LSTM *Attention*.

O estudo propôs um método de detecção de CS combinando dados subjetivos e objetivos, usando sinais fisiológicos e dados do avatar virtual para treinar um modelo de rede neural em tempo real. O sistema consiste em duas etapas: 1) coletar dados fisiológicos do usuário e treinar o modelo, 2) implantar o modelo em um sistema imersivo para prever o nível de CS do usuário. Durante a experiência de RV, o modelo foi capaz de detectar em tempo real o nível de CS dos usuários. O modelo foi validado cinco vezes com uma precisão média de 96,85% na classificação do nível de CS, demonstrando um desempenho superior em relação a outros estudos relevantes. O sistema pode alertar o usuário ou tomar medidas para reduzir os efeitos da CS.

O sistema utiliza um ambiente virtual que permite ao usuário ver seu avatar e reflexo no espelho, fornecendo feedback visual e reduzindo a carga cognitiva. O avatar é animado com rastreadores HTC Vive, permitindo movimento corporal preciso. Os usuários realizam tarefas de navegação passiva em um ambiente virtual simplificado para coletar dados fisiológicos relacionados ao CS. Antes da fase de avaliação, os participantes foram solicitados a fazer uma pausa para que pudessem colocar os biosensores em seus corpos e registrar a linha de base do biosinal. Durante a fase de avaliação, os participantes realizaram tarefas de navegação passiva em um ambiente virtual, podendo clicar no touchpad do

controlador para indicar desconforto ou melhora e podendo interromper o experimento se necessário. Após a fase de avaliação, os participantes preencheram um questionário subjetivo usando o VRSQ para coletar feedback sobre os sintomas de CS.

O modelo proposto obteve desempenho robusto na classificação de CS, mesmo quando comparado a outros estudos que usam EEG. A camada Attention pode ser adicionada após a camada LSTM para tornar a decisão final do modelo mais focada nas características efetivas. A aplicação da camada de Attention após o LSTM teve melhor desempenho com os dados fisiológicos. Por fim, o modelo apresentou uma precisão média de 96,58% na classificação do nível de *Cybersickness* (CS), mostrando um ótimo desempenho em comparação a outros estudos. A integração do modelo na plataforma RV pode permitir a detecção on-line em tempo real da CS no futuro.

3.2.2 Detecção Automática e Previsão usando DNN

Antecipar a possibilidade futura de *Cybersickness* (CS) é crucial, pois permite que os desenvolvedores usem técnicas de redução de CS, como desfoque de redução e campo de visão dinâmico. A pesquisa de Islam et al. [28], investigou as alterações fisiológicas associadas à CS, coletando dados de *Heart Rate* (HR), *Galvanic Skin Response* (GSR), *Breathing Rate* (BR) e *Heart Rate Variability* (HRV) de 31 participantes saudáveis imersos em uma simulação de montanha-russa RV. Para o experimento, foi criada uma simulação virtual de montanha-russa usando o Unity 3D. Os participantes foram submetidos a duas condições diferentes: 1) uma condição de repouso, na qual o carrinho da montanha-russa ficou parado por 5 minutos, e 2) uma condição de simulação, na qual o carrinho da montanha-russa se moveu ao longo da pista e levou 57 segundos para completar um ciclo. Entre dois ciclos consecutivos, houve uma pausa de 12 segundos, com no máximo 13 ciclos, totalizando 897 segundos de imersão.

Inicialmente, a detecção e previsão da gravidade da CS a partir dos biosinais, foi realizada utilizando um classificador de *Support Vector Machine* (SVM). Em seguida, a arquitetura CNN-LSTM foi utilizada para melhorar o desempenho da classificação. Os sinais fisiológicos foram rotulados usando feedback verbal autorrelatado, coletado durante a imersão em cada intervalo de minuto. Segundo os autores, estudos anteriores relataram que a CS afeta os sinais fisiológicos, incluindo a onda delta do EEG, HR, HRV e GSR, demonstrando uma correlação significativa com a CS.

Os equipamentos empregados consistiram em um fone de ouvido de realidade virtual HTC-Vive com resolução de 1080 x 1200 pixels por olho, um processador Intel Core i7 com 32 GB de memória RAM, uma placa gráfica Nvidia RTX 2070. A coleta de dados de resposta GSR foi realizada por meio de um sensor NeuLog GSR, sendo a unidade para dados GSR expressa em microsiemens. Já os dados de HR e BR, foram capturados

pelo sensor Zephyr OmniSense BioHarness-5.0 HR com o uso de uma cinta peitoral. Participaram do estudo um total de 31 estudantes universitários, dos quais apenas duas eram do sexo feminino. A média de idade dos participantes foi de 24,04 anos, com um desvio padrão de 2,75 anos.

Os resultados deste estudo, sugeriram que a maioria dos participantes obteve CS durante a experiência com a montanha-russa RV. Encontraram uma correlação significativa entre o *Fast Motion Sickness Scale* (FMS) relatado pelos participantes e os dados correspondentes de HR, GSR e HRV. Em todas as métricas de avaliação, o modelo CNN-LSTM teve um desempenho melhor do que os outros modelos testados. O modelo proposto pode detectar e prever a gravidade da CS, considerando apenas os últimos dois minutos de dados com uma precisão de 97,44% (atual) e 87,38% (futura a partir dos sinais fisiológicos).

3.3 IA Explicável na previsão de AVC usando EEG

A Inteligência Artificial (IA) está desempenhando um papel cada vez mais importante no campo da saúde. Entretanto, a falta de transparência nos modelos de IA torna difícil entender como eles tomam decisões. Por isso, muitos modelos são percebidos como "caixas pretas", pois não oferecem uma explicação para suas decisões. A *Explainable Artificial Intelligence* (XAI) é essencial para a ML aplicado à saúde, pois permite entender como os modelos de previsão de doenças chegam às suas conclusões. Isso é importante para garantir a confiabilidade dos modelos e para que os profissionais de saúde possam confiar nos resultados.

O trabalho de Islam [147], faz uso de modelos de ML para classificação de pacientes em dois grupos: aqueles com Acidente Vascular Cerebral (AVC) isquêmico e indivíduos saudáveis. O objetivo é antecipar a ocorrência de AVC agudo em pessoas saudáveis, usando características neurais de estados ativos, como caminhar, trabalhar e leitura cognitiva. Adicionalmente, ferramentas de *Explainable Artificial Intelligence* (XAI), como Eli5 e LIME, foram empregadas para esclarecer o funcionamento do modelo e identificar as características relevantes que influenciam as previsões de AVC. O estudo obteve biosinais de *Electroencephalogram* (EEG) três meses após o início dos sintomas de AVC isquêmico. Esses sinais fisiológicos foram registrados durante atividades cotidianas ativas, como caminhar, trabalhar e ler, por meio de eletrodos posicionados nas áreas corticais frontal, central, temporal e occipital (Fz, C1, T7, Oz).

Três modelos de ML foram utilizados: *Adaptive Gradient Boosting*, *XGBoost* e *LightGBM*. O modelo *Adaptive Gradient Boosting*, com aproximadamente 80% de precisão, demonstrou desempenho superior em todos os aspectos em comparação aos demais modelos. Com

base na análise de ML interpretável, o modelo Eli5 enfatizou a relevância das frequências das ondas delta, teta e gama nas áreas frontais e centrais, conferindo-lhes maior peso na classificação dos pacientes com AVC nos modelos de ML. Esses resultados sublinharam a significativa influência dessas características em todos os modelos de classificação empregados na pesquisa. No contexto da classificação dos pacientes com AVC, o modelo LIME destacou as características relacionadas às frequências delta e teta nas áreas frontais e centrais. Ambos os modelos interpretáveis, Eli5 e LIME, destacaram a importância das frequências das ondas delta e teta na tarefa de classificar os pacientes com AVC.

3.4 Análise da CS com Algoritmos Simbólico de ML

No trabalho de Porcino [12], no qual esta dissertação se fundamenta, é proposta uma nova análise experimental que utiliza Aprendizado de Máquina Simbólico para classificar as causas potenciais da CS em jogos de RV. A hipótese principal deste trabalho foi de que os modelos Simbólicos de ML, permitem a interpretação dos resultados de maneira compreensível e previsível. Uma vez que as causas do desconforto em uma experiência de RV foram identificadas, uma ou mais estratégias foram sugeridas para mitigar os sintomas da CS.

As causas foram estimadas e classificadas de acordo com seu impacto na tarefa de classificação de ML. Os experimentos foram conduzidos em dois jogos de Realidade Virtual (jogo de corrida e jogo de voo) e 6 protocolos experimentais, utilizando 37 amostras válidas de um total de 88 voluntários. Até o momento da pesquisa, o autor identificou alguns fatores dominantes que podem desencadear a CS, como rotação, velocidade, gênero e experiência prévia em RV. A abordagem proposta na pesquisa, leva em consideração até oito fatores atribuídos a CS, incluindo aceleração, tempo de exposição, taxa de quadros, idade, rotação, gênero, velocidade e experiência prévia em RV. O autor menciona ainda estudos anteriores que propuseram estratégias para lidar com quatro desses atributos, como tempo de exposição, aceleração, velocidade, taxa de quadros e rotação da câmera no eixo z [148, 74]. As causas do CS, como gênero, experiência em RV e idade, estão relacionadas ao perfil do usuário e ainda não possuem uma estratégia clara associada.

O estudo comparou os efeitos dos jogos de corrida e voo em relação ao desconforto na Realidade Virtual (RV). O tempo de exposição foi a causa mais frequente de desconforto. Os participantes relataram mais desconforto no jogo de corrida do que no de jogo de voo. No caso de jogos de corrida, uma possível sugestão para minimizar os efeitos da CS, é reduzir o tempo de exposição. Mudanças de aceleração controladas pelo usuário causaram menos desconforto no jogo de corrida, quando comparado ao jogo de voo, onde a aceleração não era controlada pelo usuário. A experiência anterior em RV também

influenciou no desconforto em ambos os jogos. Jogadores menos experientes são mais propensos a sentir desconforto. O estudo concluiu que diferentes causas de desconforto surgem com base em exposições de curto ou longo prazo à RV. Como comentário final, o trabalho sugere estratégias para mitigar a *Cybersickness* (CS).

Capítulo 4

Método e Experimentos

Neste capítulo, são apresentados os procedimentos adotados para condução dos experimentos realizados neste estudo, incluindo os biosinais e jogos utilizados, os métodos de coleta de dados por meio de questionários qualitativos, bem como os procedimentos para a obtenção de dados quantitativos. Também são apresentadas as análises dos dados coletados.

4.1 Softwares e Equipamentos

4.1.1 Realidade Virtual e HMD

Jogos de RV

Para uma análise mais abrangente, conforme apresentado na Figura 4.1, foram empregados dois jogos distintos de Realidade Virtual (RV): um Jogo de Corrida de Carro e um Jogo de Voo (implementados usando Unity 3D), desenvolvidos como parte do estudo conduzido por Porcino [12].




Figura 4.1: Jogo de Corrida de Carro à esquerda (a) e de Voo à direita (b) ([12]).

Ao iniciar o software do jogo, eram apresentadas duas opções: Jogo de Corrida de Carro e de Voo. Após a seleção do jogo desejado, era solicitado que o usuário preenchesse o formulário *Cybersickness Profile Questionnaire* (CSPQ). Imediatamente após completar o CSPQ, o usuário era convidado a responder o VRSQ-Pré. Em seguida, na tela, era exibida a imagem de um controle, juntamente com informações básicas sobre como controlar o jogo, além de instruções para o usuário colocar o dispositivo *Head-mounted Display* (HMD). Após a conclusão do jogo, o usuário recebia uma mensagem instruindo-o a remover os óculos HMD e a preencher o VRSQ-Pós. Por fim, o usuário era redirecionado para a tela inicial do Jogo.

Head-mounted Display

O *Head-mounted Display* (HMD) escolhido para os experimentos neste trabalho, foi um HTC Vive (2016), conforme ilustrado na Figura 4.2. Este headset requer conexão a um computador para processamento gráfico e alimentação, e oferece funcionalidades como, fones de ouvido integrados. As especificações detalhadas deste dispositivo podem ser encontradas na Tabela 4.1.



Figura 4.2: HMD HTC Vive.

Antes do experimento, o HMD era fixado na cabeça do participante, com atenção especial à centralização da tela e organização dos cabos. Durante a experiência, o HMD era monitorado para garantir a segurança e o conforto do participante.

4.1.2 Configurações de Hardware do Computador

O hardware do computador utilizado neste experimento foi capaz de executar com sucesso os seguintes aplicativos: os Jogos de RV (Unity 3D), SteamVR e o software de coleta de

Data de Lançamento	30 de Abril, 2016
Especificações do Headset	
Tela	Dual AMOLED de 3,6" na diagonal
Resolução	1080 x 1200 pixels por olho (2160 x 1200 pixels combinados)
Taxa de Atualização	90 Hz
Campo de Visão	110 graus
Recursos de Segurança	Limites da área de jogo do acompanhante e câmera frontal
Sensores	Rastreamento SteamVR, sensor G, giroscópio, proximidade
Conexões	HDMI, USB 2.0, fone de ouvido estéreo de 3,5 mm, alimentação, Bluetooth
Entrada	Microfone integrado
Alívio Ocular	Distância interpupilar e ajuste de distância da lente
Especificações do Controlador	
Sensores	Rastreamento SteamVR
Entrada	Trackpad multifuncional, botões Grip, gatilho de dois estágios, botão Sistema, botão Menu
Uso por Carga	Aprox. 6 horas
Conexões	Porta de carregamento micro-USB

Tabela 4.1: Especificações do Headset e Controlador.

biosinais (BC). As especificações técnicas do hardware estão disponíveis na Tabela 4.2.

Componente	Especificações
Processador	Intel(R) Core(TM) i7-7700HQ CPU @ 2.80Ghz
Memória	16GB
Gráfico	NVIDIA GeForce GTX 1050 Ti
Armazenamento	255GB SSD
Sistema Operacional	Windows 10 Pro Versão 22H2
Arquitetura	64-bit (x64)
Resolução do Monitor	1920 x 1080, 60,020 Hz

Tabela 4.2: Especificações do Computador.

4.1.3 Bitalino

Nesta dissertação, os biosinais foram coletados por meio do BITalino (conforme Figura 4.3), dispositivo amplamente utilizado em pesquisas científicas e aplicações relacionadas à saúde [149, 150]. O BITalino é um sistema modular e portátil que permite a aquisição precisa e não invasiva de sinais fisiológicos. É composto por sensores específicos para cada tipo de sinal, os quais podem ser conectados e configurados de maneira simples, de acordo com as necessidades do usuário. Ele possibilita a captura de diversos tipos de biosinais, incluindo *Electrocardiogram* (ECG), *Electromyography* (EMG), *Electroencephalogram* (EEG), *Electrogastrography* (EGG), *Accelerometer* (ACC) e outros.

A utilização do BITalino para a coleta de biosinais, apresenta vantagens significativas. Primeiramente, o dispositivo oferece uma solução acessível quando comparado a outros sistemas disponíveis no mercado, tornando-se uma opção viável para pesquisadores com recursos limitados. Além disso, o BITalino é compacto e portátil, permitindo que as medições sejam realizadas em ambientes diversos. Isso proporciona flexibilidade e a capacidade de obter dados fisiológicos em diferentes locais. As especificações técnicas da placa estão detalhadas na Tabela 4.3.




Figura 4.3: Placa e sensores BITalino.

Especificação	Valor
Taxa de amostragem	1, 10, 100 ou 1000Hz
Portas analógicas	4 in (10-bit) + 2 in (6-bit) + 1 auxiliary in (battery) + 1 out (8-bit)
Portas Digitais	2 in (1-bit) + 2 out (1-bit)
Comunicação	Bluetooth or BLE
Faixa	up to 10m (in line of sight)
Sensores	EMG; ECG; EDA; EEG; ACC; LUX; BTN
Atuadores	LED; BUZ; DAC
Tamanho	100x65x6mm
Bateria	500mA 3.7V LiPo (rech.)
Consumo	65mA
Acessórios	1x 3-lead cable; 1x 2-lead cable; 1x UC-E6 to UC-E6 sensor cable; 5x Electrodes; 1x ProtoBIT

Tabela 4.3: Especificações do BITalino (r)evolution Plugged.

Conexões dos Sensores à Placa Bitalino

A descrição detalhada das conexões dos sensores com a placa Bitalino pode ser encontrada no manual fornecido com o BITalino (r)evolution Plugged Kit BLE/BT. A Figura 4.4 é

dedicada a ilustrar as conexões específicas usadas na aquisição dos biosinais neste estudo.




Figura 4.4: Conexões dos sensores à Placa Bitalino: a) Sensor ECG ;b) Sensor EDA; c) Sensor ACC.

4.1.4 Biosignal Collector

O *Biosignal Collector* (BC), desenvolvido neste estudo, teve como propósito assegurar um controle mais eficiente na aquisição dos biosinais e permitir que os participantes dos experimentos relatassem os diferentes níveis possíveis de *Cybersickness* (CS). Uma das características significativas do BC, é a capacidade dos usuários relatarem os sintomas por meio de comandos de voz. O reconhecimento dos comandos segue a seguinte escala (em inglês), sendo: 0 (zero) para nenhum sintoma relacionado a CS; 1 (one) para moderado; 2 (two) para leve e 3 (three) para severo. Essa funcionalidade facilita a coleta e o registro dos sintomas de CS, tornando a experiência mais interativa e precisa.

Conforme apresentado nas Figuras 4.5 e 4.6, o BC é uma ferramenta que permite a coleta de dados por meio de comunicação TCP/IP com o software OpenSignals, que acompanha a placa Bitalino. O dados coletados do Bitalino, são em formato *JavaScript Object Notation* (JSON). É possível selecionar uma das três frequências disponíveis: 10Hz, 100Hz ou 1000Hz. Além disso, é também possível configurar quais canais serão ativados para a coleta de dados. Os canais disponíveis para conexão com o Bitalino variam de 1 a 6. Adicionalmente à seleção do canal, é possível ainda configurar o sensor correspondente a cada canal.

Uma das funcionalidades do *Biosignal Collector* (BC), é gerar um arquivo de saída em formato JSON, agrupado por sensor, que inclui o nível de *Cybersickness* (CS) informado

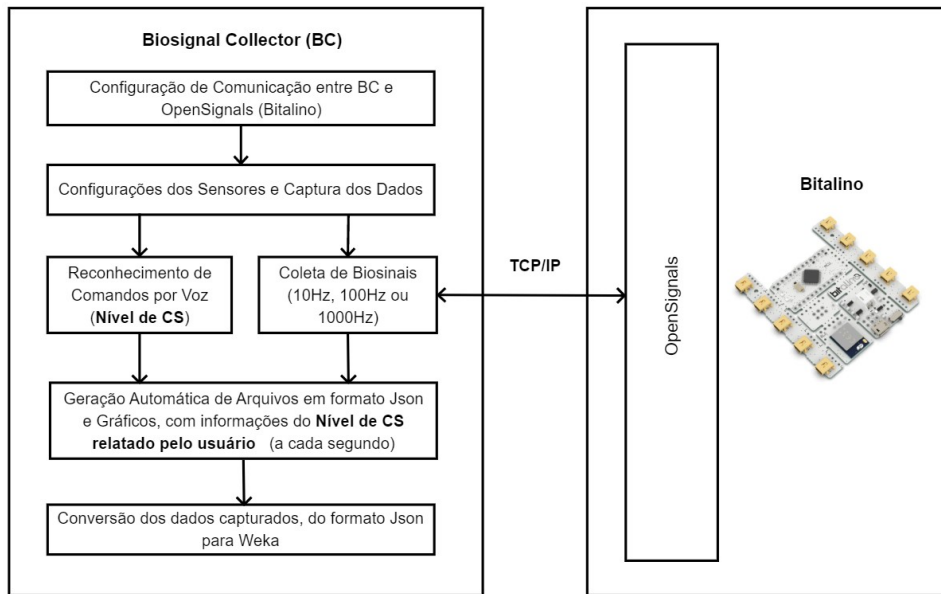


Figura 4.5: Arquitetura do BC.

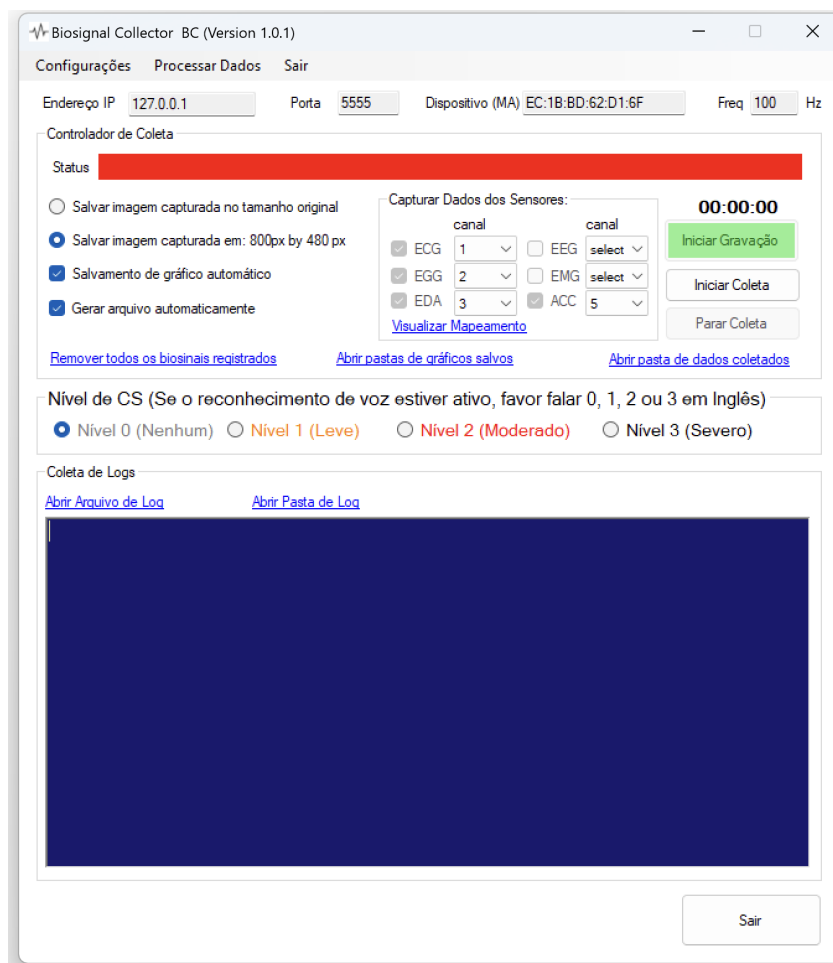


Figura 4.6: Tela Principal do BC.

pelo usuário. Além disso, a ferramenta oferece a opção de gerar, visualizar e capturar os gráficos de acordo com o tempo configurado, permitindo o salvamento em diretórios específicos, de acordo com o nível de CS informado durante os experimentos. Também é possível configurar as dimensões de saída dos gráficos, o que pode ser especialmente útil para o treinamento de modelos de *Convolutional Neural Networ* (CNN). Com o intuito de facilitar a análise e o pré-processamento dos dados capturados, o BC oferece a opção de converter os dados do formato JSON para o formato Weka.

A escolha estratégica para o desenvolvimento do *Biosignal Collector* (BC), foi utilizar a linguagem de programação C# em ambiente Windows Desktop. Esta é uma das principais linguagens de programação utilizadas atualmente [151], oferecendo uma ampla gama de recursos gráficos e funcionalidades. Essa escolha proporciona diversas vantagens, incluindo a criação de uma interface visual simples e intuitiva para os usuários da ferramenta. Ao aproveitar as características e recursos do C#, o BC oferece uma experiência amigável e eficiente para coleta e análise de biosinais.

4.2 Aquisição dos Dados Qualitativos e Dados do Jogo

Neste estudo, os dados qualitativos foram obtidos durante a interação com o software do jogo, conforme descrito na Seção 4.1.1. O questionário CSPQ, disponível no Apêndice A, abordava nove questões que tratavam de tópicos como gênero, idade, experiência, pré-sintomas, sensibilidade à cintilação, uso de óculos de grau, deficiências visuais, postura durante o jogo e olho dominante, conforme descrito por Porcino em seu trabalho de 2021 [12]. Já o questionário VRSQ, conforme apresentado no Apêndice B, consistia em nove itens que avaliavam aspectos como desconforto geral, fadiga, fadiga ocular, dificuldade de concentração, dor de cabeça, sensação de "cabeça pesada", visão embaçada, tontura e vertigem.

Durante todo o experimento, os dados do jogo foram registrados continuamente, capturando uma instância de dados a cada segundo, incluindo informações como velocidade, aceleração, rotações, região de interesse e outros, conforme detalhado na Tabela 4.7.

4.3 Biosinais

Neste trabalho de pesquisa, conforme já mencionado, foram empregados os biosinais: Eletrocardiograma (*Electrocardiogram* (ECG)), Atividade Eletrodérmica (*Electrodermal Activity* (EDA)) e Acelerômetro (*Accelerometer* (ACC)). Acredita-se que esses biosinais desempenhem um papel crucial na análise e entendimento dos efeitos da CS em indivíduos

expostos à Realidade Virtual (RV), o que contribui para uma melhor compreensão dos sintomas associados.

4.3.1 Eletrocardiograma

O Eletrocardiograma (ECG) é o registro da atividade elétrica gerada pelo coração na superfície corporal [93], sendo amplamente empregado na avaliação de doenças cardíacas e distúrbios do ritmo cardíaco. Esse registro fornece informações valiosas sobre a frequência cardíaca, ritmo e possíveis arritmias, possibilitando uma análise mais precisa dos efeitos da CS no sistema cardiovascular. Normalmente, a faixa de frequência cardíaca é de 60 a 100 batimentos por minuto (bpm), correspondendo a um intervalo RR de 1 a 0.6 segundos[34].

No cenário em questão, os dados de ECG foram originalmente amostrados a uma taxa de 100Hz, o que significa que 100 valores são registrados a cada segundo. No entanto, para atender aos requisitos específicos deste estudo e permitir a união dos dados de biosinais com os dados do jogo utilizado em nossos experimentos (implementado pelo Porcino [12]), foi necessário reduzir a taxa de amostragem para torná-la compatível com o padrão de coleta estabelecido no jogo, que é de uma amostra por segundo. Portanto, os dados foram reduzidos de 100Hz para 1Hz. Este procedimento será descrito na Seção 4.8.




Figura 4.7: Exemplo de um ECG com Intervalo RR em destaque.

A partir dos sinais de ECG, é possível calcular a Variabilidade da Frequência Cardíaca (VFC) e obter informações importantes sobre a atividade elétrica do coração. Neste estudo, o intervalo RR foi empregado como valor de entrada a cada segundo no conjunto de dados utilizado para o modelo de Machine Learning Simbólico. O intervalo RR (RR-I) é um parâmetro da VFC que representa o tempo decorrido entre dois batimentos cardíacos consecutivos. Ele é calculado medindo-se a distância entre os picos consecutivos do sinal

de ECG e representa a duração do ciclo cardíaco, conforme a Figura 4.7. É uma medida utilizada para avaliar a regularidade dos batimentos cardíacos e a variabilidade temporal entre eles. Um RR-I curto indica uma frequência cardíaca alta, enquanto um RR-I longo indica uma frequência cardíaca mais baixa.

4.3.2 Atividade Eletrodérmica

A *Cybersickness* (CS) pode desencadear respostas emocionais e psicológicas, resultando em alterações na atividade eletrodérmica. No trabalho realizado por Qu et al [34], os pesquisadores exploraram a relação entre os sintomas da CS e a atividade eletrodérmica. Eles descobriram que os indivíduos que apresentavam sintomas mais intensos de CS também exibiam um aumento na condutância da pele. Essa descoberta sugere que a resposta eletrodérmica pode ser um indicador útil para avaliar a gravidade da *Cybersickness* (CS) e seu impacto no organismo.




Figura 4.8: Exemplo EDA. Saída típica do sensor não filtrado (enquanto o usuário está em um estado relaxado). Adaptado [13].

A Atividade Eletrodérmica (EDA) refere-se à variação na condutância elétrica da pele em resposta a estímulos emocionais ou psicológicos. É uma medida fisiológica amplamente utilizada para avaliar a resposta do sistema nervoso autônomo. Ela pode ser registrada por meio da colocação de eletrodos na superfície da pele, especialmente em áreas onde a transpiração é mais intensa, como as palmas das mãos e dedos, ou a região planta dos pés. A Figura 4.8 mostra um exemplo típico de dados coletados durante um estado de relaxamento do usuário. A unidade de medida da EDA é microsiemens (μS) e normalmente o valor varia de 5 a 50 [34].

A fim de integrar os dados da EDA com os do jogo, a taxa de amostragem foi ajustada para 1Hz. Isso foi alcançado calculando a média dos valores coletados a 100Hz e, em seguida, registrando apenas um valor médio. Ao calcular a média dos valores em intervalos de um segundo, é possível manter informações pertinentes sobre esse biosinal.

4.3.3 Acelerômetro

Um Acelerômetro (ACC) é um dispositivo eletromecânico projetado para medir as forças de aceleração. Existem muitos tipos de acelerômetros desenvolvidos e relatados na literatura. Na década de 1990, os acelerômetros desenvolvidos a partir dos Microsistemas Eletromecânicos (*Microelectromechanical Systems* (MEMS)), revolucionaram a indústria de sistemas de airbags automotivos. Desde então, esses dispositivos possibilitaram a criação de recursos e aplicativos exclusivos, desde a proteção de discos rígidos em laptops até controladores de jogos [152]. Esses dispositivos, conhecidos como MEMS integrados inteligentes, englobam funções como aquisição de dados, filtragem, armazenamento e comunicação [153].

Para Bassett [154], um ACC é um dispositivo que registra as acelerações do tronco ou membros durante o movimento humano. Durante a exposição a ambientes virtuais, a ocorrência da CS pode estar associada a movimentos rápidos e bruscos. O ACC é capaz de capturar com precisão os deslocamentos e fornecer informações sobre o ângulo e a magnitude do movimento, permitindo a análise de como esses movimentos podem influenciar a sensação de desconforto. Acelerômetros podem ser medidos em duas unidades principais: força-g (g) e em metros por segundo ao quadrado (m/s^2) [155]. A Figura 4.9 apresenta um exemplo correspondente aos dados brutos típicos de um Acelerômetro, coletados especificamente a partir do eixo Z, obtidos com o BITalino (r) revolution, o mesmo equipamento utilizado em nossa pesquisa.

Para o biosinal ACC, seguimos o mesmo procedimento da EDA ao reduzir a frequência de amostragem de 100Hz para 1Hz. Adotamos o valor médio correspondente aos valores de aceleração em intervalos de 1 segundo. Devido a uma limitação técnica do sensor adquirido para este estudo, onde o ACC registra apenas os movimentos relacionados ao eixo Z, a média foi calculada com base nos valores de aceleração frontal dos movimentos do participante e incluída no dataset usado para treinamento e classificação do modelo.




Figura 4.9: Dados brutos típicos do ACC (Z) (adquiridos com o BI-Talino (r)evolution) realizando um burpee com flexão, começando e terminando em posição de pé, com o sensor colocado no peito[14].

4.4 Aquisição dos Biosinais

Fixação dos Eletrodos e Sensores nos Participantes

Conforme ilustrado na Figura 4.10, para a colocação dos eletrodos relacionados à derivação Einthoven do ECG, foram utilizados os eletrodos IN+ (vermelho) e IN- (preto) nas clavículas, e o eletrodo REF (branco) na crista ilíaca. Os eletrodos da EDA foram fixados nos dedos das mãos, enquanto o sensor do ACC foi posicionado na fúrcula supraesternal do participante com o auxílio de uma fita adesiva.

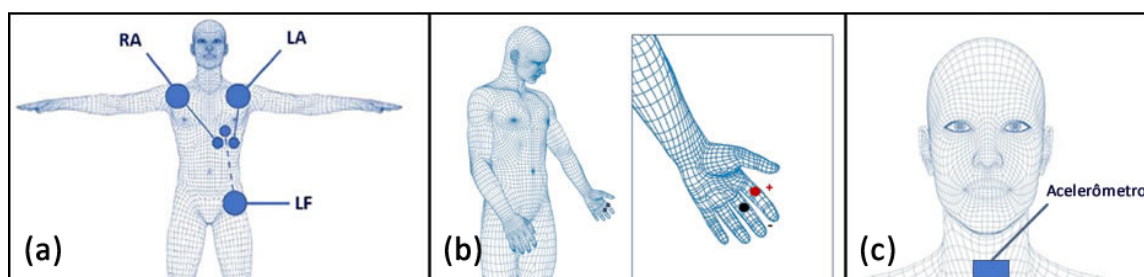


Figura 4.10: a) Colocação dos Eletrodos (ECG) [15]; b) Fixação dos eletrodos EDA nos dedos da mão [13]; c) ACC localizado na fúrcula supraesternal do usuário.

O uso do BC

Após a fixação dos sensores/eletrodos nos participantes, o administrador do experimento iniciava a coleta dos biosinais por meio do software *Biosignal Collector* (BC), acionando o botão "Iniciar Coleta", conforme Figura 4.6. Após verificar que as coletas estavam

ocorrendo de forma satisfatória e que o participante estava pronto para iniciar o jogo, o administrador então acionava o botão "Iniciar Gravação", dando início à gravação dos dados em sincronia com a atividade do jogo. Além disso, um cronômetro era apresentado na tela do BC, permitindo que o responsável pelos experimentos monitorasse o tempo da experiência do usuário. Para terminar o processo de coleta, o botão "Parar Coleta" era acionado.

4.5 Participantes

Os critérios de seleção adotados neste experimento, visam garantir a segurança dos participantes, excluindo indivíduos com condições de saúde graves, como distúrbios vestibulares severos e problemas extremos de equilíbrio, que são suscetíveis à CS extrema.

4.5.1 Recrutamento

O recrutamento dos participantes, envolveu o uso de métodos de divulgação, incluindo o envio de mensagens para grupos de WhatsApp e abordagens individuais. Como era esperado, a maioria dos participantes eram estudantes da Universidade de Brasília (UnB), uma vez que a divulgação estava principalmente direcionada a esse público.

4.6 Procedimento Experimental

Para a condução deste experimento, a participação de todos os voluntários foi obtida mediante consentimento explícito. Todos os participantes demonstraram seu acordo e comprometimento com a pesquisa, concordando com a participação anônima no estudo e formalizando esse consentimento através da assinatura do formulário correspondente, disponível no Apêndice C.

4.6.1 Antes da Sessão

Ao chegar ao laboratório, foi disponibilizado um intervalo de tempo para que o participante pudesse ler o termo de consentimento e receber as instruções básicas para a realização do experimento. Essas orientações compreendiam informações fundamentais sobre o jogo, a maneira confortável de se sentar e a recomendação de evitar conversas durante a experiência, a menos que estivesse se sentindo mal e precisasse interrompê-la. Os participantes receberam orientações para descrever seu estado atual em relação às condições de repouso, utilizando a seguinte escala (em inglês): 0 (zero) para ausência de sintomas relacionados ao CS; 1 (one) para sintomas moderados; 2 (two) para sintomas

leves e 3 (three) para sintomas severos. Além disso, nesse momento, procedeu-se à fixação do *Head-mounted Display* (HMD) e dos eletrodos/sensores no participante.

4.6.2 Durante a Sessão

Para não sacrificar tanto o usuário durante a experiência, considerando não apenas os dispositivos de RV, mas também os eletrodos em seu corpo, em vez dos intervalos de 5 e 20 minutos propostos pelo Porcino [12], optamos por uma exposição de 10 minutos. Destes, 5 minutos são dedicados à linha de base e os outros 5 minutos à experiência com o Jogo de Realidade Virtual. Pode-se acrescentar ao tempo total, um período de 2 a 3 minutos para a conclusão dos questionários.

A Figura 4.11 mostra o fluxo sequencial do experimento em quatro fases distintas, proporcionando uma visão geral das etapas seguidas pelos participantes.



Figura 4.11: Fluxo do Experimento.

1. Inicialmente, foi realizado um período de coleta de cinco minutos de sinais fisiológicos durante a fase de repouso, antes de iniciar qualquer interação por parte do usuário com o ambiente de Realidade Virtual (RV);
2. Em seguida, os participantes preencheram suas informações de perfil, por meio do CSPQ e o questionário VRSQ-Pré (antes da experiência);
3. Enquanto os participantes jogavam o jogo por 5 minutos, a coleta de dados do jogo e dos biosinais estava em andamento. As avaliações verbais dos sintomas relacionados a CS foram registradas continuamente ao longo de toda a experiência do usuário;
4. Após a realização do jogo de RV, os participantes foram solicitados a preencher o questionário VRSQ-Pós (após a experiência).

4.6.3 Após a Sessão

Após a experiência ser concluída, os voluntários foram auxiliados na remoção do equipamento. Em seguida, foram inquiridos sobre seu bem-estar. Após o término do experimento, os dados coletados foram verificados e transferidos para um pendrive. O

equipamento foi então higienizado com lenços umedecidos e, se preciso, os cabos foram desembaraçados.

4.7 Dados Coletados

Conforme apresentado na Tabela 4.4, este estudo contou com a participação de 17 indivíduos, divididos entre dois jogos, sendo 8 participantes no jogo de carro e 9 no jogo de voo. Dentro dessa amostra, observa-se a presença de 8 participantes do sexo feminino e 9 do sexo masculino. A faixa etária desses participantes varia entre 18 a 50 anos.

Jogo	Gênero	Faixa Etária	Exposição Prevista (min)	Participantes
Carro	Feminino	37 a 50	5	2
Carro	Feminino	18 a 36	5	2
Carro	Masculino	18 a 36	5	4
Voo	Masculino	18 a 36	5	5
Voo	Feminino	18 a 36	5	4
Total				17

Tabela 4.4: Experimentos realizados e características dos dados coletados.

Devido a problemas ocorridos durante os experimentos, especificamente relacionadas à conectividade bluetooth entre a placa Bitalino e o computador no qual o software Open-Signals estava instalado, os dados dos participantes 2 e 4 precisaram ser desconsiderados, uma vez que não foi possível assegurar a sincronização adequada entre os dados de coleta dos biosinais e os dados do jogo, assim como os relatos dos usuários sobre os seus níveis de desconforto. Além disso, embora tenha pontuado no VRSQ, o usuário 6 não relatou nenhum nível de desconforto durante o experimento, e por isso foi excluído das análises. As tabelas 4.5 e 4.6 apresentam uma visão geral dos dados válidos obtidos nos experimentos realizados neste trabalho. No decorrer da nossa pesquisa, temos o interesse em examinar os dados dos participantes cuja pontuação total no VRSQ foi superior a zero. Dessa maneira, os participantes 8, 12, 15 e 16 não foram incluídos como válidos.

Durante os experimentos, coletamos uma nova instância a cada segundo para obter dados tanto dos jogos quanto dos biosinais. Isso resultou em um total de 2309 instâncias para o jogo de carro e 2408 para o jogo de voo, conforme detalhado nas Tabelas 4.5 e 4.6.

Estrutura dos Dados Obtidos por meio dos Jogos

A Tabela 4.7 exhibe a organização dos dados coletados durante os experimentos nos jogos de carro e de voo. A primeira seção da tabela, apresenta os atributos relacionados aos dados do jogo, enquanto a segunda seção mostra os atributos relacionados aos dados dos usuários (coletados por meio do formulário CSPQ).

	Usuário	Gênero	Instâncias	Exposição (min)	VRSQ (Total)
✓	3	Feminino	260	4.33	25.80
✓	5	Feminino	270	4.50	37.50
	6	Masculino	303	5.05	7.50
	8	Masculino	302	5.03	0.00
✓	9	Masculino	270	4.50	65.00
✓	11	Feminino	300	5.0	31.70
✓	13	Masculino	302	5.03	40.00
	16	Feminino	302	5.03	0.00
Total			2309	38.47	207.50

✓Dados válidos

Tabela 4.5: Dados válidos coletados para Jogo de Carro, destinados as análises que incluem informações de autorrelatos e biosinais.

	Usuário	Gênero	Instâncias	Exposição (min)	VRSQ (Total)
✓	1	Masculino	280	4.67	17.50
	2	Feminino	220	3.67	70.00
	4	Masculino	140	2.33	7.50
✓	7	Masculino	302	5.03	20.00
✓	10	Feminino	302	5.03	63.33
	12	Feminino	300	5.00	0.00
✓	14	Feminino	302	5.03	7.50
	15	Masculino	260	4.33	0.00
✓	17	Masculino	302	5.03	15.00
Total			2408	40.12	200.83

✓Dados válidos

Tabela 4.6: Dados válidos coletados para Jogo de Voo, destinados as análises que incluem informações de autorrelatos e biosinais.

Dados de Jogos		Dados de Usuários	
Recurso	Tipo	Recurso	Tipo
TimeStamp	N	Gênero	C
Velocidade	N	Idade	C
Aceleração	N	Experiência de RV	C
Rotação (x, y e z)	N	Sensibilidade ao Flicker	C
Posição (x, y e z)	N	Pré-sintomas	C
Região de Interesse	N	Usa Óculos	C
Tamanho do FoV	N	Deficiências Visuais	C
Taxa de Quadros	N	Postura	C
Quadro Estático	C	Olho Dominante	C
Feedback Tátil	C	Nível de desconforto	N
Grau de Controle	C		
Simulação DoF	C		
Locomoção do Jogador	C		
Câmera Automática	C		

Tabela 4.7: Atributos dos dados coletados através dos jogos durante a imersão do usuário no experimento. Tipos: Numérico (N) e Categórico (C).

Estrutura dos Dados Obtidos por meio do BC

A estrutura resultante da aquisição de biosinais por meio da ferramenta *Biosignal Collector* (BC) é detalhada na Tabela 4.8. Cada instância de dados coletados, está vinculado a um valor do atributo *TimeStamp*. O atributo *LevelCS*, refere-se ao nível de CS expresso verbalmente pelo usuário durante a atividade do jogo. Por fim, os atributos ECG, EDA e ACC representam os dados obtidos dos sensores correspondentes.

		Valores dos Biosinais		
TimeStamp	LevelCS	ECG	EDA	ACC
N	N	L	L	L

Tabela 4.8: Estrutura dos biosinais coletados. Atributos Numérico (N) e Lista (L).

A Lista 4.1, apresenta exemplos de dados brutos de biosinais coletados durante uma atividade do Jogo. Cada entrada nesta lista corresponde a uma instância de dados capturados em um determinado momento durante o experimento.

Lista 4.1: Exemplo de Dados Brutos coletados pelo BC em Formato JSON

```
1 [{"TimeStamp": 0, "LevelCS": 0, "ECG": [0.097, 0.105, 0.108, 0.064, 0.044,
0.035, 0.009, -0.009, -0.041, -0.056, -0.05, -0.067, -0.073, -0.056,
-0.038], "EDA": [21.09, 21.09, 21.09, 21.09, 21.09, 21.09, 21.09,
21.09, 21.09, 21.09, 21.09, 21.09, 21.07, 21.07, 21.07], "ACC":
[-0.663, -0.654, -0.654, -0.663, -0.654, -0.654, -0.644, -0.663,
-0.663, -0.654, -0.644, -0.663, -0.663, -0.663, -0.663]}],
```

```
2 ...
3 {"TimeStamp": 301.497,"LevelCS": 2,"ECG": [-0.085, -0.1, -0.103, -0.1,
    -0.103, -0.088, -0.079, -0.062, -0.05, -0.032, -0.032, -0.035,
    -0.035, -0.023, -0.029],"EDA": [24.68, 24.68, 24.68, 24.68, 24.71,
    24.71, 24.71, 24.71, 24.73, 24.73, 24.73, 24.73, 24.73, 24.76,
    24.76],"ACC": [-0.615, -0.625, -0.606, -0.615, -0.606, -0.625,
    -0.615, -0.606, -0.606, -0.625, -0.625, -0.587, -0.615, -0.625,
    -0.615]}}
```

4.8 Pré-processamento de Dados

No processo de coleta de dados, é frequente deparar-se com ruídos e anomalias que podem afetar a precisão da análise. Essas interferências podem resultar em interpretações errôneas por parte dos pesquisadores, comprometendo a exatidão dos resultados. Nesse cenário, o pré-processamento desempenha um papel crucial na análise [95], pois visa diminuir esses ruídos e anomalias, permitindo uma identificação mais precisa dos sintomas relacionados à CS.

Os sinais fisiológicos brutos, foram coletados a uma amostragem de 100Hz e passaram por um processo de pré-processamento, utilizando algoritmos desenvolvidos em Python, especificamente para esta etapa. Esses algoritmos foram desenvolvidos para auxiliar na inspeção visual dos biosinais e, em alguns casos, em especial para o ECG, foram aplicados filtros, como passa-baixa, passa-alta e mediana.

Para cada sinal fisiológico, quando foram identificadas grandes anomalias no sinal bruto, como picos de ruído ou falhas do equipamento, que foram consideradas pontos atípicos, foi adotada uma abordagem de interpolação de valores, conforme [48]. Isso significa que os dados defeituosos nos biosinais correspondentes, foram substituídos para corrigir essas anomalias e garantir a integridade e confiabilidade dos dados fisiológicos. A técnica de interpolação, teve por objetivo preencher as lacunas causadas pelas anomalias e restaurar a continuidade dos sinais, para que fosse possível obter uma representação mais completa e precisa das informações fisiológicas coletadas.


Nesta fase, realizamos a integração dos dados de biosinais capturados com as informações coletadas relacionadas aos dados do perfil do usuário e do jogo. Especificamente para o ECG, o processo de redução da amostragem de 100Hz para 1Hz foi realizado conforme descrito na Figura 4.12 e a seguir.

Inicialmente, geramos uma lista contendo todos os valores de ECG capturados para um usuário específico. Em seguida, dividimos esta lista em sublistas de 1000 valores de ECG, cada um correspondendo a 10 segundos de experiência do usuário. Para cada sublista de 1000Hz (10s), implementamos uma função para extrair exatamente 10 intervalos RR. Se


houver mais de 10 intervalos RR, a função extrairá apenas os primeiros 10 valores. Se não for possível identificar 10 intervalos na sublista, seja devido a razões como bradicardia do usuário (baixa frequência cardíaca) ou problemas no sinal capturado, repetimos o último intervalo RR encontrado. Essa estratégia assegura que a função sempre retorne uma lista com 10 valores, permitindo, dessa forma, a redução da taxa de amostragem de 100Hz para 1Hz. Cada intervalo RR extraído é então adicionado a uma lista global destinada ao usuário em questão. Após obtermos a lista completa de intervalos RR, incluímos a tag ECG com o valor RR-I obtido dentro do arquivo de dados do jogo, relacionando-os a cada instância (segundo) coletada durante a experiência do usuário.

Após a redução das taxas de amostragem de 100Hz para 1Hz, os atributos ACC e EDA, também foram incorporadas aos arquivos de coleta do jogo, conforme a Tabela 4.9.


Lista contendo todos os valores de ECG de um usuário (amostrados a **100 Hz**).



A partir da lista anterior contendo milhares de valores de ECG, geramos diversas sublistas. Cada sublista possui um conjunto de **1000** valores.



Para cada 1000 valores de ECG, extraímos **10 RR-I** e os incorporamos a uma lista global de Intervalos RR destinada ao usuário em questão.



Cada **Intervalo RR** é associado a um (TimeStamp) do conjunto de dados coletados do jogo.

TimeStamp	...	RotationX	RotationY	RotationZ	...	DiscomfortLevel	ECG	EDA	ACC
0.9990627	...	-0.006232809	0.9997309	-0.0004588771	...	0	0.53	18.62	1.06
2.00458	...	-0.006232809	0.9997309	-0.0004588771	...	0	0.69	18.62	1.05

Figura 4.12: Procedimento sobre como associar os intervalos RR às instâncias do experimento para um usuário específico.

Dados de Jogos		Dados de Usuários		Dados de Biosinais	
Recurso	Tipo	Recurso	Tipo	Recurso	Tipo
Time Stamp	N	Gênero	C	ECG	N
Velocidade	N	Idade	C	ACC	N
Aceleração	N	Experiência de RV	C	EDA	N
Rotação (X, Y e Z)	N	<i>Flicker</i>	C		
Posição (X, Y e Z)	N	Pré-sintomas	C		
Região de interesse	N	Usa Óculos	C		
Tamanho do FOV	N	Deficiências visuais	C		
Taxa de Quadros	N	Postura	C		
Quadro Estático	C	Olho Dominante	C		
Feedback Tátil	C	Nível de desconforto	N		
Grau de Controle	C				
Simulação DoF	C				
Locomoção do Jogador	C				
Câmera Automática	C				

Tabela 4.9: Atributos com os biosinais incluídos, coletados durante a imersão do usuário no experimento. Tipos: Numérico (N) e Categórico (C).

4.9 Análises de Dados

4.9.1 Pontuações do VRSQ

As pontuações do *Virtual Reality Sickness Questionnaire* (VRSQ), apresentadas nas Figuras 4.13 e 4.14, e também presentes nas Tabelas 4.5 e 4.6, foram extraídas dos valores calculados de acordo com a Tabela 4.10 [156].

Os casos em que os resultados do VRSQ foram registrados como zero, podem ser atribuídos a duas razões distintas: a) o participante não relatou nenhum tipo de desconforto durante a realização do experimento; b) o participante preencheu o questionário de forma descuidada ou sem a devida atenção.

Analisando os dados da Tabela 4.11, nota-se que para o Jogo de Carro, os usuários do sexo masculino apresentaram um nível de desconforto maior em comparação com os do sexo feminino. Por outro lado, para o Jogo de Voo, ao examinar os resultados da Tabela 4.12, percebe-se que o gênero feminino registrou uma pontuação geral maior no VRSQ, sugerindo uma maior incidência de sintomas de *Cybersickness*. Além disso, ao comparar as categorias Oculomotor e Desorientação, constata-se que a categoria Oculomotor apresentou uma média de pontuação ligeiramente superior à categoria Desorientação.

Sintoma VRSQ	Oculomotor (O)	Desorientação (D)
Mal-estar generalizado	X	
Cansaço	X	
Vista cansada	X	
Dificuldade de manter o foco	X	
Dor de cabeça		X
"Cabeça Pesada"		X
Visão embaçada		X
Tontura com olhos fechados		X
Vertigem		X
Total	[1]	[2]

Resultado

$$O = [1] / 0.12$$

$$D = [2] / 0.15$$

$$\text{Total} = (O + D)/2$$

Tabela 4.10: *Virtual Reality Sickness Questionnaire (VRSQ)*.

Usuário	Sexo	Oculomotor	Desorientação	Total
3	F	25.00	26.67	25.83
5	F	41.67	33.33	37.50
11	F	16.67	46.67	31.67
Média (Feminino)		27.78	35.56	31.67
6	M	8.33	6.67	7.50
9	M	83.33	46.67	65.00
13	M	33.33	46.67	40.00
Média (Masculino)		41.67	33.33	37.50
Média Total		34.72	34.44	34.58

Tabela 4.11: VRSQ - Jogo de Carro.

Usuário	Sexo	Oculomotor	Desorientação	Total
2	F	66.67	73.33	70.00
10	F	66.67	60.00	63.33
14	F	8.33	6.67	7.50
Média (Feminino)		47.22	46.67	46.94
1	M	8.33	26.67	17.50
4	M	8.33	6.67	7.5
7	M	33.33	6.67	20.00
17	M	16.67	13.33	15.00
Média (Masculino)		16.67	13.34	15.00
Média Total		29.76	27.62	28.69

Tabela 4.12: VRSQ - Jogo de Voo.

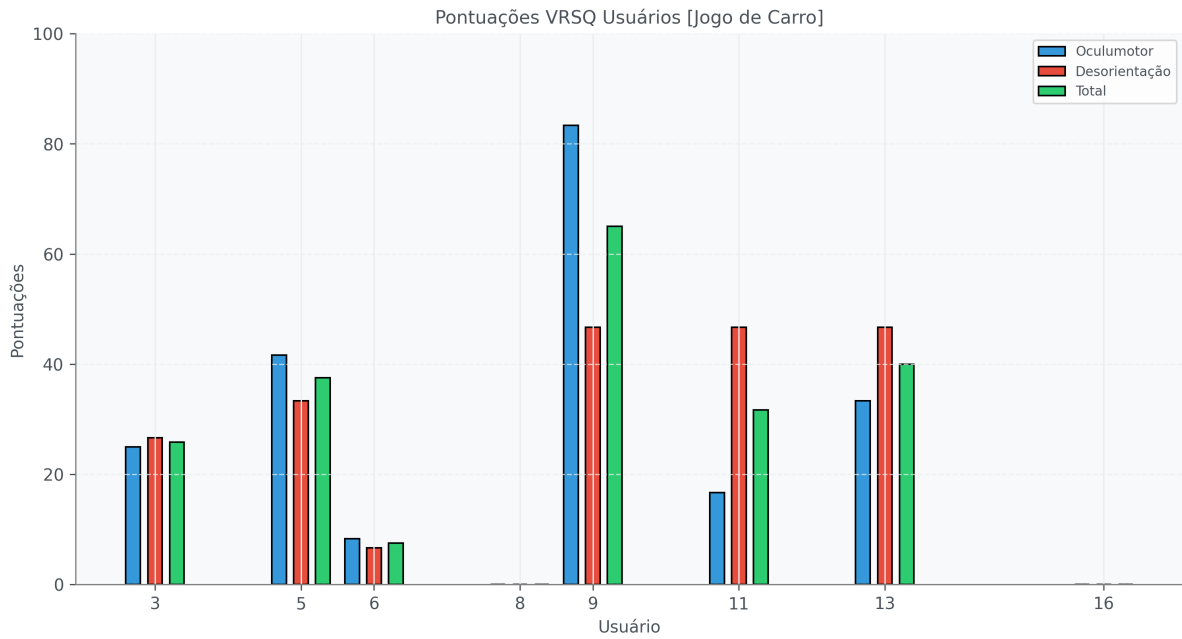


Figura 4.13: Resultados das Pontuações VRSQ obtidas do Jogo de Carro.

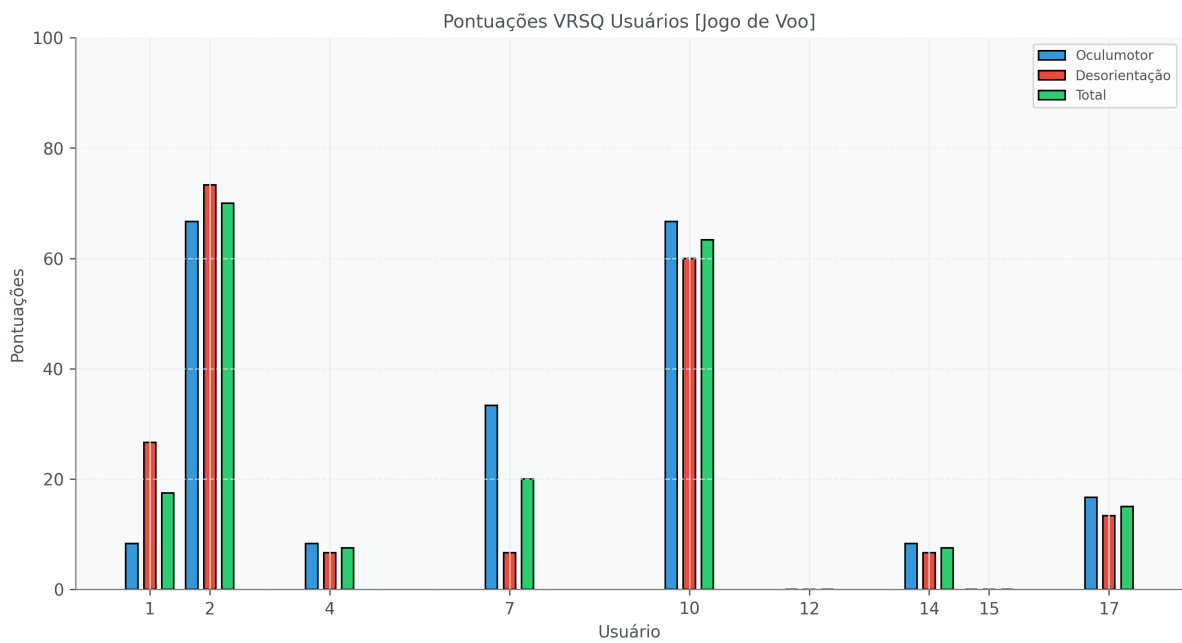


Figura 4.14: Resultados das Pontuações VRSQ obtidas do Jogo de Voo.

4.9.2 Análise dos Níveis de Desconforto dos Usuários

Examinamos os níveis de desconforto relatados por cada participante durante os experimentos. Além disso, apresentamos os percentuais baseado no gênero, agrupados pelos diferentes graus de CS. Por último, fornecemos o percentual geral dos níveis de CS reportados, juntamente com os percentuais em que os participantes não indicaram nenhum nível de *Cybersickness*.

Autorrelatos para o Jogo de Carro

A Figura 4.15, exibe o percentual por nível de desconforto, relatado por cada participante durante o experimento com o Jogo de Carro.

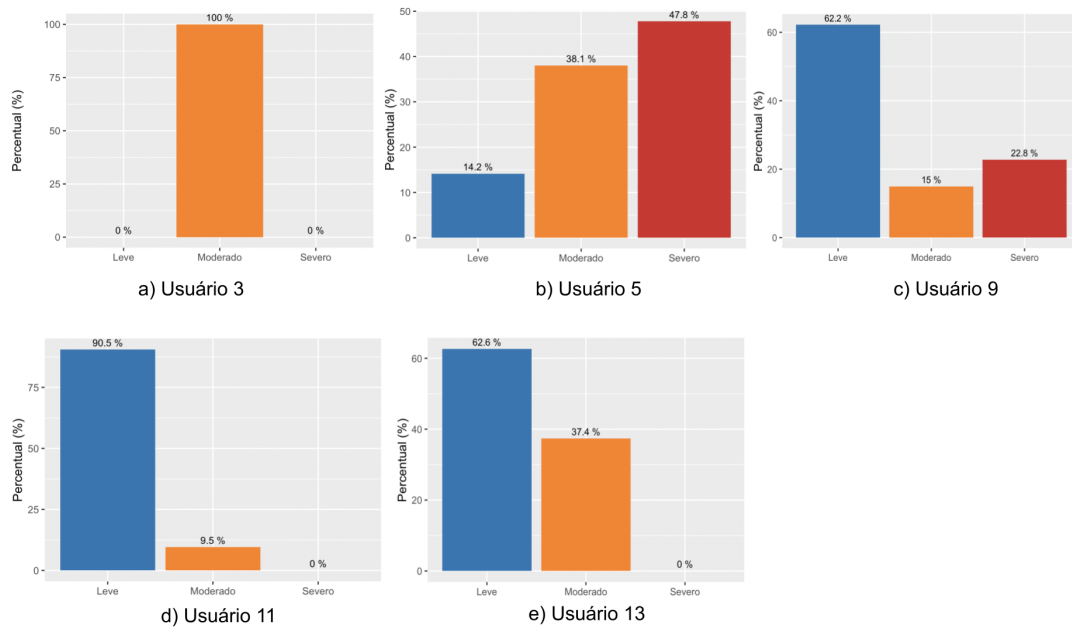


Figura 4.15: Percentual de tempo que cada participante vivenciou com desconforto Leve, Moderado e Severo no Jogo de Carro.

Conforme apresentado na Tabela 4.13, observa-se que os participantes do sexo masculino relataram uma maior incidência de sintomas de CS, em comparação com os do sexo feminino. Esses resultados estão alinhados com a análise das médias das pontuações do VRSQ por gênero da seção anterior. Nossos achados também corroboram as descobertas de Porcino [12], cujo estudo também indicou que os participantes do sexo masculino, relataram maior desconforto em relação aos do sexo feminino, durante o jogo de corrida. Nossos resultados contradizem a literatura, que sugere que as mulheres são mais suscetíveis a apresentar sintomas de CS, em comparação aos homens, já que elas não possuem a mesma percepção espacial [22, 16, 54].

Com um nível de significância de 0.05, o teste de Fisher realizado para os totais relatados (Tabela 4.13), resultou em um **valor-p < 0.0001**, o que nos conduz a rejeitar a hipótese nula. Dessa forma, para este cenário, podemos concluir que existe uma associação significativa entre as variáveis sexo e nível de desconforto.

Sexo	Nível de CS	Total Relatado	%
Feminino	Leve	171	54.98
	Moderado	76	24.44
	Severo	64	20.58
Total		311	
Masculino	Leve	218	62.46
	Moderado	102	29.23
	Severo	29	8.31
Total		349	

Tabela 4.13: Totais e percentuais dos níveis de CS relatados por gênero (Jogo de Carro).

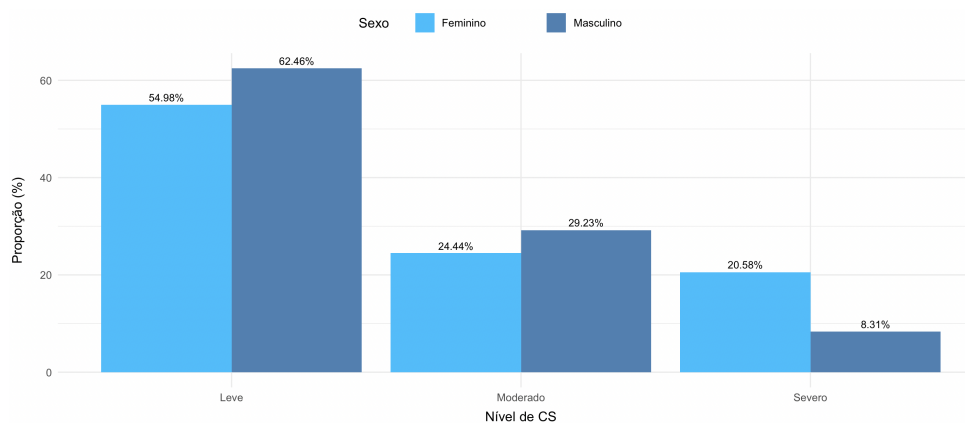


Figura 4.16: Percentuais dos Níveis de Desconforto relatados pelos usuários para o Jogo de Carro, agrupados por Sexo.

Examinamos a proporção geral dos níveis de sintomas relatados durante o Jogo de Carro. Conforme evidenciado na Tabela 4.14 e na Figura 4.17, durante 53.2% do tempo de experiência, os usuários não relataram nenhum desconforto. Enquanto 27.6% do tempo, houve relatos de sintomas *Leves*, e respectivamente 12.6% e 6.6% para *Moderado* e *Severo*.

Nenhum	Leve	Moderado	Severo
53.2%	27.6%	12.6%	6.6%

Tabela 4.14: Percentuais dos níveis de CS relatados durante o Jogo de Carro, incluindo aqueles sem sintomas.




Figura 4.17: Percentuais dos níveis de CS relatados durante o Jogo de Carro, incluindo aqueles sem sintomas.

Autorrelatos para o Jogo de Voo

Também analisamos os experimentos com o Jogo de Voo. A distribuição percentual dos diversos níveis de desconforto relatados pelos participantes, é mostrada na Figura 4.18. Além disso, são apresentados na Figura 4.19, os percentuais de cada nível de desconforto por gênero. No jogo em questão, nenhum participante do sexo masculino relatou o nível mais severo de sintomas.

No entanto, devido à falta de um número suficiente e equilibrado de participantes com dados válidos por sexo, não foi viável realizar uma análise para determinar qual gênero relatou uma incidência maior de CS. Consequentemente, essa análise foi limitada ao Jogo de Carro.

Sexo	Nível de CS	Total Relatado	%
Feminino	Leve	296	65.78
	Moderado	97	21.56
	Severo	57	12.67
Masculino	Leve	596	89.22
	Moderado	72	10.78
	Severo	0	0.00

Tabela 4.15: Totais dos níveis de CS relatados por gênero (Jogo de Voo).

Por último, examinamos também a proporção geral dos níveis de sintomas relatados para os experimentos neste jogo. Conforme a Tabela 4.16 e Figura 4.20, durante a maior parte do experimento, os usuários relataram ter experimentado algum sintoma de CS. O nível *Leve* teve o maior percentual registrado, alcançando 59.1%, enquanto os níveis *Moderado* e *Severo* foram relatados, respectivamente, em 11.2% e 3.8% do período analisado. Apenas 25.9% do tempo de jogo foi caracterizado pela ausência de desconforto.

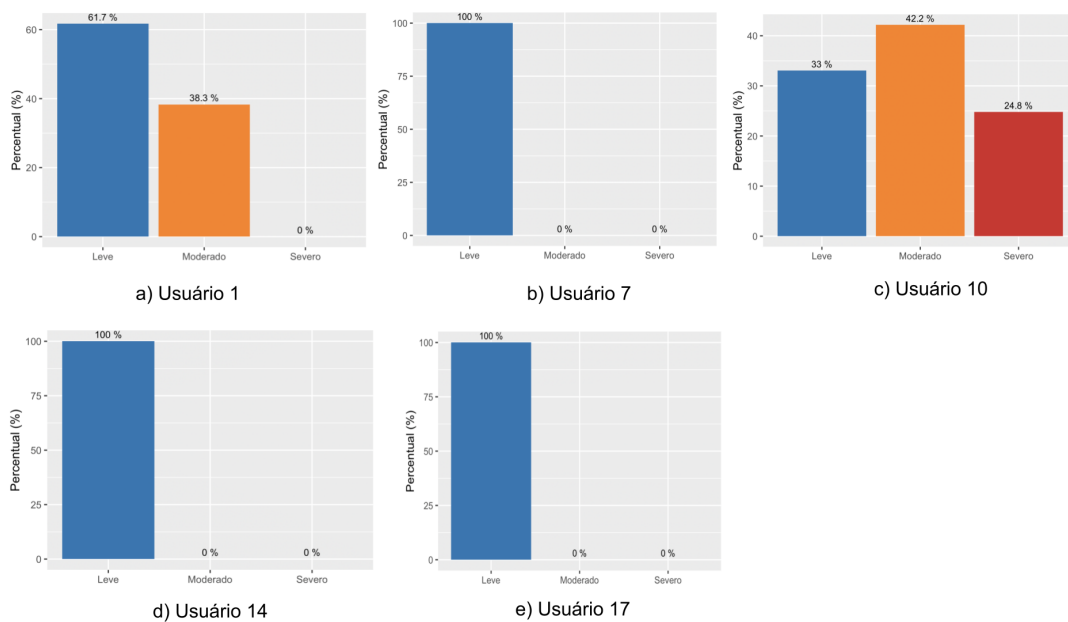


Figura 4.18: Percentual de tempo que cada participante vivenciou com desconforto Leve, Moderado e Severo no Jogo de Voo.

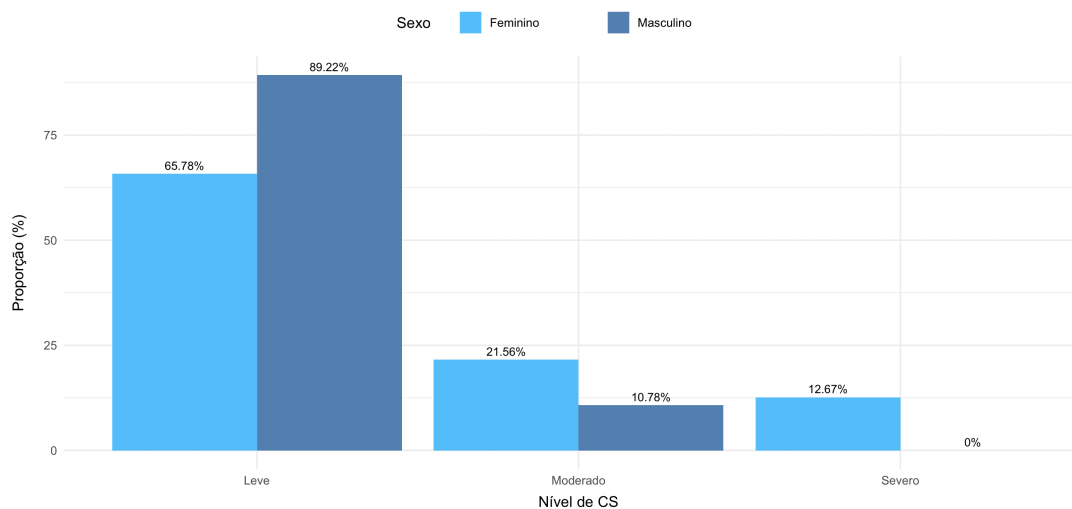


Figura 4.19: Percentuais dos Níveis de Desconforto relatados pelos usuários, para o Jogo de Voo, agrupados por sexo.

Nenhum	Leve	Moderado	Severo
25.9%	59.1%	11.2%	3.8%

Tabela 4.16: Percentuais dos níveis de CS relatados durante o Jogo de Voo, incluindo aqueles sem sintomas.




Figura 4.20: Percentuais dos níveis de CS relatados durante o Jogo de Voo, incluindo aqueles sem sintomas.

4.9.3 Alterações Fisiológicas (Repouso VS *Cybersickness*)

Como mencionado anteriormente, durante a sessão experimental, coletamos dados de biosinais dos usuários em repouso (linha de base) e durante a atividade do jogo. Nosso objetivo agora, é analisar as alterações fisiológicas dos usuários durante a imersão no jogo, em comparação com os dados da linha de base. É importante salientar que, as análises desta seção, foram conduzidas comparando os dados de repouso com os dados durante o jogo, especialmente quando o usuário relatou algum nível de desconforto. Calculamos as médias e desvios padrão, além dos testes-t de amostras pareadas. O teste-t é uma ferramenta estatística comumente utilizada para comparar as médias de dois grupos distintos e destaca-se como uma das técnicas mais prevalentes na literatura científica [157].

Análise do Jogo de Carro

Para o Jogo de Carro, conforme a Tabela 4.17 e as Figuras 4.21, 4.22 e 4.23, os resultados revelaram um aumento médio nos movimentos corporais (eixo Z) dos jogadores durante o jogo (com sintomas de CS) em comparação com os dados coletados na linha de base. Este aumento pode ser explicado pela "Teoria da Instabilidade Postural"[16], juntamente com os movimentos realizados pelo usuário durante jogo, especialmente para manter o carro na pista. Além disso, observou-se um aumento médio significativo na Atividade Eletrodérmica (EDA) durante o jogo, o que está em concordância com o estudo de Islam [28], o qual sugere que a EDA é um dos principais indicadores de CS. Em relação ao Eletrocardiograma (ECG), especificamente no que diz respeito aos intervalos RRs, houve uma redução na média em comparação com os dados coletados durante o repouso. O intervalo RR representa o período de tempo entre duas ondas R consecutivas, ou seja, o

intervalo entre dois batimentos cardíacos. Portanto, durante os sintomas de CS, os usuários apresentaram uma frequência cardíaca mais elevada, o que confirma as descobertas do estudo realizado por Tian et al. [158].

Os testes-t conduzidos para o Jogo de Carro, indicaram uma diferença estatisticamente significativa entre as médias das duas amostras, evidenciada pelo alto valor de t e pelo valor-p muito baixo (< 0.001). Com um Intervalo de Confiança (IC) de 95%, nenhum dos conjuntos de biosinais analisados contém o valor zero, o que refuta a hipótese nula de que não há diferença entre as médias das duas amostras. Com base nesta análise, podemos concluir que existem indícios de uma relação direta entre os sintomas de *Cybersickness* e as alterações nos sinais fisiológicos monitorados.

Biosinal	Médias e Desvios Padrão		testes-t			
	Linha de Base	Com CS	df	valor-t	valor-p	IC
ACC	0.593 (0.097)	0.650 (0.075)	255	7.6402	< 0.001	0.043 a 0.073
EDA	13.731 (7.876)	16.789 (5.926)	255	13.474	< 0.001	2.611 a 3.505
ECG (Intervalo RR)	0.751 (0.120)	0.689 (0.210)	255	-5.8058	< 0.001	-0.083 a -0.041

Tabela 4.17: Médias, desvios padrão e testes-t dos biosinais (ACC, EDA e ECG) durante o Jogo de Carro, em condições de linha de base e com sintomas de CS.




Figura 4.21: Média e Desvio Padrão para o Jogo de Carro e Biosinal ACC.

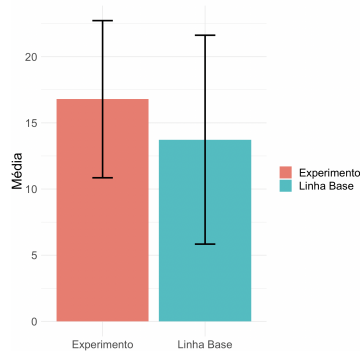


Figura 4.22: Média e Desvio Padrão para o Jogo de Carro e Biosinal EDA.




Figura 4.23: Média e Desvio Padrão para o Jogo de Carro e Biosinal ECG.

Análise do Jogo de Voo

Conforme evidenciado nas Tabelas 4.18 e nas Figuras 4.24, 4.25 e 4.26, os resultados relativos ao Jogo de Voo, demonstram alterações significativas em todos os biosinais. Entretanto, em relação ao dados de movimentos corporais, coletados através do ACC, observa-se um padrão distinto em comparação ao mesmo biosinal coletado durante o Jogo de Carro. Os movimentos corporais dos participantes durante o Jogo de Voo, quando em repouso, foram notavelmente restritos. No que se refere as fases de coleta de dados de linha de base, a explicação reside no comportamento disciplinado dos participantes.

Quanto aos movimentos mais contidos durante o experimento, isso pode ser atribuído ao estilo de jogo mais tranquilo adotado, o qual é menos radical se comparado ao Jogo de Carro. Os desvios padrão consideravelmente altos, tanto na linha de base quanto durante o experimento, estão relacionados a possíveis movimentos abruptos realizados pelos participantes e, portanto, não foram tratados como *outliers*, sendo mantidos na análise.

Em relação ao biosinal EDA, observa-se também um aumento médio durante a atividade do jogo em comparação com os dados de linha de base (com a mesma explicação aplicada ao Jogo de Carro). O ECG, especialmente os intervalos RRs, também revelou uma redução média em relação aos dados coletados durante o repouso, indicando um aumento na frequência cardíaca durante o jogo, com a mesma justificativa do jogo anterior.

Os testes-t realizados para este jogo, assim como no anterior, revelaram uma diferença estatisticamente significativa entre as médias das duas amostras, evidenciada pelo alto valor de t e os valores-p correspondentes também muito baixos (< 0.001). Assim como no jogo anterior, para um Intervalo de Confiança (IC) de 95%, nenhum dos biosinais analisados contém o valor zero, o que também rejeita a hipótese nula. Portanto, com base nesse resultado, pode-se também afirmar a presença de uma ligação direta entre os sintomas associados à CS e as mudanças nos biosinais monitorados, ressaltando a relevância desses biosinais na detecção e compreensão da CS.

Biosinal	Médias e Desvios Padrão		testes-t			
	Linha de Base	Com CS	df	valor-t	valor-p	IC
ACC	0.103 (0.591)	0.126 (0.589)	431	4.779	< 0.001	0.014 a 0.032
EDA	13.433 (6.351)	14.819 (3.458)	557	6.2294	< 0.001	0.949 a 1.823
ECG (Intervalo RR)	0.761 (0.118)	0.697 (0.205)	557	-8.5174	< 0.001	-0.079 a -0.049

Tabela 4.18: Médias, desvios padrão e testes-t dos biosinais (ACC, EDA e ECG) durante o Jogo de Voo, em condições de linha de base e com sintomas de CS.




Figura 4.24: Média e Desvio Padrão para o Jogo de Voo e Biosinal ACC.




Figura 4.25: Média e Desvio Padrão para o Jogo de Voo e Biosinal EDA.

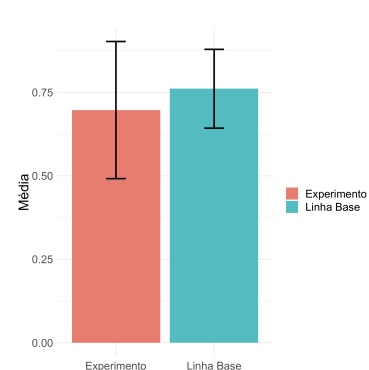


Figura 4.26: Média e Desvio Padrão para o Jogo de Voo e Biosinal ECG.

Capítulo 5

Identificação das Causas da CS

Neste capítulo, será apresentada uma visão geral da abordagem de referência proposta por Porcino [12], assim como da abordagem delineada nesta dissertação. Além disso, serão apresentadas as avaliações dos classificadores, atributos e do modelo empregado, juntamente com a metodologia utilizada na Identificação das Causas da CS. Por fim, as análises dos resultados serão expostas.

5.1 Abordagem de Referência

No estudo realizado por Porcino [12], foi proposta uma análise experimental que emprega Aprendizado de Máquina Simbólico para classificar as possíveis causas de *Cybersickness* em jogos de RV. Conforme destacado pelo autor, uma vez identificadas as causas, os designers de jogos poderão escolher a estratégia mais apropriada para reduzir os efeitos dos sintomas.

Para a obtenção dos dados, foram desenvolvidos dois jogos de Realidade Virtual (RV) (utilizando Unity 3D): um jogo de corrida e um jogo de voo. No protocolo de experimentos, os pesquisadores solicitaram que os participantes respondessem aos questionários *Cybersickness Profile Questionnaire* (CSPQ) e *Virtual Reality Sickness Questionnaire* (VRSQ) antes e depois de participarem de uma sessão de jogo de RV com duração de 5 ou 20 minutos. A coleta de dados ocorreu enquanto os usuários interagem com o jogo, permitindo-lhes rotular seu nível de desconforto. Além das avaliações subjetivas dos participantes, também foram registrados dados em tempo real relacionados ao jogo, incluindo informações como aceleração, orientação da cabeça, posição do cenário, entre outros.

Além disso, no estudo de Porcino [12], são apresentados dois algoritmos simbólicos de aprendizado de máquina (*Decision Tree* e *Random Forest*) capazes de gerar um ranking contendo as identificações das possíveis causas de CS.

5.1.1 Pipeline Referencial

Conforme ilustrado na Figura 5.1, no pipeline proposto [12], o treinamento ocorre de maneira sequencial. A primeira etapa é a coleta de dados, que é realizada com base no perfil do usuário (obtido por meio do questionário CSPQ), no questionário VRSQ e nos dados do jogo. Em seguida, esses dados são submetidos a um processo de pré-processamento, no qual são organizados e preparados para o treinamento do algoritmo de Machine Learning Simbólico. Na fase de treinamento, o algoritmo utiliza os dados coletados para construir um modelo treinado.

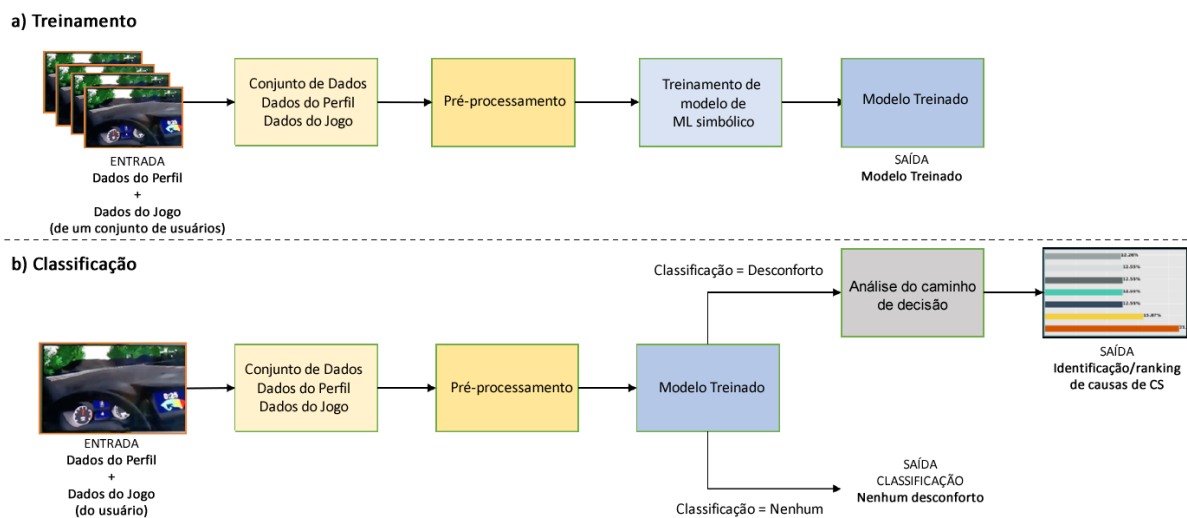


Figura 5.1: Método Proposto por Porcino [12].

A classificação, envolve a utilização de dados de perfil e do jogo de um determinado usuário. Nessa etapa, ocorre também o pré-processamento dos dados, que são então submetidos ao modelo treinado. Se o resultado da classificação indicar algum nível de desconforto, é realizado um processo de análise do caminho de decisão. Como resultado desse processo, é gerado um ranking (baseado nos atributos descritos na Tabela 5.1), contendo as identificações das possíveis causas de *Cybersickness* (CS). Esse ranking fornece insights valiosos sobre os fatores que contribuem para o desconforto do usuário. Se a classificação resultar na identificação de que não há desconforto, o processo é encerrado.

5.1.2 Conjunto de Dados

No estudo de Porcino [12], a coleta de dados ocorreu enquanto os usuários interagiam com o jogo, permitindo-lhes responder as avaliações subjetivas dos participantes. De acordo com o pesquisador, os dados referentes às características do perfil do usuário (CSPQ)

Dados do Jogo	Dados do Perfil
TimeStamp	Gênero
Velocidade	Idade
Aceleração	Experiência em VR
Rotação Z	
FPS	

Tabela 5.1: Fatores pesquisados por Porcino [12].

foram selecionadas com base na literatura e no conhecimento adquirido durante os testes-piloto conduzidos para o estudo. No que diz respeito aos dados relacionados aos sintomas de desconforto, eles são adquiridos por meio do questionário VRSQ, tanto antes quanto após a condução do experimento.

Além dos dados de perfil de usuário, conforme a Tabela 4.7, também foram registrados dados em tempo real relacionados ao jogo. Os atributos não categóricos são: timestamp, velocidade, aceleração, rotação (eixo de rotação do jogador), posição (posição do jogador), região de interesse, tamanho do FoV, taxa de quadros e nível de desconforto (relatado pelo usuário durante o jogo). Os atributos categóricos são: quadro estático (existência de quadros de repouso estáticos), feedback tátil, grau de controle (nível de controle do usuário sobre a câmera), simulação DoF (existência de simulação de profundidade de campo), locomoção do jogador e por último, câmera automática (se a câmera principal do jogo se move automaticamente sem intervenção do usuário).

5.2 Abordagem Proposta

A abordagem proposta neste estudo, representa um avanço em relação ao método apresentado pelo Porcino [12], ao incorporar informações de biosinais. Como ilustrado na Figura 5.2, ao considerar os intervalos RRs, obtidos a partir do Eletrocardiograma (*Electrocardiogram* (ECG)), Atividade Eletrodérmica (*Electrodermal Activity* (EDA)) e os registros de movimentos corporais, coletados por meio de um Acelerômetro (*Accelerometer* (ACC)), torna-se possível realizar uma análise mais abrangente das causas da *Cybersickness* (CS), além da possibilidade de estabelecer correlações entre os sintomas relatados e as respostas fisiológicas do indivíduo. Essa metodologia fortalece a capacidade de identificação dos sintomas, o que é crucial para avançar na compreensão e no desenvolvimento de estratégias para prevenir e mitigar a *Cybersickness*. Essas contribuições são significativas para proporcionar uma experiência mais confortável e satisfatória para os usuários de Realidade Virtual (RV).

No método proposto, conforme ilustrado na Figura 5.2 (a), o treinamento se inicia com a obtenção de dados qualitativos (CSPQ e VRSQ), além de dados quantitativos

provenientes do jogo e dos biosinais. Na etapa subsequente, os dados são submetidos a um processo de pré-processamento e, em seguida, a uma nova etapa que adicionamos, a qual permite a seleção do modelo (com ou sem a inclusão dos biosinais). As demais etapas do modelo de referência foram mantidas.

O procedimento de classificação é bastante similar. Ele começa com um conjunto de instâncias de um usuário específico, seguido por um pré-processamento dos dados. Em seguida, ocorre a seleção do modelo, que pode ou não incluir os biosinais. Após essa etapa, os dados são submetidos ao modelo treinado. Se o resultado indicar algum nível de desconforto, é analisado o caminho de decisão, e então gerado um ranking dos principais fatores causadores da CS.

O processo de coleta de dados foi expandido para incluir não apenas os questionários quantitativos e dados do jogo, mas também os sinais fisiológicos dos participantes. Nesta etapa, as coletas foram realizadas simultaneamente tanto para os biosinais quanto para os dados coletados do game, os quais foram posteriormente integrados em um único arquivo para cada experimento.

Com base no trabalho de referência, implementamos todo o processo, desde a coleta dos biosinais até a identificação das causas da *Cybersickness*, utilizando dois métodos de ranqueamento distintos: o *Potential-Cause Score* (PCS) [12] e o *Potential Discomfort Indicator* (PDI), propostos neste trabalho.

5.2.1 Avaliação dos Classificadores

No contexto deste trabalho, os classificadores simbólicos baseados em Árvores de Decisão (*Decision Tree* (DT)), são escolhidos como uma abordagem adequada para a tarefa de classificação dos dados, além da sua capacidade de fornecer uma representação visual transparente e de fácil compreensão das decisões realizadas pelo modelo. Uma vez construída a DT, ela pode ser utilizada para classificar novos exemplos. As árvores de decisão são facilmente interpretáveis, o que permite uma compreensão clara das regras de classificação adotadas pelo modelo.

As DTs são uma das técnicas de aprendizado de máquina, onde um problema complexo é decomposto em subproblemas mais simples. É uma estrutura de dados definida recursivamente como: nó folha que corresponde a uma classe ou um nó de decisão que possui um teste sobre algum atributo. Em cada resultado do teste, existe uma aresta para uma subárvore que possui a mesma estrutura da árvore [159]. Ao construir uma DT, o algoritmo procura encontrar a melhor divisão dos dados em cada nó. Várias medidas foram projetadas para avaliar o grau de não homogeneidade ou impureza em um conjunto. As duas medidas mais comuns são a *Entropia* e o *Índice de Gini*.

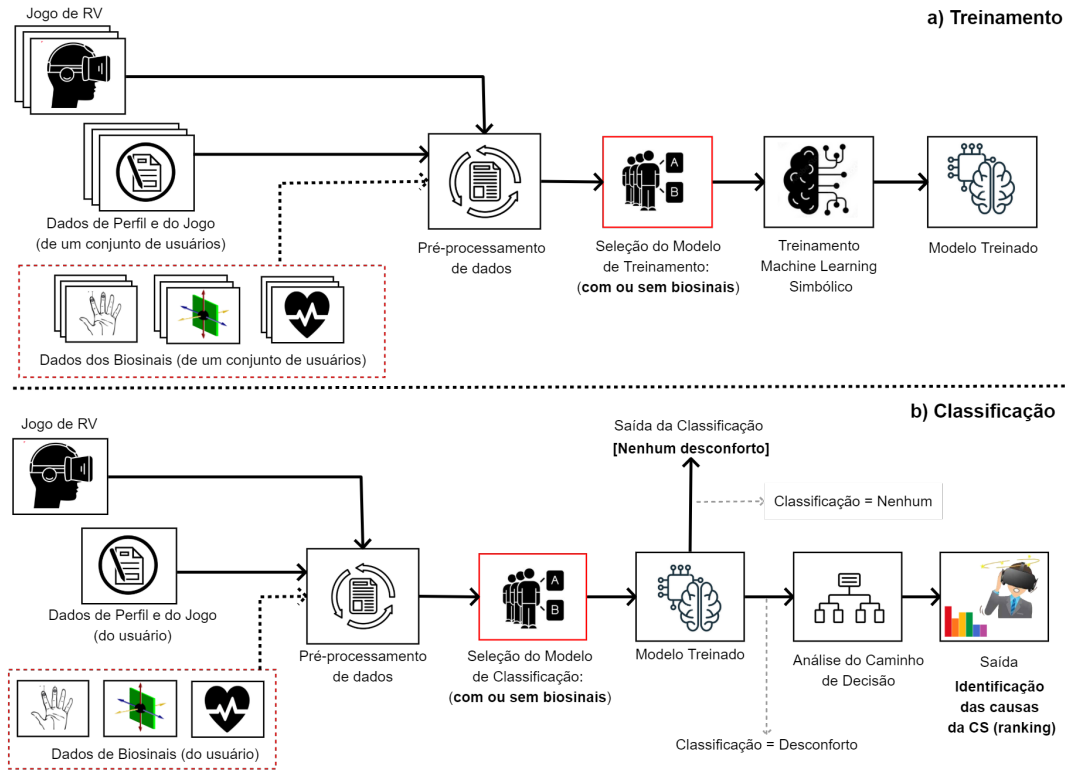


Figura 5.2: Método proposto neste trabalho.

O conceito de entropia está associado a medida de impureza ou grau de desordem de um conjunto de dados de treinamento, e obedece a um conjunto de axiomas formulado por Claude Shannon em 1948 [160]. Em cada nível hierárquico da *Decision Tree*, o atributo com maior ganho de informação, é selecionado como um nó da árvore. A *Entropia* e o ganho de informação são dados pelas respectivas fórmulas:

$$\text{Entropy}(S) = - \sum_{i=1}^c p_i \log_2(p_i) \quad (5.1)$$

Na Equação 5.1, S representa o conjunto de dados ou subconjunto de dados; c é o número de classes no conjunto de dados; p_i é a probabilidade da classe i no conjunto de dados.

$$\text{Gain}(S, A) = \text{Entropy}(S) - \sum_{v \in \text{Values}(A)} \frac{|S_v|}{|S|} \cdot \text{Entropy}(S_v) \quad (5.2)$$

Já na Equação 5.2, A representa um atributo ou característica; $\text{Values}(A)$ denota os possíveis valores do atributo A ; S_v representa o subconjunto de dados em S onde o atributo A tem o valor v ; $|S_v|$ e $|S|$ denotam o número de instâncias nos subconjuntos S_v e S , respectivamente. $\text{Gain}(S, A)$ é o ganho de informação ao dividir os dados com base

no atributo A .

O *Índice de Gini* (medida adotada neste trabalho), mede a probabilidade de dois elementos selecionados aleatoriamente, do mesmo subconjunto, terem rótulos de classe diferentes. Segundo Rokach [161], o *Índice de Gini* é um critério baseado em impurezas que mede as divergências entre as distribuições de probabilidade dos valores do atributo alvo. Ele tem sido utilizado em vários trabalhos [162, 161] e é definido como:

$$Gini(D) = 1 - \sum_{i=1}^C (p_i)^2 \quad (5.3)$$

Na equação 5.3, D representa o conjunto de dados e C é o número de classes no conjunto de dados. A probabilidade de um item pertencer a uma determinada classe ou categoria é denotada por p_i . Para cada classe, eleva-se a probabilidade ao quadrado (p_i^2) e soma-se todos esses termos quadráticos. Em seguida, subtrai-se esse valor da unidade (1) para obter o índice de Gini. O índice de Gini varia de 0 a 1. Um valor de Gini igual a 0 indica uma distribuição perfeitamente homogênea, em que todos os itens pertencem à mesma classe. Por outro lado, um valor de Gini igual a 1 indica uma distribuição totalmente impura ou heterogênea. Essa medida nos permite quantificar a impureza ou a desordem de um conjunto de dados com base na distribuição de classes.

Avaliação dos Classificadores usando o Weka

No campo do aprendizado de máquina, é uma prática comum realizar a validação dos dados e garantir que o modelo treinado seja capaz de fazer previsões acuradas e úteis em novos exemplos. Para auxiliar nesse processo, uma ampla variedade de ferramentas e bibliotecas estão disponíveis, e o Weka é uma delas. A ferramenta WEKA (Waikato Environment for Knowledge Analysis), é uma ferramenta de mineração de dados, de código aberto e desenvolvida em Java, pela Universidade de Waikato, na Nova Zelândia. Seu desenvolvimento surgiu da necessidade dos pesquisadores terem uma ferramenta que permitisse fácil acesso as novas técnicas de ML. Além disso, a plataforma oferece recursos abrangentes para o pré-processamento, visualização e avaliação dos dados, proporcionando uma solução completa para as necessidades de análise e exploração de dados.

A partir dos dados coletados e pré-processados, usamos a ferramenta Weka para empregar diversos algoritmos de *Machine Learning* na classificação da CS. Nesta etapa, três conjuntos de dados (Datasets A, B e C) foram organizados, incluindo informações do jogo, dados do perfil do usuário e dos biosinais (como demonstrado na Tabela 4.9).

- *Dataset A*: inclui 2309 amostras coletadas durante o Jogo de Carro.
- *Dataset B*: Consiste em 2408 amostras coletadas durante o Jogo de Voo.

- *Dataset C*: Contém 4717 amostras combinadas dos dois Datasets (A e B).

Cada conjunto de dados, inclui a classificação atribuída pelo usuário a um nível de desconforto, de acordo com a seguinte escala: 0 (zero) para nenhum sintoma relacionado à CS, 1 (um) para sintomas leves, 2 (dois) para moderados e 3 (três) para sintomas severos. Avaliamos os principais algoritmos baseados em árvores de decisão no Weka, que incluem: CSForest, DecisionStump, ForestPA, HoeffdingTree, J48, LMT, ExtraTree, RandomForest, RandomTree e REPTree.

Para validar o modelo de classificação, optamos pela validação cruzada k-fold (Folds=10) para todos os classificadores simbólicos avaliados. A abordagem K-fold Cross Validation (KCV) é amplamente empregada por profissionais para a seleção de modelos e a estimativa de erros de classificadores. Essa técnica envolve a divisão de um conjunto de dados em k subconjuntos; posteriormente, de forma iterativa, alguns desses subconjuntos são utilizados para treinar o modelo, enquanto as outras para avaliar seu desempenho [163].

Inicialmente, através da ferramenta Weka, realizamos uma classificação multiclasse, os quais compreendem as quatro classes originais: 0 = Nenhum, 1 = Leve, 2 = Moderado e 3 = Severo. Nos três conjuntos de dados, incorporamos os biosinais capturados. Em seguida, repetimos o processo de classificação multiclasse sem a inclusão dos biosinais. Adicionalmente, geramos três conjuntos de dados suplementares derivados dos conjuntos originais (A, B e C) para a realização de classificações binárias. Nesse contexto, as classes de saída foram definidas como duas: 0=Nenhum ou 1=Desconforto, sendo que esta última incorpora as classes (Leve, Moderado e Severo). Para os subconjuntos, as execuções também foram realizadas tanto com os atributos de biosinais quanto sem eles. É apresentado na Figura 5.3, uma visão geral da estrutura dos Datasets utilizados.

Vamos analisar se os resultados das classificações utilizando o Weka, tanto com quanto sem a inclusão dos biosinais, influenciaram na seleção do melhor algoritmo de *Machine Learning* (ML). Nas seções seguintes, serão expostos os índices de Precisão (ACC) e Kappa (KPP), para os resultados das classificações multiclases (com e sem a inclusão de biosinais) e binárias (com e sem a inclusão de biosinais). Mais detalhes serão fornecidos nas próximas seções.

Melhor Algoritmo para Classificação Multiclasse

Conforme demonstrado na Tabela 5.2, ao considerar as classificações multiclases sem a inclusão de dados de biosinais, destaca-se que o classificador RF obteve o melhor desempenho, alcançando precisões de 98.18%, 98.01% e 98.20% para os conjuntos A, B e C, respectivamente.

Os resultados das classificações multiclases com a inclusão dos dados de biosinais, de acordo com a Tabela 5.3, indicaram novamente que o algoritmo de classificação RF teve

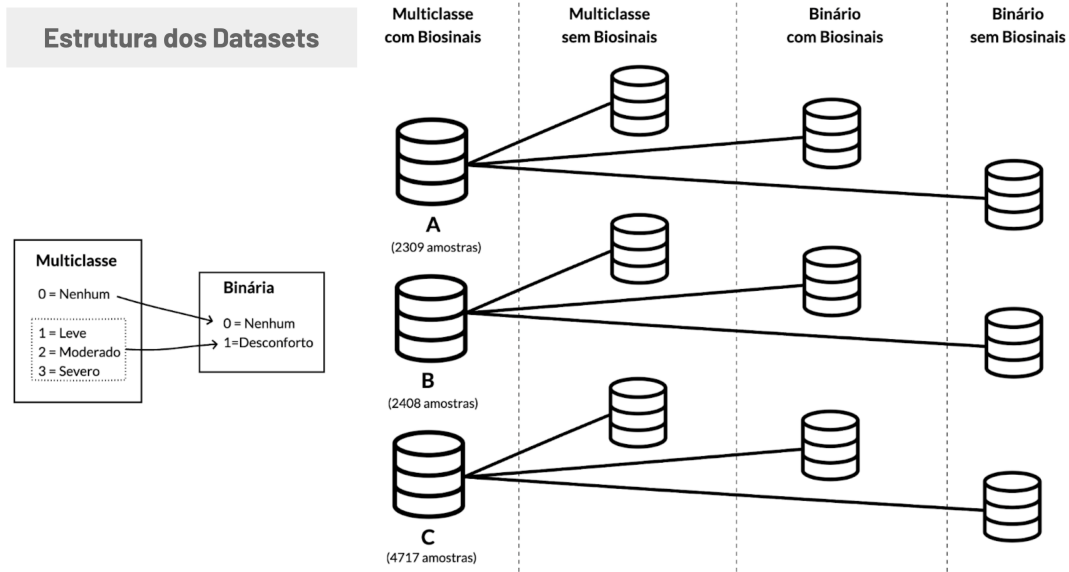


Figura 5.3: Estrutura dos Datasets utilizados na avaliação dos classificadores e atributos.

	Classificador	Dataset A		Dataset B		Dataset C	
		ACC	KPP	ACC	KPP	ACC	KPP
	CSForest	97.62%	0.9434	96.55%	0.9363	96.86%	0.9357
	DecisionStump	79.42%	0.4885	73.71%	0.3789	70.11%	0.3216
	ForestPA	97.31%	0.9365	96.71%	0.9399	96.95%	0.9376
	HoeffdingTree	72.76%	0.0000	62.67%	0.4051	69.39%	0.3348
	J48	97.62%	0.9444	97.55%	0.9552	97.22%	0.9435
	LMT	96.75%	0.9238	96.22%	0.9306	95.97%	0.9183
	ExtraTree	95.84%	0.9024	95.43%	0.9165	95.72%	0.9132
✓	RandomForest	98.18%	0.9569	98.01%	0.9635	98.20%	0.9632
	RandomTree	93.16%	0.8389	93.81%	0.8869	93.19%	0.8626
	REPTree	97.14%	0.9333	96.89%	0.9432	96.46%	0.9281

Tabela 5.2: Classificação Multiclasse sem a Inclusão de Dados de Biosinais (Weka).

um desempenho superior. Nota-se que, para o Dataset A, o algoritmo RF não obteve o melhor desempenho, sendo superado pelo algoritmo J48 (com uma precisão de 99.44%), enquanto *Random Forest* atingiu 99.35%. No entanto, nos Datasets B e C, RF demonstrou desempenho superior, alcançando precisões de 98.26% e 98.77%, respectivamente. Portanto, foi novamente selecionado como o melhor classificador. Vale ressaltar que, a inclusão de biosinais resultou em um melhor desempenho em comparação a classificação com a ausência desses dados.

Melhor Algoritmo para Classificação Binária

Analisamos também o algoritmo que apresentou o melhor desempenho na classificação binária. Como mencionado anteriormente, essa classificação gera apenas duas classes (0=Nenhum e 1=Desconforto).

		Dataset A		Dataset B		Dataset C	
	Classificador	ACC	KPP	ACC	KPP	ACC	KPP
	CSForest	98.79%	0.9714	96.55%	0.9363	98.04%	0.9601
	DecisionStump	79.43%	0.4885	73.71%	0.3789	70.10%	0.3216
	ForestPA	99.22%	0.9817	97.22%	0.9488	98.64%	0.9724
	HoeffdingTree	72.76%	0.0000	62.87%	0.4366	69.56%	0.2638
	J48	99.44%	0.9868	98.01%	0.9635	98.38%	0.9672
	LMT	98.70%	0.9696	97.43%	0.9530	97.71%	0.9536
	ExtraTree	97.70%	0.9462	95.97%	0.9264	96.25%	0.9235
✓	RandomForest	99.35%	0.9847	98.26%	0.9681	98.77%	0.9750
	RandomTree	95.97%	0.9057	95.06%	0.9094	95.70%	0.9124
	REPTree	99.05%	0.9776	97.88%	0.9612	97.63%	0.9517

Tabela 5.3: Classificação Multiclasse com a Inclusão de Dados de Biosinais (Weka).

		Dataset A		Dataset B		Dataset C	
	Classificador	ACC	KPP	ACC	KPP	ACC	KPP
	CSForest	97.57%	0.9402	97.59%	0.9489	97.92%	0.9529
	DecisionStump	84.53%	0.5982	63.08%	0.0000	69.73%	0.1731
	ForestPA	97.70%	0.9415	98.38%	0.9652	98.16%	0.9576
	HoeffdingTree	72.76%	0.0000	88.91%	0.7630	78.02%	0.5199
	J48	97.96%	0.9487	98.71%	0.9724	98.11%	0.9568
	LMT	97.75%	0.9435	98.59%	0.9697	98.18%	0.9583
	ExtraTree	96.67%	0.9167	97.97%	0.9564	97.14%	0.9345
✓	RandomForest	98.83%	0.9704	99.17%	0.9821	98.92%	0.9751
	RandomTree	95.50%	0.8867	96.14%	0.9174	96.21	0.9131
	REPTree	97.49%	0.9363	97.63%	0.9494	97.71%	0.9474

Tabela 5.4: Classificação Binária sem a Inclusão de Dados de Biosinais (Weka).

Conforme evidenciado na Tabela 5.4, para a classificação binária sem a inclusão de biosinais, o algoritmo RF apresentou mais uma vez melhores resultados, atingindo precisões de 98.83%, 99.17%, e 98.92% respectivamente, para os Datasets A, B e C.

Finalmente, também avaliamos o desempenho do melhor algoritmo na classificação binária com a inclusão de dados de biosinais. Conforme mostrado na Tabela 5.5, o algoritmo *Random Forest* também apresentou os melhores resultados, com precisões de 99.78%, 99.50%, e 99.62% para os conjuntos de dados A, B e C, respectivamente. É importante ressaltar que, nesta classificação, alcançamos os resultados mais expressivos em comparação com todas as análises anteriores.

5.2.2 Avaliação dos Atributos

Assim como observado no estudo de Porcino [12], nosso propósito é aprofundar a compreensão das causas relacionadas ao desconforto. Nesse sentido, é necessário avaliar os atributos que exercem influência na tomada de decisão para a previsão da CS.

Diferente da pesquisa de referência [12], na qual a avaliação dos atributos foi conduzida por meio da ferramenta Weka, em nossa pesquisa, após a identificação do melhor

		Dataset A		Dataset B		Dataset C	
	Classificador	ACC	KPP	ACC	KPP	ACC	KPP
	CSForest	99.35%	0.9837	97.80%	0.9533	98.62%	0.9687
	DecisionStump	84.54%	0.5982	63.08%	0.0000	69.73%	0.1731
	ForestPA	99.61%	0.9901	98.80%	0.9741	99.32%	0.9844
	HoeffdingTree	72.76	0.0000	87.04%	0.7303	78.67%	0.5273
	J48	99.70%	0.9923	98.75%	0.9733	99.22%	0.9820
	LMT	99.57%	0.9891	98.59%	0.9696	99.13%	0.9801
	ExtraTree	98.31%	0.9572	97.76%	0.9519	98.56%	0.9669
✓	RandomForest	99.78%	0.9945	99.50%	0.9893	99.62%	0.9912
	RandomTree	98.48%	0.9616	97.34%	0.9427	97.77%	0.9490
	REPTree	99.65%	0.9913	98.05%	0.9582	99.17%	0.9810

Tabela 5.5: Classificação Binária com a Inclusão de Dados de Biosinais (Weka).

classificador, optamos por utilizar a biblioteca *scikit-learn* na elaboração do ranking dos atributos mais relevantes. Essa decisão foi tomada visando alcançar um controle mais detalhado do procedimento de avaliação. Para a avaliação do modelo, decidimos pela validação cruzada *leave-one-out*, na qual o modelo é treinado em várias iterações, removendo um atributo do conjunto de treinamento a cada vez e avaliando o desempenho do modelo sem esse atributo no conjunto de teste. Esta abordagem é comum na avaliação de modelos de ML, sendo especialmente útil para conjuntos de dados pequenos [164]. Além disso, vários estudos na literatura utilizam essa técnica para avaliar modelos *Random Forest* [165, 166, 167].

Nossa abordagem para criação do ranking dos melhores atributos, transcorreu da seguinte maneira: inicialmente, executamos o algoritmo no conjunto de dados multiclasse nos três conjuntos (A, B e C), incorporando os biosinais capturados. Posteriormente, removemos os atributos de biosinais de cada conjunto de dados e repetimos o processo de classificação multiclasse sem a inclusão desses biosinais. Utilizamos também os três conjuntos de dados suplementares, derivados dos conjuntos originais, para conduzir classificações binárias. Nas análises dos subconjuntos, foram realizadas execuções com e sem os atributos de biosinais. Uma visão geral da divisão dos conjuntos de dados, pode ser observada na Figura 5.3.

Seleção dos Melhores Atributos

Na abordagem proposta em nosso estudo, optamos por empregar dez atributos para o modelo sem biosinais e um total de treze para o modelo com biosinais, incluindo os atributos ACC, EDA e ECG.

Ao analisar os atributos associados à classificação multiclasse (não incorporando os biosinais), conforme a Tabela 5.6, o atributo TimeStamp (Tempo de Exposição) [12], se destacou como sendo o mais relevante para os Datasets A e C. Outros atributos respalda-

dos pela literatura, também apresentaram relevância significativa, incluindo Flicker [16], Rotação [66] e Gênero [4].

	Rank	Dataset A	Dataset B	Dataset C
✓	1	TimeStamp	Posição Z	TimeStamp
	2	Sintomas	TimeStamp	Posição Z
	3	Flicker	Rotação X	Rotação X
	4	Velocidade	Rotação Z	Rotação Y
	5	Rotação X	Rotação Y	Rotação Z
	6	Posição X	Flicker	Flicker
	7	Região de Interesse	Sintomas	Deficiências Visuais
	8	Rotação Y	Velocidade	Velocidade
	9	Posição Y	Gênero	Deficiências Visuais
	10	Rotação Z	Posição Y	Posição X

✓ Melhor

Tabela 5.6: Avaliação dos Atributos (classificação multiclasse, sem biosinais).

Na análise dos atributos relacionados à classificação binária, igualmente não incluindo os biosinais (conforme apresentado na Tabela 5.7), observamos resultados bastante semelhantes aos obtidos na análise anterior (Tabela 5.6). Vale ressaltar a presença dos atributos de rotação (X, Y e Z) também nesta avaliação.

	Rank	Dataset A	Dataset B	Dataset C
✓	1	TimeStamp	Posição Z	TimeStamp
	2	Sintomas	TimeStamp	Posição Z
	3	Flicker	Rotação Y	Rotação Y
	4	Velocidade	Rotação Z	Rotação Z
	5	Região de Interesse	Rotação X	Flicker
	6	Rotação X	Deficiências Visuais	Rotação X
	7	Posição X	Flicker	Sintomas
	8	Rotação Z	Gênero	Deficiências Visuais
	9	Rotação Y	Velocidade	Velocidade
	10	Posição Z	Usa Óculos	Posição X

✓ Melhor

Tabela 5.7: Avaliação dos Atributos (classificação binária, sem biosinais).

Nas execuções que incorporaram biosinais para a classificação multiclasse, o atributo TimeStamp destacou-se como o mais eficaz para o DataSet A. No entanto, para o DataSet B, a posição de destaque foi ocupada pelo biosinal ACC, enquanto para o DataSet C, o atributo EDA apresentou a melhor performance. Além disso, é importante observar que o ECG, outro biosinal utilizado em nossa pesquisa, também exibiu uma relevância consi-

derável, classificando-se entre os dez melhores atributos avaliados, conforme apresentado na Tabela 5.8.

	Rank	Dataset A	Dataset B	Dataset C
✓	1	TimeStamp	ACC	EDA
	2	EDA	Posição Z	TimeStamp
	3	ACC	EDA	ACC
	4	Sintomas	TimeStamp	Posição Z
	5	Flicker	Rotação X	Flicker
	6	Velocidade	Rotação Y	Rotação X
	7	Posição X	Rotação Z	Rotação Y
	8	Posição Y	Flicker	Rotação Z
	9	Rotação X	Deficiências Visuais	Deficiências Visuais
	10	ECG	Gênero	Velocidade

✓ Melhor

Tabela 5.8: Avaliação dos Atributos (classificação multiclasse, com biosinais).

Finalmente, nas execuções relacionadas à classificação binária com a inclusão de biosinais, conforme apresentado na Tabela 5.9, observamos que o atributo TimeStamp conquistou a melhor posição para o DataSet A. Entretanto, para os outros conjuntos de dados, a posição de destaque foi alcançada pelo atributo de biosinal EDA.

	Rank	Dataset A	Dataset B	Dataset C
✓	1	TimeStamp	EDA	EDA
	2	EDA	Posição Z	TimeStamp
	3	ACC	TimeStamp	ACC
	4	Flicker	ACC	Posição Z
	5	Sintomas	Rotação Y	Rotação Y
	6	Velocidade	Rotação Z	Flicker
	7	ECG	Rotação X	Rotação Z
	8	Usa Óculos	Deficiências Visuais	Rotação X
	9	Deficiências Visuais	Flicker	Deficiências Visuais
	10	Gênero	Usa Óculos	Sintomas

✓ Melhor

Tabela 5.9: Avaliação dos Atributos (classificação binária, com biosinais).

Durante o processo de seleção dos melhores atributos, alternamos os oito principais entre os DataSets A e B, como demonstrado na Tabela 5.7. Segundo Porcino [12], a taxa de quadros por segundo (*FPS*) é um atributo relevante nos jogos utilizados tanto em seu estudo, quanto na nossa pesquisa. Portanto, decidimos incorporá-lo ao nosso modelo. Além

disso, mesmo não sendo parte da combinação dos oito principais, o atributo *Velocidade*, citado nos resultados das avaliações, foi incluído na análise devido à sua importância comprovada no desencadeamento da CS, conforme indicado em estudos anteriores [168, 12]. Os atributos escolhidos para o nosso modelo são apresentados nas Tabelas 5.10 e 5.11.

Dados do Jogo	Dados do Usuário
TimeStamp	Gênero
Rotação X	Flicker
Rotação Y	Deficiências Visuais
Rotação Z	
Região de Interesse	
FPS	
Velocidade	

Atributo classe: Nível de Desconforto.

Tabela 5.10: Conjunto de Atributos Selecionados (sem a inclusão dos biosinais).

Como um dos objetivos específicos deste trabalho é analisar a influência dos biosinais coletados nas possíveis causas da *Cybersickness*, empregamos dois métodos de avaliação em conjunto com os algoritmos *Decision Tree* e *Random Forest*. No primeiro método, utilizamos os dados do jogo e do usuário para treinamento e testes nos algoritmos DT e RF, conforme os atributos selecionados na Tabela 5.10. Já o segundo método, considera a inclusão dos atributos de biosinais (conforme apresentado na Tabela 5.11) também para treinamento e testes, utilizando os mesmos algoritmos de *Machine Learning*.

Dados do Jogo	Dados do Usuário	Dados de Biosinais
TimeStamp	Gênero	ACC
Rotação X	Flicker	EDA
Rotação Y	Deficiências Visuais	ECG
Rotação Z		
Região de Interesse		
FPS		
Velocidade		

Atributo classe: Nível de Desconforto.

Tabela 5.11: Conjunto de Atributos Selecionados (com a inclusão dos biosinais).

5.2.3 Avaliação do Modelo

Em nosso estudo, também empregamos o método de avaliação do modelo de validação cruzada *leave-one-out* [12]. Para cada conjunto de dados associado aos experimentos realizados com jogos de carro ou de voo, o algoritmo foi treinado com n-1 participan-

tes, enquanto o modelo foi testado com o participante excluído do treinamento. Esse procedimento foi repetido n vezes, alternando o participante removido em cada iteração.

Também realizamos uma análise com o objetivo de determinar a profundidade ideal para a configuração do modelo, baseado no algoritmo RF, visando maximizar as pontuações AUC e minimizar a profundidade da árvore.

Profundidade Máxima da Árvore

Como evidenciado anteriormente, o algoritmo *Random Forest* obteve o melhor desempenho, conforme as análises realizadas. Diferentemente da *Decision Tree* simples, o algoritmo RF combina várias árvores de decisão, treinadas em subconjuntos aleatórios dos dados de treinamento, resultando em uma maior robustez e capacidade de generalização.

Entretanto, é importante notar que o treinamento do algoritmo *Random Forest* pode ser computacionalmente caro, devido à necessidade de construir e combinar múltiplas árvores. Com o objetivo de otimizar o processo de treinamento durante os experimentos, exploramos diferentes configurações de profundidade para os conjuntos de dados referentes aos jogos de carro e de voo. Em ambos os conjuntos, empregamos uma divisão de 70% para treinamento e 30% para teste. A Figura 5.4 apresenta os valores das pontuações AUC em relação a cada profundidade testada. Para o Jogo de Voo, a melhor profundidade foi 5, enquanto para o Jogo de Carro foi 7.




Figura 5.4: Profundidade X Pontuação AUC (com os Biosinais).

Pontuações AUC

A Área Sob a Curva ROC (*Area under ROC curve* (AUC)), tem sido utilizada em diversos estudos de *Machine Learning* como um critério importante de medição [169, 170], especialmente em problemas de classificação binária.

Nossa análise, se concentrou nos resultados de AUC obtidos pelos dois algoritmos baseados em árvores de decisão, utilizados em nossa pesquisa (DT e RF). Essas avaliações foram realizadas nos conjuntos de dados associados aos jogos de carro e de voo, incluindo tanto cenários sem a inclusão de biosinais, quanto aqueles que consideraram todas as combinações possíveis dos sinais fisiológicos (ACC, EDA e ECG), coletados durante os experimentos conduzidos neste estudo.

A seguir, serão apresentadas as tabelas contendo os resultados individuais para cada participante do experimento, para os dois algoritmos analisados. Os conjuntos de dados foram divididos em dois grupos distintos, treinamento e teste. Cada tabela, corresponde a um dos jogos utilizados durante a experiência de imersão do usuário. Iremos concentrar nossas análises nos resultados dos testes dos modelos.

Os resultados apresentados nas Tabelas 5.12 e 5.13, mostram respectivamente, os valores obtidos para o Jogo de Carro e o de Voo, utilizando apenas 10 atributos (Conforme a 5.10), sem a inclusão de qualquer tipo de biosinal coletado. Como podemos observar, as médias destacadas refletem a performance dos modelos. Em ambos os jogos, durante o cenário de *Teste*, o algoritmo *Random Forest* (RF) teve um desempenho superior, alcançando 0.68 (RF) em comparação com 0.53 (DT) para o Jogo de Carro, e 0.92 (RF) em comparação com 0.85 (DT) para o Jogo de Voo.

Usuário	Sem Biosinais			
	<i>Decision Tree</i>		<i>Random Forest</i>	
	Treino	Teste	Treino	Teste
3	0.99	0.19	0.99	0.03
5	0.99	0.50	0.99	0.90
9	1.00	0.50	1.00	0.67
11	0.99	0.90	0.99	0.96
13	0.99	0.55	0.99	0.73
Média	0.99	0.53	0.99	0.68

Tabela 5.12: AUC por usuário sem Biosinais (Jogo de Carro, Profundidade: 7).

Usuário	Sem Biosinais			
	<i>Decision Tree</i>		<i>Random Forest</i>	
	Treino	Teste	Treino	Teste
1	0.99	0.79	0.99	0.89
7	0.99	0.89	0.99	0.96
10	0.99	0.79	1.00	0.78
14	1.00	0.82	0.99	0.98
17	0.99	0.95	0.99	1.00
Média	0.99	0.85	0.99	0.92

Tabela 5.13: AUC por usuário sem Biosinais (Jogo de Voo, Profundidade: 5).

Analisando a inclusão do biosinal EDA, em relação aos modelos sem a inclusão de biosinais, conforme apresentado nas Tabelas 5.14 e 5.15, pode-se notar uma melhoria nos dois modelos (DT e RF) para ambos os jogos. Com exceção para o algoritmo DT no Jogo de Voo, onde a inclusão desse biosinal resultou em uma diferença de um ponto para baixo.

Conforme evidenciado pelas Tabelas 5.16 e 5.17, pode-se verificar que ao incluir apenas o biosinal ACC, as pontuações AUC foram inferiores para ambos os modelos, em ambos os jogos em comparação aos modelos sem a inclusão dos biosinais. A exceção ocorreu somente no algoritmo DT para o Jogo de Carro, onde a inclusão desse biosinal resultou em um desempenho superior (0.55) em comparação a não adicioná-lo ao conjunto de atributos (0.53).

Usuário	Com Biosinal EDA			
	<i>Decision Tree</i>		<i>Random Forest</i>	
	Treino	Teste	Treino	Teste
3	1.00	0.27	1.00	0.10
5	1.00	0.50	1.00	0.96
9	1.00	0.42	1.00	0.58
11	1.00	0.79	0.99	0.97
13	1.00	0.85	1.0	0.81
Média	1.0	0.57	1.0	0.69

Tabela 5.14: AUC por usuário com EDA (Jogo de Carro, Profundidade: 7).

Usuário	Com Biosinal EDA			
	<i>Decision Tree</i>		<i>Random Forest</i>	
	Treino	Teste	Treino	Teste
1	1.00	0.90	1.00	0.87
7	1.00	0.90	1.00	0.96
10	1.00	0.80	1.00	0.93
14	1.00	0.73	1.00	0.97
17	1.00	0.89	1.00	1.00
Média	1.00	0.84	1.00	0.94

Tabela 5.15: AUC por usuário com EDA (Jogo de Voo, Profundidade: 5).

Usuário	Com Biosinal ACC			
	<i>Decision Tree</i>		<i>Random Forest</i>	
	Treino	Teste	Treino	Teste
3	1.00	0.19	1.00	0.05
5	1.00	0.60	1.00	0.82
9	1.00	0.32	1.00	0.40
11	1.00	0.83	1.00	0.99
13	1.00	0.80	1.00	0.81
Média	1.00	0.55	1.00	0.61

Tabela 5.16: AUC por usuário com ACC (Jogo de Carro, Profundidade: 7).

Usuário	Com Biosinal ACC			
	<i>Decision Tree</i>		<i>Random Forest</i>	
	Treino	Teste	Treino	Teste
1	1.00	0.86	1.00	0.94
7	1.00	0.89	1.00	0.96
10	1.00	0.81	1.00	0.80
14	1.00	0.62	1.00	0.82
17	1.00	0.79	1.00	1.00
Média	1.00	0.79	1.00	0.90

Tabela 5.17: AUC por usuário com ACC (Jogo de Voo, Profundidade: 5).

Em comparação aos modelos compostos apenas pelos atributos (sem a inclusão dos biosinais), ao incluir o biosinal ECG, conforme apresentado nas Tabelas 5.18 e 5.19, observamos uma melhora de 10 pontos de AUC em relação ao modelo DT para o Jogo de Carro, e um desempenho bastante próximo para o Jogo de Voo, com uma redução de apenas 1 ponto percentual. Comparando com o desempenho do modelo RF para o Jogo de Voo, notamos uma melhoria de 1 ponto percentual com a inclusão desse biosinal, enquanto em relação ao Jogo de Carro, houve uma redução de 4 pontos.

Usuário	Com Biosinal ECG			
	<i>Decision Tree</i>		<i>Random Forest</i>	
	Treino	Teste	Treino	Teste
3	0.99	0.20	0.99	0.03
5	0.99	0.88	0.99	0.88
9	0.99	0.50	1.00	0.50
11	0.99	0.90	0.99	0.96
13	0.99	0.67	0.99	0.83
Média	0.99	0.63	1.00	0.64

Tabela 5.18: AUC por usuário com ECG (Jogo de Carro, Profundidade: 7).

Usuário	Com Biosinal ECG			
	<i>Decision Tree</i>		<i>Random Forest</i>	
	Treino	Teste	Treino	Teste
1	0.99	0.72	0.99	0.87
7	0.99	0.89	0.99	0.96
10	0.99	0.81	1.00	0.81
14	1.00	0.82	0.99	0.99
17	0.99	0.98	0.99	0.99
Média	0.99	0.84	0.99	0.93

Tabela 5.19: AUC por usuário com ECG (Jogo de Voo, Profundidade: 5).

Ao incorporar os dois biosinais ACC e EDA, notamos uma melhoria no desempenho do modelo RF para o Jogo de Voo (0.94 contra 0.92) e do modelo DT para o Jogo de Carro (0.66 contra 0.53). Conforme as Tabelas 5.20 e 5.21, nas demais combinações, os modelos sem a inclusão de biosinais apresentaram um melhor desempenho.

Usuário	Com Biosinais ACC e EDA			
	<i>Decision Tree</i>		<i>Random Forest</i>	
	Treino	Teste	Treino	Teste
3	1.00	0.27	0.99	0.27
5	1.00	0.50	0.99	0.79
9	1.00	0.42	1.00	0.43
11	1.00	0.80	0.99	0.98
13	1.00	0.82	0.99	0.81
Média	0.99	0.66	1.00	0.66

Tabela 5.20: AUC por usuário com ACC e EDA (Jogo de Carro, Profundidade: 7).

Usuário	Com Biosinais ACC e EDA			
	<i>Decision Tree</i>		<i>Random Forest</i>	
	Treino	Teste	Treino	Teste
1	0.99	0.86	0.99	0.99
7	0.99	0.85	0.99	0.96
10	0.99	0.80	1.00	0.91
14	1.00	0.62	0.99	0.85
17	0.99	0.69	0.99	1.00
Média	0.99	0.76	0.99	0.94

Tabela 5.21: AUC por usuário com ACC e EDA (Jogo de Voo, Profundidade: 5).

Ao incluir a combinação dos biosinais ACC e ECG, observamos uma leve melhoria nos resultados do Jogo de Carro, tanto para DT quanto para RF, sendo respectivamente 0.55 contra 0.53 e 0.69 contra 0.68. Mais detalhes nas Tabelas 5.22 e 5.23.

Usuário	Com Biosinais ACC e ECG			
	<i>Decision Tree</i>		<i>Random Forest</i>	
	Treino	Teste	Treino	Teste
3	1.00	0.17	1.00	0.08
5	0.99	0.60	1.00	0.82
9	1.00	0.32	1.00	0.73
11	1.00	0.83	1.00	0.98
13	1.00	0.80	1.00	0.83
Média	0.99	0.55	1.00	0.69

Tabela 5.22: AUC por usuário com ACC e ECG (Jogo de Carro, Profundidade: 7).

Usuário	Com Biosinais ACC e ECG			
	<i>Decision Tree</i>		<i>Random Forest</i>	
	Treino	Teste	Treino	Teste
1	0.99	0.79	0.99	0.96
7	0.99	0.89	0.99	0.96
10	0.99	0.81	1.00	0.81
14	1.00	0.50	0.99	0.80
17	0.99	0.79	0.99	1.00
Média	0.99	0.76	0.99	0.91

Tabela 5.23: AUC por usuário com ACC e ECG (Jogo de Voo, Profundidade: 5).

Adicionando os biosinais EDA e ECG ao conjunto de atributos, conforme as Tabelas 5.24 e 5.25, com exceção do modelo DT para o Jogo de Voo (0.85 contra 0.83), observou-se uma melhoria na performance dos modelos em ambos os jogos.

Usuário	Com Biosinais EDA e ECG			
	<i>Decision Tree</i>		<i>Random Forest</i>	
	Treino	Teste	Treino	Teste
3	1.00	0.37	1.00	0.32
5	1.00	0.50	1.00	0.95
9	1.00	0.42	1.00	0.56
11	1.00	0.79	1.00	0.97
13	0.99	0.85	1.00	0.77
Média	0.99	0.59	1.00	0.71

Tabela 5.24: AUC por usuário com EDA e ECG (Jogo de Carro, Profundidade: 7).

Usuário	Com Biosinais EDA e ECG			
	<i>Decision Tree</i>		<i>Random Forest</i>	
	Treino	Teste	Treino	Teste
1	0.99	0.84	0.99	0.85
7	0.99	0.89	0.99	0.96
10	0.99	0.80	1.00	0.94
14	1.00	0.71	0.99	0.94
17	0.99	0.90	0.99	1.00
Média	0.99	0.83	0.99	0.94

Tabela 5.25: AUC por usuário com EDA e ECG (Jogo de Voo, Profundidade: 5).

Ao incluir todos os biosinais, conforme as Tabelas 5.26 e 5.27, observamos que, para o Jogo de Voo, RF obteve o melhor desempenho, em comparação com os cenários anteriores, alcançando 0.95 (95%) das pontuações de AUC. Para o Jogo de Carro, RF se manteve praticamente estável, com diferença de apenas 1 ponto em relação à configuração dos

atributos sem a inclusão de biosinais. Em comparação com o modelo DT, a inclusão dos dados fisiológicos, mostrou-se superior para o Jogo de Carro, 0.59 (59%) contra 0.53 (53%), tendo um desempenho inferior para o Jogo de Voo 0.78 (78%) contra 0.85 (85%).

Usuário	Biosinais ACC, EDA e ECG			
	<i>Decision Tree</i>		<i>Random Forest</i>	
	Treino	Teste	Treino	Teste
3	1.00	0.23	0.99	0.21
5	1.00	0.50	1.00	0.88
9	1.00	0.42	1.00	0.47
11	1.00	0.96	1.00	0.98
13	1.00	0.85	1.00	0.84
Média	0.99	0.59	1.00	0.67

Tabela 5.26: AUC por usuário com ACC, EDA e ECG (Jogo de Carro, Profundidade: 7).

Usuário	Biosinais ACC, EDA e ECG			
	<i>Decision Tree</i>		<i>Random Forest</i>	
	Treino	Teste	Treino	Teste
1	0.99	0.84	0.99	0.99
7	0.99	0.85	0.99	0.96
10	0.99	0.80	1.00	0.93
14	1.00	0.61	0.99	0.85
17	0.99	0.79	0.99	1.00
Média	0.99	0.78	0.99	0.95

Tabela 5.27: AUC por usuário com ACC, EDA e ECG (Jogo de Voo, Profundidade: 5).

Finalmente, analisamos as pontuações mais elevadas de AUC em todas as combinações, conforme apresentado nas Tabelas 5.28, 5.29, 5.30 e 5.31. De acordo com a Figura 5.5, entre as quatro combinações de cenários (Jogos VS Algoritmos) analisadas, em três delas, observamos um desempenho superior com a inclusão de biosinais. A exceção foi no cenário do Jogo de Voo, com o algoritmo de *Decision Tree*.

Cenário	<i>Decision Tree</i>
ACC e EDA	0.66
ECG	0.63
EDA e ECG	0.59
ACC, EDA e ECG	0.59
EDA	0.57
ACC	0.55
ACC e ECG	0.55
Sem Biosinais	0.53

Tabela 5.28: AUC em ordem decrescente para o **Jogo de Carro** e Algoritmo DT.

Cenário	<i>Random Forest</i>
EDA e ECG	0.71
EDA	0.69
ACC e ECG	0.69
Sem Biosinais	0.68
ACC, EDA e ECG	0.67
ACC e EDA	0.66
ECG	0.64
ACC	0.61

Tabela 5.29: AUC em ordem decrescente para o **Jogo de Carro** e Algoritmo RF.

Cenário	<i>Decision Tree</i>
Sem Biosinais	0.85
EDA	0.84
ECG	0.84
EDA e ECG	0.83
ACC	0.79
ACC, EDA e ECG	0.78
ACC e EDA	0.76
ACC e ECG	0.76

Tabela 5.30: AUC em ordem decrescente para o **Jogo de Voo** e Algoritmo DT.

Cenário	<i>Random Forest</i>
ACC, EDA e ECG	0.95
EDA	0.94
ACC e EDA	0.94
EDA e ECG	0.94
ECG	0.93
Sem Biosinais	0.92
ACC e ECG	0.91
ACC	0.90

Tabela 5.31: AUC em ordem decrescente para o **Jogo de Voo** e Algoritmo RF.




Figura 5.5: Comparação dos melhores cenários em termos de pontuações AUC para os algoritmos *Decision Tree* (DT) e *Random Forest* (RF).

5.2.4 Identificação das Causas

A escolha de algoritmos baseados em Árvores de Decisão (*Decision Tree* (DT)), é importante devido à sua capacidade de oferecer uma compreensão clara e transparente no processo de tomada de decisão. As Árvores de Decisão, representam um método de aprendizado supervisionado utilizado para tarefas de classificação [171]. A inspiração para as DTs veio da estrutura de uma árvore comum, composta por uma raiz, nós (os pontos de divisão dos galhos), galhos e folhas.

Assim como uma árvore real, uma DT, conforme representado pela Figura 5.6 (a), é construída com nós representados por círculos e ramos, que são representados pelos segmentos que conectam esses nós [172]. Cada nó interno da árvore, representa uma decisão baseada em um atributo, enquanto os nós folha representam os resultados ou classes finais. Em cada nó, uma decisão é tomada com base no valor de um atributo específico, direcionando o fluxo para um dos nós filhos. Esse processo se repete até que um nó folha seja alcançado, determinando a classe final com base nos atributos considerados ao longo do caminho percorrido.

O algoritmo *Random Forest* (RF), amplamente utilizado em tarefas de classificação e regressão, consiste em múltiplas árvores de decisão individuais, cada uma treinada em subconjuntos aleatórios dos dados, utilizando uma seleção aleatória de atributos para as divisões dos nós. Posteriormente, essas árvores são combinadas para gerar uma decisão final. Neste contexto, "aleatórios" significa que cada árvore no conjunto de árvores de decisão, tem a mesma probabilidade de ser selecionada para contribuir com o modelo [171]. Essa "floresta" de modelos colabora para gerar previsões mais precisas e confiáveis. A Figura 5.6 (b), exemplifica uma RF composta por 4 árvores de decisão. No exemplo, como há mais previsões para a classe 1 do que para a classe 0, a *Random Forest* considerará a classe 1 como a previsão final.

Com base em nossas análises anteriores utilizando a ferramenta Weka, o algoritmo *Random Forest* (RF) mostrou-se mais promissor. Portanto, este será o classificador utilizado na identificação das principais características causadoras da CS. Além disso, após analisar as pontuações AUC das diversas combinações de classificadores e atributos, con-




Figura 5.6: a) *Decision Tree* (DT) simples; o caminho de decisão é destacado em verde; b) neste exemplo, o algoritmo *Random Forest* (RF) selecionará a classe 1 como a previsão final devido à predominância das previsões para essa classe (em destaque nas cores azul e vermelha).

cluímos que, em termos de desempenho do modelo, a inclusão dos biosinais obtidos durante os experimentos, contribui para uma melhor performance do modelo adotado.

Para realizar uma análise comparativa, e avaliar o impacto da inclusão dos biosinais na identificação das principais características causadoras da CS, configuramos nosso modelo para treinamento e classificação de duas maneiras distintas: uma usando apenas 10 atributos (conforme Tabela: 5.10) e outra adicionando os três atributos de biosinais (conforme Tabela: 5.11) propostos em nosso estudo.

Ranking das Causas de Desconforto

O ranking dos atributos mais relevantes foi construído com base no valor de *Gini*, o qual foi derivado a partir do caminho de decisão de cada instância para um usuário específico. A influência desse valor em um nó da árvore de decisão, é significativa para determinar a importância de um determinado atributo. Isso se deve ao papel do valor de *Gini* na definição das divisões dos nós durante o processo de construção da árvore. A implementação, foi realizada utilizando a linguagem Python em conjunto com a biblioteca *scikit-learn*. A seguir, descreveremos cada etapa do processo até o resultado final, que consiste na lista em ordem decrescente dos atributos que mais influenciaram no desconforto do usuário.

Primeiramente, para cada instância relacionada ao experimento de um usuário específico, verificamos se a predição de desconforto do modelo *Random Forest* (RF) é positiva, ou seja, se o nível de desconforto é igual a 1 (**DiscomfortLevel = 1**). Como o algoritmo RF é composto por um conjunto de árvores de decisão, iteramos também sobre cada esti-

mador de árvore individual da RF. Caso a previsão desta árvore seja igual à decisão final de *Random Forest*, somamos os valores de *Gini* correspondentes a cada atributo[12]. Esta etapa pode ser melhor compreendida com base no exemplo representado na Figura 5.7.

De posse dos valores de *Gini* correspondentes a todas as instâncias do usuário em questão (agrupados por atributo), calculamos o percentual de influência de cada um em relação ao total de atributos identificados. O processo geral pode ser representado pela Fórmula 5.4.

$$PDI_u = \downarrow \left(\frac{\sum_i \text{Gini}(\text{Path}_{ij}^u)}{\text{TotalGini}} \right) \times 100 \quad (5.4)$$

$\sum_i \text{Gini}(\text{Path}_{ij}^u)$: Para cada atributo (j) e instância (i) associada ao usuário u , a soma total dos valores *Gini* é calculada e agrupada.

TotalGini: Soma total dos valores *Gini* de todos atributos e de todas as instâncias.

\downarrow : Indica que a saída será classificada em ordem decrescente, começando pelos atributos com os maiores valores de *Gini*.

Vamos pegar como exemplo, duas instâncias ilustradas na Figura 5.7, que demonstram apenas os nós para o caminho de decisão, para um determinado usuário. O resultado para o numerador da Equação 5.4 é:

$$\sum_i \text{Gini}(\text{Path}_{ij}^u) = (\text{Instancia1}(\text{Gênero}[0.432] + \text{TimeStamp}[0.415] + \text{EDA}[0.671] + \text{Idade}[0.363] + \text{ECG}[0.328]) + \text{Instancia2}(\text{TimeStamp}[0.822] + \text{Gênero}[0.482] + \text{Experiência}[0.440] + \text{Idade}[0.381] + \text{Velocidade}[0.284]))$$

Observa-se que, para a instância 1, o atributo EDA é repetido duas vezes, sendo assim agrupado, totalizando o valor 0.671. Como possui maior valor *Gini*, indica que, ao longo do caminho de decisão, o atributo EDA contribuiu de forma significativa para a redução total da impureza do conjunto de dados, tornando-o, portanto, o atributo de maior importância para esta decisão. Já para a instância 2, o atributo TimeStamp também se repete duas vezes, tendo seu valor agrupado e totalizando 0.822, destacando-o como o atributo de maior relevância para essa instância. O resultado para esta etapa, agrupando as duas instâncias, consta na Tabela 5.32.

Após calcular a proporção de cada atributo em relação à soma total de todos os atributos e instâncias (denominador da Equação 5.4) e ordená-los de maneira decrescente, obtemos o resultado final: o ranking dos atributos mais relevantes, como demonstrado na Tabela 5.33.

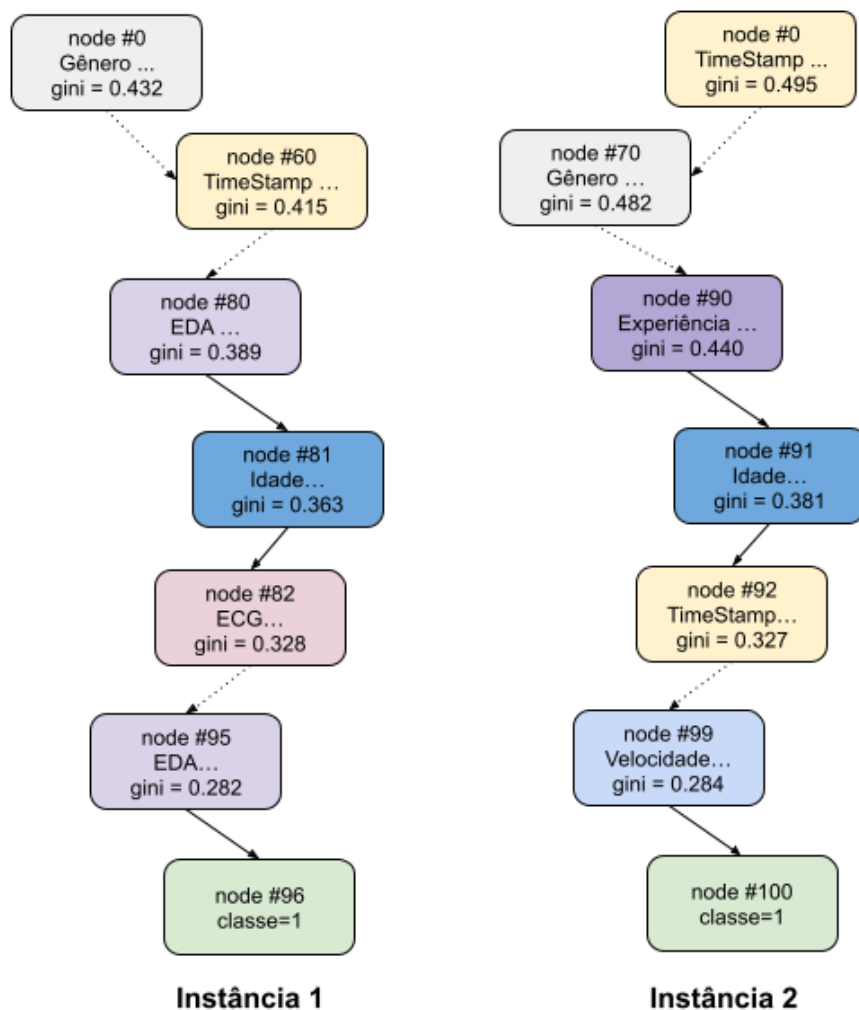


Figura 5.7: Valores de *Gini* para o caminho de decisão, para as instâncias: (1) [0, 60, 80, 81, 82, 95, 96] e (2) [0, 70, 90, 91, 92, 99, 100].

5.3 Avaliação dos Resultados

Conforme abordado no Capítulo 2, diversos elementos exercem influência sobre a *Cybersickness* (CS), como aspectos individuais, tais como Gênero, Idade, Condição de Saúde, entre outros. Além disso, existem também causas originadas por software, incluindo Flicker, Lag, Aceleração e Rotação. Logo, prever as razões por trás dos sintomas não é uma tarefa simples.

Estudos anteriores descritos na literatura [23, 26, 34, 28], exploraram a aplicação de biosinais, no entanto, não os empregaram na criação de rankings dos fatores mais significativos para as causas da CS. Porcino [12] investigou oito fatores (Tabela 5.1) associados aos sintomas da *Cybersickness*, contudo não fez uso de sinais fisiológicos.

Em nossa pesquisa, exploramos dois cenários distintos. No primeiro cenário, utilizamos dez fatores associados aos sintomas da *Cybersickness* (CS), sem a inclusão de biosinais

Atributo	Valor de Gini (Total)
Gênero	0.914
TimeStamp	1.237
EDA	0.671
Idade	0.744
ECG	0.328
Experiência	0.440
Velocidade	0.284

Tabela 5.32: Exemplo da Figura 5.7: Soma dos valores *Gini*, agrupados por atributo.

Atributo	Valor de Gini (Total)	Percentual
TimeStamp	1.237	26.79%
Gênero	0.914	19.79%
Idade	0.744	16.11%
EDA	0.671	14.53%
Experiência	0.440	9.53%
ECG	0.328	7.10%
Velocidade	0.284	6.15%

Tabela 5.33: Exemplo da Figura 5.7: Resultado final da Equação 5.4, ranking dos atributos mais relevantes em ordem de importância.

(conforme detalhado na Tabela 5.10). No segundo cenário, incorporamos o total de treze fatores relacionados à CS, incluindo os biosinais ACC, EDA e ECG (conforme apresentado na Tabela 5.11). A seguir, apresentaremos os resultados de cada cenário, além de compararmos o método utilizado em nosso estudo para identificação das causas, com o método proposto no trabalho de referência [12].

5.3.1 Resultado da Identificação das Causas sem Biosinais

Os rankings das principais características causadoras da CS, sem a inclusão dos biosinais, são apresentados para análise. Foram considerados dez atributos para ambos os jogos. Os rankings gerados para cada participante do experimento, podem ser visualizados nas Figuras 5.8 e 5.9.

As médias dos principais fatores são apresentadas na Tabela 5.34, nas colunas PDIs, em ordem de importância. Nos dois jogos utilizados em nossos experimentos, para este cenário, o Tempo de Exposição (TimeStamp) foi a causa mais relevante para o desencadeamento do desconforto, corroborando com a pesquisa de Porcino [12], que também obteve o mesmo resultado. Para o Jogo de Carro, a Velocidade ocupou o segundo lugar, seguida pela Sensibilidade ao Flicker em terceiro. Já para o Jogo de Voo, em segundo e terceiro lugar, os fatores que mais contribuíram para os sintomas foram, respectivamente, as Rota-

ções Y e Z. Segundo Fomenko et al. [66], as rotações em ambientes de Realidade Virtual, podem aumentar a probabilidade de conflitos sensoriais. Este resultado vai ao encontro de outros trabalhos disponíveis na literatura [66, 67], demonstrando a importância desses fatores na manifestação dos sintomas da CS.

Comparação dos Resultados dos Métodos PDI e PCS no cenário sem Biosinais

Também conduzimos a identificação das características principais que desencadeiam a CS, empregando a combinação do algoritmo *Random Forest* com o método proposto por Porcino [12] (*Potential-Cause Score* (PCS)), como ilustrado na Tabela 5.34. Os testes de Wilcoxon, demonstraram que para ambos os Jogos (Carro, **valor-p = 0.6953**; Voo, **valor-p= 0.6953**), não houve diferenças significativas entre a abordagem de Porcino [12] e a metodologia empregada em nosso estudo (*Potential Discomfort Indicator* (PDI)). Ambas as metodologias demonstraram resultados bastante semelhantes. Com um nível de significância de 0.05, todos os **valores-p** associados foram superiores a esse limite, indicando a falta de evidência para rejeitar a hipótese nula.

Jogo de Carro			Jogo de Voo		
Atributo	PDI ↓	PCS	Atributo	PDI ↓	PCS
TimeStamp	25.65	28.59	TimeStamp	30.04	32.49
Velocidade	13.73	13.49	Rotação Y	13.55	13.82
Sensibilidade ao Flicker	12.33	12.00	Rotação Z	12.72	14.93
Deficiências Visuais	11.11	12.49	Velocidade	11.32	10.97
Região de Interesse	10.58	11.16	Rotação X	10.19	10.34
Rotação X	6.31	5.49	FPS	8.15	2.80
Rotação Z	5.65	4.55	Deficiências Visuais	7.86	7.66
Rotação Y	5.54	4.86	Sensibilidade ao Flicker	3.12	4.04
Gênero	5.14	5.30	Gênero	2.20	2.15
FPS	3.98	2.07	Região de Interesse	0.86	0.80

Tabela 5.34: Ranking das médias percentuais das principais características causadoras da CS, **excluindo** os biosinais. Nosso estudo emprega algoritmo RF com PDI, enquanto a abordagem de Porcino [12] utiliza RF com PCS.

Ao buscar demonstrar que não há diferença significativa entre os dois métodos, é a hipótese nula que se torna o foco de nosso interesse. Ela evidencia que os resultados derivados dos valores de *Gini* previamente calculados (utilizando a biblioteca *scikit-learn*), são semelhantes aos obtidos pelo método proposto por Porcino [12].

5.3.2 Resultado da Identificação das Causas com Biosinais

Apresentamos também os rankings gerados para os dois jogos, os quais incluem os sinais fisiológicos. Esses resultados destacam como a inclusão dos biosinais (ACC, EDA e ECG) em nosso estudo, contribuiu para a identificação dos principais fatores causadores da CS. As análises estão detalhadas nas Figuras 5.10 e 5.11.

As médias dos principais fatores que contribuíram para a identificação da *Cybersickness*, de acordo com os nossos experimentos, podem ser observadas na Tabela 5.35, nas colunas PDIs. No Jogo de Carro, os movimentos do jogador (no eixo Z), capturados por um Acelerômetro (ACC), tiveram o maior impacto na identificação da CS. Esta descoberta pode ser elucidada pela "Teoria da Instabilidade Postural", conforme descrito por LaViola [16]. Em segundo lugar, o Tempo de Exposição (TimeStamp), também foi identificado como atributo relevante para o desencadeamento dos sintomas (também corroborando com Porcino [12]). Em terceiro lugar, a Atividade Eletrodérmica (EDA), em concordância com os trabalhos de Islam et al. [28] e Jung et al. [114], que também demonstraram uma correlação significativa com a CS. Os intervalos RRs (extraídos do ECG), também demonstraram ser um fator significativo nos sintomas. Os resultados da aplicação do ECG em nosso estudo, estão em concordância com outros resultados descritos na literatura [28, 23, 34].

No experimento com o Jogo de Voo, mais uma vez, o Tempo de Exposição (TimeStamp) foi o fator mais relevante, seguido pela EDA. Em terceiro lugar, encontramos a Rotação Y e em quarto lugar, os movimentos do jogador, extraídos do Acelerômetro (ACC) durante o experimento. Os princípios e fundamentos que explicam e relacionam os atributos mencionados neste parágrafo, são os mesmos que sustentam os atributos já relatados no experimento com o jogo de carro.

Comparação dos Resultados dos Métodos PDI e PCS no cenário com Biosinais

A combinação do algoritmo *Random Forest* e o método descrito no trabalho de referência [12] (PCS), também foi empregada neste cenário. Como evidenciado na Tabela 5.35, bem como nos resultados dos testes de Wilcoxon para os dois Jogos (Carro, **valor-p = 0.9443**; Voo, **valor-p = 0.8926**), tanto o método PDI quanto o PCS, também apresentaram resultados bastante similares. Com um nível de significância de 0.05, todos os **valores-p** obtidos, assim como na análise anterior, foram superiores a esse limiar, indicando a falta de evidências para rejeitar a hipótese nula.

Jogo de Carro			Jogo de Voo		
Atributo	PDI ↓	PCS	Atributo	PDI ↓	PCS
ACC	21.28	22.53	TimeStamp	23.42	24.83
TimeStamp	20.37	21.46	EDA	19.28	16.48
EDA	14.03	12.41	Rotação Y	11.39	11.02
Velocidade	7.60	7.58	ACC	11.06	11.34
Deficiências Visuais	6.79	7.64	Rotação Z	8.59	9.48
ECG	5.36	4.74	Velocidade	6.94	6.78
Sensibilidade ao Flicker	5.05	5.22	Rotação X	6.54	5.86
Região de Interesse	5.04	5.07	ECG	3.93	5.06
Rotação Z	3.76	3.14	Deficiências Visuais	3.89	3.77
Gênero	3.52	3.86	FPS	1.78	1.75
Rotação X	3.22	2.87	Sensibilidade ao Flicker	1.52	2.17
Rotação Y	2.69	2.34	Gênero	1.50	1.27
FPS	1.28	1.15	Região de Interesse	0.16	0.19

Tabela 5.35: Ranking das médias percentuais das principais características causadoras da CS, **incluindo** os biosinais que são indicativos dos sintomas dessa condição. O algoritmo RF com PDI adotado em nosso estudo, enquanto Porcino [12] emprega RF com PCS.

O resultado do teste de Wilcoxon evidencia a falta de diferenças significativas entre os dois métodos. Isso oferece uma contribuição adicional, fortalecendo a ideia de que diferentes abordagens podem levar a resultados semelhantes.




Figura 5.8: Principais atributos utilizados no processo de identificação da Cybersickness no Jogo de Carro, utilizando o algoritmo *Random Forest* (RF) e PDI, **sem** a inclusão dos Biosinais.




Figura 5.9: Principais atributos utilizados no processo de identificação da Cybersickness no Jogo de Voo, utilizando o algoritmo *Random Forest* (RF) e PDI, **sem** a inclusão dos Biosinais.




Figura 5.10: Principais atributos utilizados no processo de identificação da Cybersickness no Jogo de Carro, utilizando o algoritmo *Random Forest* (RF) e PDI, com a inclusão dos Biosinais.

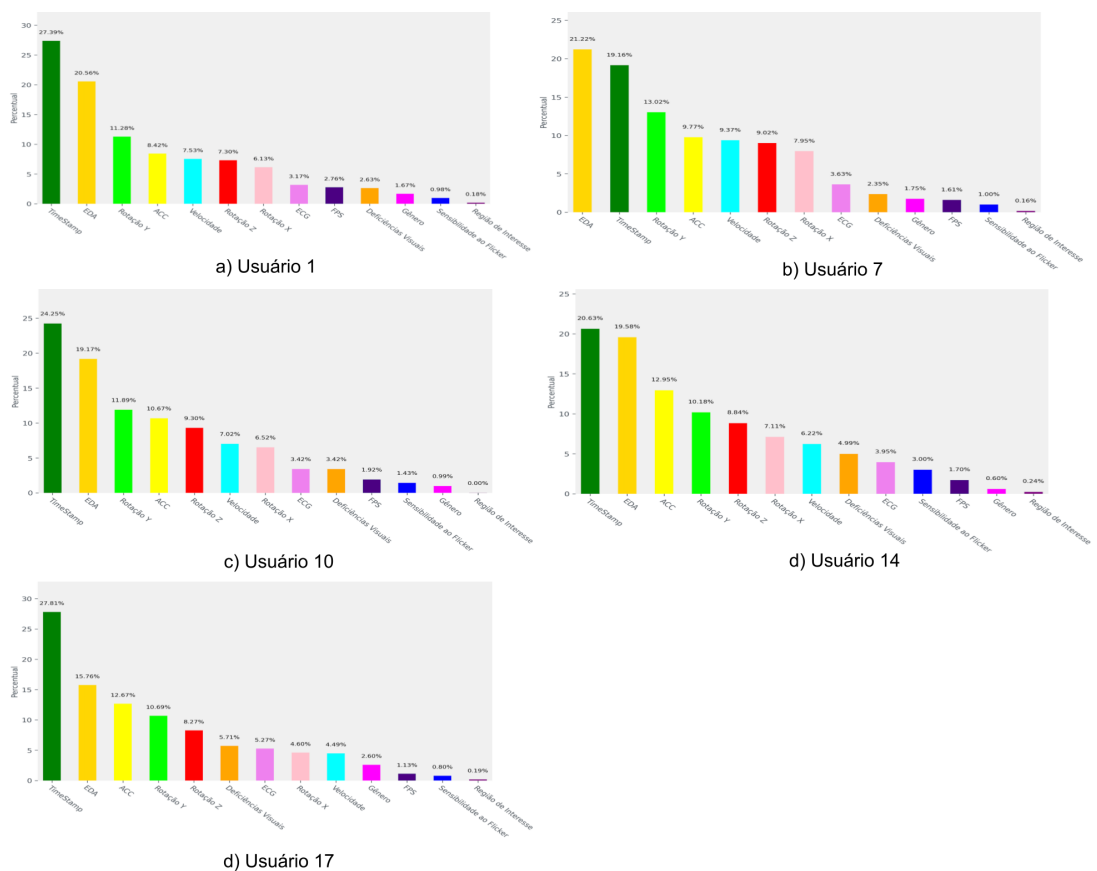


Figura 5.11: Principais atributos utilizados no processo de identificação da Cybersickness no Jogo de Voo, utilizando o algoritmo *Random Forest* (RF) e PDI, com a inclusão dos Biosinais.

Capítulo 6

Conclusão

Neste capítulo, finalizamos o estudo com as considerações finais, enfatizando suas principais contribuições e limitações. Também apontamos caminhos para futuras pesquisas e desenvolvimentos na área.

6.1 Considerações Finais

As pesquisas sobre *Cybersickness*, que abrangem métodos para identificar e avaliar sua intensidade em jogos de realidade virtual, tem ganhado atenção dos pesquisadores. No entanto, há uma lacuna significativa em estudos que buscam identificar os principais fatores que contribuem para as causas da CS, especialmente integrando biosinais, dados relacionados ao perfil do usuário e características do jogo. Adicionalmente, poucas pesquisas se dedicaram a utilizar *Machine Learning* Simbólico, visando elucidar o raciocínio por trás das decisões tomadas pelo modelo.

Nesta perspectiva, o presente estudo teve por objetivo investigar a utilização de biosinais na identificação das possíveis causas associadas à CS em jogos de Realidade Virtual (RV). Para isso, foi desenvolvido um algoritmo de ML Simbólico (com base no trabalho de Porcini [12]), com adaptações específicas para integrar os biosinais empregados nesta pesquisa. Adicionalmente, foram implementados dois métodos para a elaboração de um ranking dos principais fatores desencadeadores da CS: o *Potential Discomfort Indicator* (PDI) proposto neste estudo e o *Potential-Cause Score* (PCS), método apresentado no estudo de referência (Porcino [12]). Os resultados obtidos por ambos os métodos foram comparados para verificar possíveis diferenças estatisticamente significativas entre eles.

Para garantir um controle mais preciso na aquisição dos biosinais e permitir que os participantes relatassem os diferentes níveis de CS durante os experimentos, desenvolvemos no âmbito deste projeto, o software *Biosignal Collector* (BC). Esse software facilitou a co-

leta de dados de biosinais por meio de comunicação TCP/IP com o software OpenSignals, utilizado em conjunto com o BITalino.

Realizamos análises preliminares, que envolveram o cálculo das pontuações VRSQ para cada experiência. Os resultados do VRSQ (Seção 4.9.1), indicaram que no Jogo de Carro, os participantes do sexo masculino apresentaram um nível de desconforto maior em comparação com os do sexo feminino. Já para o Jogo de Voo, observou-se que o gênero feminino registrou uma pontuação geral maior. Além disso, investigamos as alterações fisiológicas tanto no estado de linha de base (em repouso) quanto durante a experiência. Adicionalmente, conduzimos outras análises, como a avaliação do percentual de desconforto relatado por participantes de diferentes sexos, e a análise dos percentuais relatados conforme os níveis de sintomas.

De acordo com os resultados analisados na Seção 4.9.3, os testes t realizados, revelaram uma diferença estatisticamente significativa, entre as médias dos biosinais coletados durante as condições de linha de base e aquelas registradas quando os usuários experimentaram sintomas de *Cybersickness*. Além disso, ao analisarmos os níveis de CS relatados durante o experimento, segmentados por gênero no contexto do Jogo de Carro, observamos que os homens relataram sentir mais desconforto do que as mulheres. Esse resultado foi corroborado pelo Teste Exato de Fisher, utilizando os totais relatados como base. Essa constatação reforça as descobertas de Porcino [12], cujo estudo também apontou que os participantes do sexo masculino experimentaram um desconforto maior em comparação com os do sexo feminino, durante a imersão com o mesmo jogo.

No contexto deste estudo, optamos por empregar os classificadores simbólicos baseados em árvores de decisão, devido à sua eficácia em elucidar o processo decisório adotado pelo modelo. Conduzimos análises dos classificadores, assim como dos atributos mais relevantes para a construção do modelo. Como apresentado na Seção 5.2.1, concluímos que, utilizando a ferramenta Weka, o algoritmo *Random Forest* apresentou o melhor desempenho em todos os cenários analisados.

No que concerne aos atributos, dois conjuntos foram gerados: um contendo dez atributos (sem os biosinais) e outro composto por treze, incluindo os biosinais ACC, EDA e ECG. A Seção 5.2.2, apresenta as diversas combinações exploradas para o treinamento do modelo, incluindo os cenários sem a inclusão de biosinais, a inclusão isolada de cada biosinal, combinações entre eles e a avaliação do modelo com todos os biosinais. Em cada configuração de avaliação, foram empregados dois algoritmos (DT e RF), calculando as pontuações AUC tanto durante o treinamento quanto para o teste do modelo.

Nesta pesquisa, o procedimento adotado para identificar as principais causas de desconforto, foi minuciosamente explicado e exemplificado. Adicionalmente, foram apresentados os resultados finais relacionados a um dos objetivos do estudo, que é a criação de um

ranking dos principais fatores causadores dos sintomas da CS. Esta etapa incluiu a apresentação dos gráficos individuais de cada usuário em dois cenários: com e sem a inclusão dos biosinais, além da média geral das características identificadas por jogo.

Nos dois jogos empregados em nossos experimentos, no cenário sem a inclusão dos biosinais, o Tempo de Exposição (TimeStamp) se destacou como a causa mais relevante para o desencadeamento do desconforto, corroborando com a pesquisa conduzida pelo Porcino [12], que também obteve resultados semelhantes. No Jogo de Carro, além do tempo de exposição, destacamos a importância dos atributos Velocidade e Sensibilidade ao Flicker. Já no Jogo de Voo, além do tempo de exposição, os fatores que mais contribuíram foram as Rotações Y e Z (resultados também encontrados em outros trabalhos [66, 67]).

Ao considerar os biosinais, observamos que, no Jogo de Carro, os movimentos do jogador (registrados pelo Acelerômetro - ACC), demonstraram ter maior impacto na identificação do desconforto. Além disso, identificamos que o Tempo de Exposição, a Atividade Eletrodérmica (EDA) e os intervalos RRs, extraídos do ECG, são também fatores de grande importância na previsão da CS. Já para o Jogo de Voo, o Tempo de Exposição, a EDA e a Rotação Y destacaram-se como os fatores mais bem posicionados no ranking.

6.2 Limitações e Trabalhos Futuros

Existem algumas limitações neste estudo. Inicialmente, o número de participantes do experimento é limitado, e alguns dados coletados precisaram ser excluídos de nossa análise devido a diversos motivos. Ocorreram problemas de conectividade Bluetooth entre a placa BITalino e o computador, onde o software BC estava instalado, além de dificuldades na fixação dos eletrodos. Adicionalmente, o sensor utilizado para capturar os movimentos do jogador durante a experiência tinha a capacidade de medir apenas a aceleração no eixo Z (para frente e para trás). Portanto, movimentos em outras direções (X e Y) não foram analisados.

Devido à necessidade de gerar um único conjunto de dados a partir de duas fontes (do jogo e dos biosinais), enfrentamos alguns desafios na sincronização dos dados de forma consistente. Em certos casos, ocorreu um atraso no início da captura dos dados de biosinais em relação à experiência do jogador. Para contornar esse problema, optamos por descartar as instâncias coletadas do jogo que não se alinhavam com as instâncias dos biosinais, devido à diferença de tempo entre os dois conjuntos de dados.

Existem ainda fatores limitantes associados a pontos em aberto na pesquisa. É preciso aprofundar a investigação com outros públicos (em relação a faixas etárias), além de incluir um número maior de participantes. Também é essencial explorar a possível

associação entre indivíduos que apresentam sintomas de *Motion Sickness*, desencadeado por movimentos reais, e *Cybersickness*, provocado pela exposição a ambientes de RV.

A aquisição de biosinais pode requerer o uso de sensores externos, uma vez que os dispositivos HMDs mais antigos, como HTC Vive e Oculus Quest, não possuem sensores incorporados diretamente. No entanto, vários novos dispositivos HMDs disponíveis no mercado já permitem a coleta de dados de alguns sensores integrados, como rastreamento ocular e de cabeça [85, 32]. Diante disso, é possível explorar outros aspectos fisiológicos do usuário, em relação aos sintomas da CS. Adicionalmente, é importante investigar a mitigação da *Cybersickness* (CS) por meio de feedbacks dinâmicos dos usuários, utilizando os sensores integrados aos dispositivos HMD.

Por fim, identificar as causas da *Cybersickness* é um passo importante, pois permite aos desenvolvedores de tecnologias de RV, desenvolver estratégias mais efetivas para mitigar os sintomas, tornando a experiência do usuário mais agradável. Neste sentido, avançar com este trabalho significa impactar positivamente a vida dos usuários de Realidade Virtual.

Referências

- [1] Kim, Hyun K, Jaehyun Park, Yeongcheol Choi e Mungyeong Choe: *Virtual reality sickness questionnaire (vrsq): Motion sickness measurement index in a virtual reality environment*. Applied ergonomics, 69:66–73, 2018. vii, viii, xvii, 17, 20, 120
- [2] Miroshnichenko, Tima: *A woman in blue jacket using virtual reality goggles and controllers*. 2023. <https://www.pexels.com>, acesso em 2023/04/13. xii, 8
- [3] Alqahtani, Asmaa Saeed, Lamyia Foaud Daghestani e Lamiaa Fattouh Ibrahim: *Environments and system types of virtual reality technology in stem: A survey*. International Journal of Advanced Computer Science and Applications (IJACSA), 8(6), 2017. xii, 8, 20
- [4] Reason, James T e Joseph John Brand: *Motion sickness*. Academic press, 1975. xii, 1, 9, 10, 12, 14, 83
- [5] NeuroSky: *Making sense of eeg bands*, 2015. <https://neurosky.com/2015/05/greek-alphabet-soup-making-sense-of-eeg-bands/>, acesso em 2023-04-22. xii, 21
- [6] Chang, Won Du: *Electrooculograms for human-computer interaction: A review*. Sensors, 19(12):2690, 2019. xii, 22, 23
- [7] Wolpert, Nicolai, Ignacio Rebollo e Catherine Tallon-Baudry: *Electrogastrography for psychophysiological research: Practical considerations, analysis pipeline, and normative data in a large sample*. Psychophysiology, 57(9):e13599, 2020. xii, 24
- [8] Dawson, Michael E, Anne M Schell e Diane L Filion: *The electrodermal system*. 2017. xii, 26, 27
- [9] Mellit, Adel, Alessandro Massi Pavan, Emanuele Ogliari, Sonia Leva e Vanni Lughi: *Advanced methods for photovoltaic output power forecasting: A review*. Applied Sciences, 10(2):487, 2020. xii, 30
- [10] Alom, Md Zahangir, Tarek M Taha, Chris Yakopcic, Stefan Westberg, Paheding Sidike, Mst Shamima Nasrin, Mahmudul Hasan, Brian C Van Essen, Abdul AS Awwal e Vijayan K Asari: *A state-of-the-art survey on deep learning theory and architectures*. electronics, 8(3):292, 2019. xii, 31
- [11] Husein, Munir e Il Yop Chung: *Day-ahead solar irradiance forecasting for microgrids using a long short-term memory recurrent neural network: A deep learning approach*. Energies, 12(10):1856, 2019. xii, 34

- [12] Porcino, Thiago Malheiros: *Cybersickness Analysis Using Symbolic Machine Learning Algorithms*. Tese de Doutorado, Universidade Federal Fluminense - UFF, Niterói-RJ, Brasil, 2021. xii, xiii, xv, xvi, xvii, 3, 4, 5, 6, 15, 18, 43, 45, 51, 52, 57, 66, 73, 74, 75, 76, 81, 82, 84, 85, 93, 94, 95, 96, 97, 98, 101, 102, 103, 119, 120
- [13] Biosignals, Plux: *Getting started: Bitolino electrodermal activity (eda) sensor*. 2023. <https://www.pluxbiosignals.com>, acesso em 2023/06/21. xii, xiii, 53, 55
- [14] Biosignals, Plux: *Accelerometer (acc) assembled sensor data sheet*. 2024. <https://www.pluxbiosignals.com>, acesso em 2024/03/09. xiii, 55
- [15] Biosignals, Plux: *Electrocardiography (ecg) sensor data sheet*. 2023. <https://www.pluxbiosignals.com>, acesso em 2023/06/21. xiii, 55
- [16] LaViola Jr, Joseph J: *A discussion of cybersickness in virtual environments*. ACM Sigchi Bulletin, 32(1):47–56, 2000. 1, 2, 11, 12, 13, 14, 15, 16, 66, 70, 83, 97
- [17] Vince, John: *Introduction to virtual reality*. Springer Science & Business Media, 2004. 1
- [18] Stanney, Kay M e Phillip Hash: *Locus of user-initiated control in virtual environments: Influences on cybersickness*. Presence, 7(5):447–459, 1998. 1, 11
- [19] Caserman, Polona, Augusto Garcia-Agundez, Alvar Gámez Zerban e Stefan Göbel: *Cybersickness in current-generation virtual reality head-mounted displays: systematic review and outlook*. Virtual Reality, 25(4):1153–1170, 2021. 1
- [20] Riccio, Gary E e Thomas A Stoffregen: *An ecological theory of motion sickness and postural instability*. Ecological psychology, 3(3):195–240, 1991. 2, 13
- [21] Kennedy, Robert S e Michael G Lilienthal: *Implications of balance disturbances following exposure to virtual reality systems*. Em *Proceedings Virtual Reality Annual International Symposium '95*, páginas 35–39. IEEE, 1995. 2
- [22] Kolasinski, Eugenia M: *Simulator sickness in virtual environments*. 1995. 2, 14, 38, 66
- [23] Garcia-Agundez, Augusto, Christian Reuter, Polona Caserman, Robert Konrad e Stefan Göbel: *Identifying cybersickness through heart rate variability alterations*. International Journal of Virtual Reality, 19(1):1–10, 2019. 2, 3, 19, 23, 37, 94, 97
- [24] Saredakis, Dimitrios, Ancret Szpak, Brandon Birckhead, Hannah AD Keage, Albert Rizzo e Tobias Loetscher: *Factors associated with virtual reality sickness in head-mounted displays: a systematic review and meta-analysis*. Frontiers in human neuroscience, 14:96, 2020. 2
- [25] Kourtesis, Panagiotis, Simona Collina, Leonidas AA Doulas e Sarah E MacPherson: *Technological competence is a pre-condition for effective implementation of virtual reality head mounted displays in human neuroscience: a technological review and meta-analysis*. Frontiers in Human Neuroscience, 13:342, 2019. 2

- [26] Krokos, Eric e Amitabh Varshney: *Quantifying vr cybersickness using eeg*. *Virtual Reality*, 26(1):77–89, 2022. 2, 20, 38, 94
- [27] Kennedy, Robert S, Norman E Lane, Kevin S Berbaum e Michael G Lilienthal: *Simulator sickness questionnaire: An enhanced method for quantifying simulator sickness*. *The international journal of aviation psychology*, 3(3):203–220, 1993. 2, 11, 17, 20
- [28] Islam, Rifatul, Yonggun Lee, Mehrad Jaloli, Imtiaz Muhammad, Dakai Zhu, Paul Rad, Yufei Huang e John Quarles: *Automatic detection and prediction of cybersickness severity using deep neural networks from user’s physiological signals*. Em *2020 IEEE international symposium on mixed and augmented reality (ISMAR)*, páginas 400–411. IEEE, 2020. 2, 17, 19, 20, 23, 26, 41, 70, 94, 97
- [29] Kennedy, Robert S, Julie M Drexler, Daniel E Compton, Kay M Stanney, D Susan Lanham, Deborah L Harm *et al.*: *Configural scoring of simulator sickness, cybersickness and space adaptation syndrome: Similarities and differences*. *Virtual and adaptive environments: Applications, implications, and human performance issues*, 247, 2003. 2
- [30] Young, Sean D, Bernard D Adelstein e Stephen R Ellis: *Demand characteristics in assessing motion sickness in a virtual environment: Or does taking a motion sickness questionnaire make you sick?* *IEEE transactions on visualization and computer graphics*, 13(3):422–428, 2007. 2
- [31] Sawada, Yuki, Yoshihiro Itaguchi, Masami Hayashi, Kosuke Aigo, Takuya Miyagi, Masayuki Miki, Tetsuya Kimura e Makoto Miyazaki: *Effects of synchronised engine sound and vibration presentation on visually induced motion sickness*. *Scientific reports*, 10(1):1–10, 2020. 3, 18
- [32] Islam, Rifatul, Kevin Desai e John Quarles: *Cybersickness prediction from integrated hmd’s sensors: A multimodal deep fusion approach using eye-tracking and head-tracking data*. Em *2021 IEEE international symposium on mixed and augmented reality (ISMAR)*, páginas 31–40. IEEE, 2021. 3, 8, 104
- [33] Miljković, Nadica, Nenad B Popović, Milana Prodanov e Jaka Sodnik: *Assessment of sickness in virtual environments*. Em *Proceedings of the 9th International Conference on Information Society and Technology (ICIST 2019)*, 2019. 3
- [34] Qu, Chenxin, Xiaoping Che, Siqi Ma e Shuqin Zhu: *Bio-physiological-signals-based vr cybersickness detection*. *CCF Transactions on Pervasive Computing and Interaction*, 4(3):268–284, 2022. 3, 17, 18, 19, 20, 22, 23, 40, 52, 53, 94, 97
- [35] Islam, Rifatul, Samuel Ang e John Quarles: *Cybersense: A closed-loop framework to detect cybersickness severity and adaptively apply reduction techniques*. Em *2021 IEEE Conference on Virtual Reality and 3D User Interfaces Abstracts and Workshops (VRW)*, páginas 148–155. IEEE, 2021. 3, 20
- [36] LaValle, Steven M.: *Virtual Reality*. Cambridge University Press, 2020. 7

- [37] Jerald, J.: *The vr book: Human-centered design for virtual reality*. Available at: <https://www.perlego.com/book/4181537/the-vr-book-human-centered-design-for-virtual-reality-pdf>, 2015. Accessed on 7 September 2023. 7
- [38] Bamodu, Oluleke e Xu Ming Ye: *Virtual reality and virtual reality system components*. Em *Advanced materials research*, volume 765, páginas 1169–1172. Trans Tech Publ, 2013. 7, 8
- [39] Isdale, J.: *What is virtual reality? a web-based introduction*. Available at: <http://masters.donntu.ru/2012/fknt/chernyaev/library/article7.htm>. Accessed on September 27, 2023. 8
- [40] Tori, Romero, Claudio Kirner e Robson Augusto Siscoutto: *Fundamentos e tecnologia de realidade virtual e aumentada*. Editora SBC Porto Alegre, 2006. 8
- [41] Jensen, Lasse e Flemming Konradsen: *A review of the use of virtual reality head-mounted displays in education and training*. *Education and Information Technologies*, 23:1515–1529, 2018. 9
- [42] Irwin, JA: *The pathology of sea-sickness*. *The Lancet*, 118(3039):907–909, 1881. 9, 10
- [43] Johnson, David M: *Introduction to and review of simulator sickness research*. 2005. 9
- [44] Gianaros, Peter J, Eric R Muth, J Toby Mordkoff, Max E Levine e Robert M Stern: *A questionnaire for the assessment of the multiple dimensions of motion sickness*. *Aviation, space, and environmental medicine*, 72(2):115, 2001. 9, 17
- [45] Graybiel, A, RS Kellogg e RS Kennedy: *Motion sickness symptomatology of labyrinthine defective and normal subjects during zero gravity maneuvers*. *Relatório Técnico*, 1964. 10
- [46] Kennedy, R. S., J. Drexler e R. C. Kennedy: *Research in visually induced motion sickness*. *Applied ergonomics*, 41(4):494–503, 2010. <https://www.sciencedirect.com/science/article/abs/pii/S0003687009001574>. 10
- [47] Bos, Jelte E, Willem Bles e Eric L Groen: *A theory on visually induced motion sickness*. *Displays*, 29(2):47–57, 2008. <https://www.sciencedirect.com/science/article/abs/pii/S0141938207000935>, Accessed on 27th September 2023. 10
- [48] Keshavarz, Behrang, Katlyn Peck, Sia Rezaei e Babak Taati: *Detecting and predicting visually induced motion sickness with physiological measures in combination with machine learning techniques*. *International Journal of Psychophysiology*, 176:14–26, 2022. 10, 61
- [49] Kennedy, RS, LJ Hettlinger e MG Lilienthal: *Simulator sickness*. *Motion and space sickness*, páginas 317–341, 1988. 11

- [50] Kennedy, RS, KS Berbaum, MG Lilienthal, WP Dunlap e BE Mulligan: *Guidelines for alleviation of simulator sickness symptomatology*. Relatório Técnico, NAVAL TRAINING SYSTEMS CENTER ORLANDO FL, 1987. 12, 14
- [51] Kemeny, Andras, Jean Rémy Chardonnet e Florent Colombet: *Getting rid of cybersickness*. Virtual Reality, Augmented Reality, and Simulators, 2020. 12, 15
- [52] Treisman, Michel: *Motion sickness: an evolutionary hypothesis*. Science, 197(4302):493–495, 1977. 13
- [53] Koohestani, Afsaneh, Darius Nahavandi, Houshyar Asadi, Parham M Kebria, Abbas Khosravi, Roohallah Alizadehsani e Saeid Nahavandi: *A knowledge discovery in motion sickness: a comprehensive literature review*. IEEE access, 7:85755–85770, 2019. 14, 15
- [54] Mourant, Ronald R e Thara R Thattacherry: *Simulator sickness in a virtual environments driving simulator*. Em *Proceedings of the human factors and ergonomics society annual meeting*, volume 44, páginas 534–537. SAGE Publications Sage CA: Los Angeles, CA, 2000. 14, 66
- [55] Lawther, Anthony e Michael J Griffin: *A survey of the occurrence of motion sickness amongst passengers at sea*. Aviation, space, and environmental medicine, 59(5):399–406, 1988. 14
- [56] Domeyer, Joshua E, Nicholas D Cassavaugh e Richard W Backs: *The use of adaptation to reduce simulator sickness in driving assessment and research*. Accident Analysis & Prevention, 53:127–132, 2013. 14
- [57] Lackner, JAMES: *Human orientation, adaptation, and movement control*. Motion sickness, visual displays, and armored vehicle design, páginas 28–50, 1990. 14
- [58] Tan, Chek Tien, Leon Cewei Foo, Adriel Yeo, Jeannie Su Ann Lee, Edmund Wan, Xiao Feng Kenan Kok e Megani Rajendran: *Understanding user experiences across vr walking-in-place locomotion methods*. Em *Proceedings of the 2022 CHI Conference on Human Factors in Computing Systems*, páginas 1–13, 2022. 15
- [59] Lo, WT e Richard HY So: *Cybersickness in the presence of scene rotational movements along different axes*. Applied ergonomics, 32(1):1–14, 2001. 15
- [60] Palmisano, Stephen, Frederick Bonato, Andrea Bubka e John Folder: *Vertical display oscillation effects on forward vection and simulator sickness*. Aviation, space, and environmental medicine, 78(10):951–956, 2007. 15
- [61] Biocca, Frank: *Will simulation sickness slow down the diffusion of virtual environment technology?* Presence: Teleoperators & Virtual Environments, 1(3):334–343, 1992. 16
- [62] Wu, Fei e Evan Suma Rosenberg: *Adaptive field-of-view restriction: Limiting optical flow to mitigate cybersickness in virtual reality*. Em *Proceedings of the 28th ACM Symposium on Virtual Reality Software and Technology*, páginas 1–11, 2022. 16

- [63] Blum, Tobias, Matthias Wieczorek, André Aichert, Radhika Tibrewal e Nassir Navab: *The effect of out-of-focus blur on visual discomfort when using stereo displays*. Em *2010 IEEE International Symposium on Mixed and Augmented Reality*, páginas 13–17. IEEE, 2010. 16
- [64] Hoffman, David M, Ahna R Girshick, Kurt Akeley e Martin S Banks: *Vergence–accommodation conflicts hinder visual performance and cause visual fatigue*. *Journal of vision*, 8(3):33–33, 2008. 16
- [65] Prothero, Jerrold Douglas: *The role of rest frames in vection, presence and motion sickness*. University of Washington, 1998. 16
- [66] Fomenko, Ivan e Taninwat Kaewpankan: *Thrill vs. cybersickness: A study on camera settings’ impact on immersion and cybersickness in vr racing games.*, 2022. 16, 83, 96, 103
- [67] Bonato, Frederick, Andrea Bubka e Stephen Palmisano: *Combined pitch and roll and cybersickness in a virtual environment*. *Aviation, space, and environmental medicine*, 80(11):941–945, 2009. 16, 96, 103
- [68] Sevinc, Volkan e Mehmet Ilker Berkman: *Psychometric evaluation of simulator sickness questionnaire and its variants as a measure of cybersickness in consumer virtual environments*. *Applied ergonomics*, 82:102958, 2020. 18
- [69] Stone III, William Bruce: *Psychometric evaluation of the Simulator Sickness Questionnaire as a measure of cybersickness*. Tese de Doutorado, Iowa State University, 2017. 18, 20
- [70] Keshavarz, Behrang e Heiko Hecht: *Validating an efficient method to quantify motion sickness*. *Human factors*, 53(4):415–426, 2011. 18
- [71] McHugh, Natalie, Sungchul Jung, Simon Hoermann e Robert W Lindeman: *Investigating a physical dial as a measurement tool for cybersickness in virtual reality*. Em *Proceedings of the 25th ACM Symposium on Virtual Reality Software and Technology*, páginas 1–5, 2019. 18
- [72] Arshad, Iqra, Paulo De Mello, Martin Ender, Jason D McEwen e Elisa R Ferré: *Reducing cybersickness in 360-degree virtual reality*. *Multisensory Research*, 35(2):203–219, 2021. 18
- [73] Rathke, Juliano Elesbão *et al.*: *Sistema de processamento de sinais biomédicos: módulos didáticos de aquisição de ecg, emg, eeg e conversão analógico-digital de biosinais*. 2008. 19
- [74] Budhiraja, Pulkit, Mark Roman Miller, Abhishek K Modi e David Forsyth: *Rotation blurring: use of artificial blurring to reduce cybersickness in virtual reality first person shooters*. arXiv preprint arXiv:1710.02599, 2017. 19, 43
- [75] Cao, Zekun, Jason Jerald e Regis Kopper: *Visually-induced motion sickness reduction via static and dynamic rest frames*. Em *2018 IEEE conference on virtual reality and 3D user interfaces (VR)*, páginas 105–112. IEEE, 2018. 19

- [76] Chang, EunHee, InJae Hwang, Hyeonjin Jeon, Yeseul Chun, Hyun Taek Kim e Changhoon Park: *Effects of rest frames on cybersickness and oscillatory brain activity*. Em *2013 International Winter Workshop on Brain-Computer Interface (BCI)*, páginas 62–64. IEEE, 2013. 19
- [77] Schmidhuber, Jürgen: *Deep learning in neural networks: An overview*. *Neural networks*, 61:85–117, 2015. 20
- [78] Hochreiter, Sepp e Jürgen Schmidhuber: *Long short-term memory*. *Neural computation*, 9(8):1735–1780, 1997. 20
- [79] Werbos, Paul: *Beyond regression: New tools for prediction and analysis in the behavioral sciences*. PhD thesis, Committee on Applied Mathematics, Harvard University, Cambridge, MA, 1974. 20
- [80] Tian, Nana, Phil Lopes e Ronan Boulic: *A review of cybersickness in head-mounted displays: raising attention to individual susceptibility*. *Virtual Reality*, 26(4):1409–1441, 2022. 20
- [81] Blinowska, Katarzyna e Piotr Durka: *Electroencephalography (eeg)*. *Wiley encyclopedia of biomedical engineering*, 2006. 20
- [82] Binnie, CD e PF Prior: *Electroencephalography*. *Journal of Neurology, Neurosurgery & Psychiatry*, 57(11):1308–1319, 1994. 20
- [83] Liao, Chung Yen, Shao Kuo Tai, Rung Ching Chen e Hendry Hendry: *Using eeg and deep learning to predict motion sickness under wearing a virtual reality device*. *Ieee Access*, 8:126784–126796, 2020. 21
- [84] Lopes, Phil, Nana Tian e Ronan Boulic: *Eye thought you were sick! exploring eye behaviors for cybersickness detection in vr*. Em *Proceedings of the 13th ACM SIGGRAPH Conference on Motion, Interaction and Games*, páginas 1–10, 2020. 22
- [85] Chang, Eunhee, Hyun Taek Kim e Byounghyun Yoo: *Predicting cybersickness based on user’s gaze behaviors in hmd-based virtual reality*. *Journal of Computational Design and Engineering*, 8(2):728–739, 2021. 22, 104
- [86] Bimberg, Pauline, Tim Weissker e Alexander Kulik: *On the usage of the simulator sickness questionnaire for virtual reality research*. Em *2020 IEEE conference on virtual reality and 3D user interfaces abstracts and workshops (VRW)*, páginas 464–467. IEEE, 2020. 22
- [87] Iskander, Julie, Mohammed Hossny e Saeid Nahavandi: *A review on ocular biomechanic models for assessing visual fatigue in virtual reality*. *IEEE Access*, 6:19345–19361, 2018. 22
- [88] Brown, Malcolm, Michael Marmor, Eberhard Zrenner, Mitchell Brigell e Michael Bach: *Iscev standard for clinical electro-oculography (eog) 2006*. *Documenta ophthalmologica*, 113:205–212, 2006. 22

- [89] Iwasaki, Masaki, Christoph Kellinghaus, Andreas V Alexopoulos, Richard C Burgess, Arun N Kumar, Yanning H Han, Hans O Lüders e R John Leigh: *Effects of eyelid closure, blinks, and eye movements on the electroencephalogram*. *Clinical Neurophysiology*, 116(4):878–885, 2005. 22
- [90] Vive: *Vive pro eye*. <https://www.vive.com/sea/product/vive-pro-eye/overview>, 2024. Acessado em 20 de Abril de 2024. 23
- [91] Tobii: *Hp reverb g2 omnicept edition*. <https://www.tobii.com/products/integration/xr-headsets/device-integrations/hp-reverb-g2-omnicept-edition>, 2024. Acessado em 20 de Abril de 2024. 23
- [92] Labs, Pupil: *Vr/ar*. <https://pupil-labs.com/products/vr-ar>, 2024. Acessado em 20 de Abril de 2024. 23
- [93] Alberdi, Ane, Asier Aztiria e Adrian Basarab: *Towards an automatic early stress recognition system for office environments based on multimodal measurements: A review*. *Journal of biomedical informatics*, 59:49–75, 2016. 23, 24, 52
- [94] Berkaya, Selcan Kaplan, Alper Kursat Uysal, Efnan Sora Gunal, Semih Ergin, Serkan Gunal e M Bilginer Gulmezoglu: *A survey on ecg analysis*. *Biomedical Signal Processing and Control*, 43:216–235, 2018. 23, 24
- [95] Awal, Md Abdul, Sheikh Shanawaz Mostafa, Mohiuddin Ahmad e Mohd Abdur Rashid: *An adaptive level dependent wavelet thresholding for ecg denoising*. *Biocybernetics and biomedical engineering*, 34(4):238–249, 2014. 23, 61
- [96] Reyero Lobo, Paula e Pablo Perez: *Heart rate variability for non-intrusive cyber-sickness detection*. Em *ACM International Conference on Interactive Media Experiences*, páginas 221–228, 2022. 24
- [97] Yin, Jieyun e Jiande DZ Chen: *Electrogastrography: methodology, validation and applications*. *Journal of neurogastroenterology and motility*, 19(1):5, 2013. 24
- [98] Alvarez, Walter C: *The electrogastrogram and what it shows*. *Jama*, 78:1116–1119, 1922. 24
- [99] Chen, Jiande e Richard W McCallum: *Electrogastrography: measurement, analysis and prospective applications*. *Medical and Biological Engineering and Computing*, 29:339–350, 1991. 24
- [100] Riezzo, Giuseppe, Francesco Russo e Flavia Indrio: *Electrogastrography in adults and children: the strength, pitfalls, and clinical significance of the cutaneous recording of the gastric electrical activity*. *BioMed research international*, 2013, 2013. 24
- [101] Jakus, Grega, Jaka Sodnik e Nadica Miljković: *Electrogastrogram-derived features for automated sickness detection in driving simulator*. *Sensors*, 22(22):8616, 2022. 24

- [102] Cheung, Bob e Peter Vaitkus: *Perspectives of electrogastrography and motion sickness*. Brain research bulletin, 47(5):421–431, 1998. 25
- [103] Hu, Senqi, Kathleen A McChesney, Kathryn A Player, Amy M Bahl, Jessica B Buchanan e Jason E Scozzafava: *Systematic investigation of physiological correlates of motion sickness induced by viewing an optokinetic rotating drum*. Aviation, space, and environmental medicine, 1999. 25
- [104] Murakami, Haruaki, Hideo Matsumoto, Daisuke Ueno, Akimasa Kawai, Takaaki Ensako, Yuko Kaida, Toshiya Abe, Hisako Kubota, Masaharu Higashida, Hiroshi Nakashima *et al.*: *Current status of multichannel electrogastrography and examples of its use*. Journal of Smooth Muscle Research, 49:78–88, 2013. 25
- [105] Verhagen, Marc AMT, Leonard J Van Schelven, Melvin Samsom e André JPM Smout: *Pitfalls in the analysis of electrogastrographic recordings*. Gastroenterology, 117(2):453–460, 1999. 25
- [106] Kim, Young Youn, Hyun Ju Kim, Eun Nam Kim, Hee Dong Ko e Hyun Taek Kim: *Characteristic changes in the physiological components of cybersickness*. Psychophysiology, 42(5):616–625, 2005. 25, 38
- [107] Komorowski, Dariusz, Stanislaw Pietraszek, Ewaryst Tkacz e Ivo Provaznik: *The extraction of the new components from electrogastrogram (egg), using both adaptive filtering and electrocardiographic (ecg) derived respiration signal*. Biomedical engineering online, 14:1–16, 2015. 25
- [108] Merletti, Roberto e Philip J Parker: *Electromyography: physiology, engineering, and non-invasive applications*, volume 11. John Wiley & Sons, 2004. 25
- [109] Sugiarto, Tommy, Chun Lung Hsu, Chi Tien Sun, Wei Chun Hsu, Shu Hao Ye e Kuan Ting Lu: *Surface emg vs. high-density emg: Tradeoff between performance and usability for head orientation prediction in vr application*. IEEE Access, 9:45418–45427, 2021. 25
- [110] Recenti, Marco, Carlo Ricciardi, Romain Aubonnet, Ilaria Picone, Deborah Jacob, Halldór ÁR Svansson, Sólveig Agnarsdóttir, Gunnar H Karlsson, Valdís Baeringsdóttir, Hannes Petersen *et al.*: *Toward predicting motion sickness using virtual reality and a moving platform assessing brain, muscles, and heart signals*. Frontiers in Bioengineering and Biotechnology, 9:635661, 2021. 25
- [111] Nagai, Yoko, Christopher Iain Jones e Arjune Sen: *Galvanic skin response (gsr)/electrodermal/skin conductance biofeedback on epilepsy: a systematic review and meta-analysis*. Frontiers in neurology, 10:377, 2019. 26
- [112] Shi, Yu, Natalie Ruiz, Ronnie Taib, Eric Choi e Fang Chen: *Galvanic skin response (gsr) as an index of cognitive load*. Em CHI’07 extended abstracts on Human factors in computing systems, páginas 2651–2656, 2007. 26

- [113] Electrodermal Measures, Society for Psychophysiological Research Ad Hoc Committee on, Wolfram Boucsein, Don C Fowles, Sverre Grimnes, Gershon Ben-Shakhar, Walton T Roth, Michael E Dawson e Diane L Filion: *Publication recommendations for electrodermal measurements*. *Psychophysiology*, 49(8):1017–1034, 2012. 26
- [114] Jung, Sungchul, Richard Li, Ryan McKee, Mary C Whitton e Robert W Lindeman: *Floor-vibration vr: mitigating cybersickness using whole-body tactile stimuli in highly realistic vehicle driving experiences*. *IEEE Transactions on Visualization & Computer Graphics*, 27(05):2669–2680, 2021. 26, 97
- [115] Shapiro, Stuart C: *Encyclopedia of artificial intelligence second edition*. New Jersey: A Wiley Interscience Publication, 1992. 26
- [116] Ramesh, AN, Chandra Kambhampati, John RT Monson e PJ Drew: *Artificial intelligence in medicine*. *Annals of the Royal College of Surgeons of England*, 86(5):334, 2004. 26
- [117] Nilsson, Nils J: *Artificial intelligence: a new synthesis*. Morgan Kaufmann, 1998. 26
- [118] Rouhiainen, Lasse: *Inteligencia artificial*. Madrid: Alienta Editorial, 2018. 27
- [119] Samuel, Arthur L: *Machine learning*. *The Technology Review*, 62(1):42–45, 1959. 27
- [120] Molnar, Christoph: *Interpretable machine learning*. Lulu. com, 2020. 27
- [121] Bochie, Kaylani, Mateus da Silva Gilbert, Luana Gantert, Mariana de Souza Maciel Barbosa, Dianne Scherly Varela de Medeiros e Miguel Elias Mitre Campista: *Aprendizado profundo em redes desafiadoras: Conceitos e aplicações*. Sociedade Brasileira de Computação, 2020. 28
- [122] Ghahramani, Zoubin: *Unsupervised learning*. Em *Summer school on machine learning*, páginas 72–112. Springer, 2003. 28
- [123] Džeroski, Sašo: *Applications of symbolic machine learning to ecological modelling*. *Ecological modelling*, 146(1-3):263–273, 2001. 28
- [124] Bernardini, Flávia Cristina: *Combinação de classificadores simbólicos utilizando medidas de regras de conhecimento e algoritmos genéticos*. Tese de Doutorado, Universidade de São Paulo, 2006. 28, 29
- [125] Breiman, L., J. Friedman, C.J. Stone e R.A. Olshen: *Classification and Regression Trees*. Taylor & Francis, 1984, ISBN 9780412048418. <https://books.google.com.br/books?id=JwQx-W0mSyQC>. 30
- [126] Ravì, Daniele, Charence Wong, Fani Deligianni, Melissa Berthelot, Javier Andreu-Perez, Benny Lo e Guang Zhong Yang: *Deep learning for health informatics*. *IEEE journal of biomedical and health informatics*, 21(1):4–21, 2016. 30

- [127] LeCun, Yann, Yoshua Bengio e Geoffrey Hinton: *Deep learning*. nature, 521(7553):436–444, 2015. 30
- [128] Microsoft: *What is deep learning?* <https://azure.microsoft.com/en-us/overview/what-is-deep-learning/>, 2021. Acessado em 04/05/2023. 30
- [129] Bengio, Yoshua, Yann Lecun e Geoffrey Hinton: *Deep learning for ai*. Communications of the ACM, 64(7):58–65, 2021. 30
- [130] Gu, Jiuxiang, Zhenhua Wang, Jason Kuen, Lianyang Ma, Amir Shahroudy, Bing Shuai, Ting Liu, Xingxing Wang, Gang Wang, Jianfei Cai *et al.*: *Recent advances in convolutional neural networks*. Pattern recognition, 77:354–377, 2018. 31
- [131] Li, Zewen, Fan Liu, Wenjie Yang, Shouheng Peng e Jun Zhou: *A survey of convolutional neural networks: analysis, applications, and prospects*. IEEE transactions on neural networks and learning systems, 2021. 31, 32
- [132] Hubel, David H e Torsten N Wiesel: *Receptive fields, binocular interaction and functional architecture in the cat's visual cortex*. The Journal of physiology, 160(1):106, 1962. 31
- [133] Krizhevsky, Alex, Ilya Sutskever e Geoffrey E Hinton: *Imagenet classification with deep convolutional neural networks*. Communications of the ACM, 60(6):84–90, 2017. 31
- [134] Agarap, Abien Fred: *Deep learning using rectified linear units (relu)*. arXiv preprint arXiv:1803.08375, 2018. 32
- [135] Wang, Meiqi, Siyuan Lu, Danyang Zhu, Jun Lin e Zhongfeng Wang: *A high-speed and low-complexity architecture for softmax function in deep learning*. Em *2018 IEEE asia pacific conference on circuits and systems (APCCAS)*, páginas 223–226. IEEE, 2018. 33
- [136] Mikolov, Tomáš *et al.*: *Statistical language models based on neural networks*. Presentation at Google, Mountain View, 2nd April, 80(26), 2012. 33
- [137] Graves, Alex: *Generating sequences with recurrent neural networks*. arXiv preprint arXiv:1308.0850, 2013. 33
- [138] Pascanu, Razvan, Tomas Mikolov e Yoshua Bengio: *On the difficulty of training recurrent neural networks*. Em *International conference on machine learning*, páginas 1310–1318. Pmlr, 2013. 33
- [139] Haykin, Simon: *Neural networks: a comprehensive foundation*. Prentice Hall PTR, 1998. 33
- [140] Salehinejad, Hojjat, Sharan Sankar, Joseph Barfett, Errol Colak e Shahrokh Valaee: *Recent advances in recurrent neural networks*. arXiv preprint arXiv:1801.01078, 2017. 33

- [141] Islam, Mir Riyanul, Mobyen Uddin Ahmed, Shaibal Barua e Shahina Begum: *A systematic review of explainable artificial intelligence in terms of different application domains and tasks*. Applied Sciences, 12(3):1353, 2022. 35
- [142] Islam, Sheikh Rabiul, William Eberle, Sheikh Khaled Ghafoor e Mohiuddin Ahmed: *Explainable artificial intelligence approaches: A survey*. arXiv preprint arXiv:2101.09429, 2021. 35, 36
- [143] Fernandez, Alberto, Francisco Herrera, Oscar Cordon, Maria Jose del Jesus e Francesco Marcelloni: *Evolutionary fuzzy systems for explainable artificial intelligence: Why, when, what for, and where to?* IEEE Computational intelligence magazine, 14(1):69–81, 2019. 35
- [144] Samek, Wojciech, Thomas Wiegand e Klaus Robert Müller: *Explainable artificial intelligence: Understanding, visualizing and interpreting deep learning models*. arXiv preprint arXiv:1708.08296, 2017. 35
- [145] Vilone, Giulia e Luca Longo: *Explainable artificial intelligence: a systematic review*. arXiv preprint arXiv:2006.00093, 2020. 35
- [146] Morais, Fábio Luiz Daudt e Ana Cristina Bicharra Garcia: *Julho de 2020*. 36
- [147] Islam, Mohammed Saidul, Iqram Hussain, Md Mezbaur Rahman, Se Jin Park e Md Azam Hossain: *Explainable artificial intelligence model for stroke prediction using eeg signal*. Sensors, 22(24):9859, 2022. 42
- [148] Bouyer, Guillaume, Amine Chellali e Anatole Lécuyer: *Inducing self-motion sensations in driving simulators using force-feedback and haptic motion*. Em *2017 IEEE Virtual Reality (VR)*, páginas 84–90. IEEE, 2017. 43
- [149] Batista, Diana, Hugo Plácido da Silva, Ana Fred, Carlos Moreira, Margarida Reis e Hugo Alexandre Ferreira: *Benchmarking of the bitalino biomedical toolkit against an established gold standard*. Healthcare technology letters, 6(2):32–36, 2019. 47
- [150] Ponciano, Vasco, Ivan Miguel Pires, Fernando Reinaldo Ribeiro, Nuno M Garcia, Maria Vanessa Villasana, Eftim Zdravevski e Petre Lameski: *Machine learning techniques with ecg and eeg data: an exploratory study*. Computers, 9(3):55, 2020. 47
- [151] Alomari, Zakaria, Oualid El Halimi, Kaushik Sivaprasad e Chitrang Pandit: *Comparative studies of six programming languages*. arXiv preprint arXiv:1504.00693, 2015. 51
- [152] Andrejašič, Matej: *Mems accelerometers*. Em *University of Ljubljana. Faculty for mathematics and physics, Department of physics, Seminar*, volume 49, 2008. 54
- [153] Lyshevski, Sergey Edward: *MEMS and NEMS: systems, devices, and structures*. CRC press, 2018. 54
- [154] Bassett, David R e Dinesh John: *Use of pedometers and accelerometers in clinical populations: validity and reliability issues*. Physical therapy reviews, 15(3):135–142, 2010. 54

- [155] Biosignals, Plux: *Bitalino (r)evolution lab guide*. 2024. <https://www.pluxbiosignals.com>, acesso em 2024/03/09. 54
- [156] Tollini, Gabriel C: *Avaliação do virtual reality sickness questionnaire (vrsq) como preditor de cybersickness*. 2020. 63
- [157] Kim, Tae Kyun: *T test as a parametric statistic*. Korean journal of anesthesiology, 68(6):540–546, 2015. 70
- [158] Tian, Nana e Ronan Boulic: *Who says you are so sick? an investigation on individual susceptibility to cybersickness triggers using eeg, egg and ecg*. 71
- [159] Monard, Maria Carolina e José Augusto Baranauskas: *Indução de regras e árvores de decisão*. Sistemas Inteligentes-fundamentos e aplicações, 1:115–139, 2003. 76
- [160] Shannon, Claude E: *A mathematical theory of communication*. The Bell system technical journal, 27(3):379–423, 1948. 77
- [161] Rokach, Lior e Oded Maimon: *Decision trees*. Data mining and knowledge discovery handbook, páginas 165–192, 2005. 78
- [162] Daniya, T, M Geetha e K Suresh Kumar: *Classification and regression trees with gini index*. Advances in Mathematics: Scientific Journal, 9(10):8237–8247, 2020. 78
- [163] Anguita, Davide, Luca Ghelardoni, Alessandro Ghio, Luca Oneto, Sandro Ridella et al.: *The 'k' in k-fold cross validation*. Em *ESANN*, páginas 441–446, 2012. 79
- [164] Tan, Jinkai, Hexiang Liu, Mengya Li e Jun Wang: *A prediction scheme of tropical cyclone frequency based on lasso and random forest*. Theoretical and applied climatology, 133:973–983, 2018. 82
- [165] Pashaei, Elham e Elnaz Pashaei: *Gene selection using intelligent dynamic genetic algorithm and random forest*. Em *2019 11th international conference on electrical and electronics engineering (ELECO)*, páginas 470–474. IEEE, 2019. 82
- [166] Yao, Dengju, Xiaojuan Zhan e Chee Keong Kwoh: *An improved random forest-based computational model for predicting novel mirna-disease associations*. BMC bioinformatics, 20:1–14, 2019. 82
- [167] Valkonen, Mira, Kimmo Kartasalo, Kaisa Liimatainen, Matti Nykter, Leena Latonen e Pekka Ruusuvoori: *Metastasis detection from whole slide images using local features and random forests*. Cytometry Part A, 91(6):555–565, 2017. 82
- [168] Oh, Heeseok e Wookho Son: *Cybersickness and its severity arising from virtual reality content: A comprehensive study*. Sensors, 22(4):1314, 2022. 85
- [169] Kotlowski, Wojciech, Krzysztof J Dembczynski e Eyke Huellermeier: *Bipartite ranking through minimization of univariate loss*. Em *Proceedings of the 28th International Conference on Machine Learning (ICML-11)*, páginas 1113–1120. Citeseer, 2011. 86

- [170] Nguyen, Ngoc Dang, Wei Tan, Lan Du, Wray Buntine, Richard Beare e Changyou Chen: *Auc maximization for low-resource named entity recognition*. Em *Proceedings of the AAAI Conference on Artificial Intelligence*, volume 37, páginas 13389–13399, 2023. 86
- [171] Zhao, Yongheng e Yanxia Zhang: *Comparison of decision tree methods for finding active objects*. *Advances in Space Research*, 41(12):1955–1959, 2008. 91
- [172] Ali, Jehad, Rehanullah Khan, Nasir Ahmad e Imran Maqsood: *Random forests and decision trees*. *International Journal of Computer Science Issues (IJCSI)*, 9(5):272, 2012. 91

Apêndice A

Cybersickness Profile Questionnaire (CSPQ)

Item	Pergunta	Opções
1	Gênero	Feminino, Masculino
2	Idade	18 a 36, 37 a 50, +50
3	Experiência	Nenhuma, Alguma, Muita
4	Pré-Sintomas	Nenhum, Algum
5	Sensibilidade a Cintilação	Nenhum, Alguma
6	Uso de óculos de grau	Não, Sim
7	Postura de Jogo	Sentado, Em pé
8	Deficiências Visuais	Miopia, Hipermetropia ou Astigmatismo
9	Olho Dominante	Esquerdo, Direito

Tabela A.1: *Cybersickness Profile Questionnaire* (CSPQ) [12].

Apêndice B

Virtual Reality Sickness Questionnaire (VRSQ)

Item	Sintoma	Classificação			
		Nenhum	Leve	Moderado	Severo
1	Desconforto Geral				
2	Fadiga (cansaço)				
3	Fadiga (ocular)				
4	Dificuldade de Concentração				
5	Dor de Cabeça				
6	"Cabeça Pesada"				
7	Visão Embaçada				
8	Tontura				
9	Vertigem				

Tabela B.1: Versão em português do *Virtual Reality Sickness Questionnaire* (VRSQ) [1, 12].

Apêndice C

Termo de Consentimento Livre e Esclarecido

Você está sendo convidado a participar da pesquisa **Análise da Cybersickness através de Biosinais: uma abordagem com Machine Learning Simbólico**, de responsabilidade de WEDREY NUNES DA SILVA, estudante de mestrado da Universidade de Brasília. O objetivo desta pesquisa é **Investigar a aplicação de biosinais para identificar as possíveis causas associadas à Cybersickness em jogos de Realidade Virtual**. Assim, gostaria de consultá-lo/a sobre seu interesse e disponibilidade de cooperar com a pesquisa.

Você receberá todos os esclarecimentos necessários antes, durante e após a finalização da pesquisa, e lhe asseguro que o seu nome não será divulgado, sendo mantido o mais rigoroso sigilo mediante a omissão total de informações que permitam identificá-lo/a. Os dados provenientes de sua participação na pesquisa, tais como questionários, entrevistas, ficarão sob a guarda do pesquisador responsável pela pesquisa.

Em relação à sua participação nesta pesquisa, ela envolverá a interação com um jogo, no qual dados fisiológicos serão coletados por meio de sensores. Além disso, você será solicitado a preencher três questionários, sendo dois antes e um após o experimento. O experimento tem uma duração aproximada de 15 minutos de interação com o jogo, sendo possível interrompê-lo a qualquer momento, além de cerca de 8 minutos para a coleta de dados fisiológicos e a conclusão dos questionários. Os riscos associados à sua participação são insignificantes, uma vez que o ambiente experimental e os equipamentos são seguros, não envolvendo o uso de produtos químicos ou substâncias semelhantes, e são devidamente higienizados com álcool em gel.

Participar desta pesquisa traz o benefício de contribuir de forma ativa para um projeto de mestrado, fornecendo dados experimentais confiáveis. Garantimos que todas as informações coletadas neste estudo serão tratadas com total confidencialidade, garantindo a privacidade de sua participação. Os dados não serão divulgados de forma que permita a identificação individual.

Sua participação é voluntária e livre de qualquer remuneração ou benefício. Você é livre para recusar-se a participar, retirar seu consentimento ou interromper sua participação a qualquer momento. A recusa em participar não irá acarretar qualquer penalidade ou perda de benefícios.

Se você tiver qualquer dúvida em relação à pesquisa, você pode me contatar através do e-mail *wedrey@gmail.com*.

Este projeto foi revisado e aprovado pelo Comitê de Ética em Pesquisa em Ciências Humanas e Sociais (CEP/CHS) da Universidade de Brasília. As informações com relação à assinatura do TCLE ou aos direitos do participante da pesquisa podem ser obtidas por meio do e-mail do CEP/CHS: *cep_chs@unb.br* ou pelo telefone: (61) 3107 1592.

Este documento foi elaborado em duas vias, uma ficará com o pesquisador responsável pela pesquisa e a outra com você.

Assinatura do/da participante

Assinatura do pesquisador

Brasília, _____ de _____ de _____