



Universidade de Brasília

Instituto de Ciências Exatas
Departamento de Ciência da Computação

Análise da Atividade Mioelétrica Gástrica e Aprendizado de Máquina Simbólico na Detecção de Cybersickness

João Vítor Siqueira de Araujo

Monografia apresentada como requisito parcial
para conclusão do Bacharelado em Ciência da Computação

Orientadora
Prof.a Dr.a Carla Denise Castanho

Brasília
2025



Universidade de Brasília

Instituto de Ciências Exatas
Departamento de Ciência da Computação

**Análise da Atividade Mioelétrica Gástrica e
Aprendizado de Máquina Simbólico na Detecção de
Cybersickness**

João Víctor Siqueira de Araujo

Monografia apresentada como requisito parcial
para conclusão do Bacharelado em Ciência da Computação

Prof.a Dr.a Carla Denise Castanho (Orientadora)
CIC/UnB

Prof. Dr. Tiago Barros Pontes e Silva Prof. Dr. Ricardo Pezzuol Jacobi
DIN/UnB CIC/UnB

Prof. Dr. Marcelo Grandi Mandelli
Coordenador do Bacharelado em Ciência da Computação

Brasília, 21 de fevereiro de 2025

Dedicatória

Dedico este trabalho aos meus pais que sempre buscaram me orientar e apoiar durante todo o meu caminho. Às minhas irmãs mais velhas que sempre estiveram à disposição para me ajudar. Em especial, minha irmã Lethícia, que me ajudou em um dos meus momentos mais difíceis e me fez seguir em frente. E aos meus amigos que fizeram dessa minha jornada acadêmica algo inesquecível.

Agradecimentos

Meus sinceros agradecimentos a todos que contribuíram com a realização dos experimentos desta pesquisa.

Primeiramente, gostaria de agradecer à minha orientadora e professora Carla Denise Castanho por toda a paciência e orientação ao longo deste trabalho. Também sou grato aos professores Ricardo Pezzuol Jacobi e Tiago Barros Pontes e Silva por participarem da banca avaliadora. Além disso, agradeço também ao Dr. Thiago Malheiros Porcino pela disponibilização dos códigos do modelo de *Machine Learning* e dos jogos de Realidade Virtual, sem eles esse trabalho não seria possível.

Sou imensamente grato à minha família e amigos que sempre me apoiaram e forneceram o suporte necessário para eu seguir em frente.

Expresso também minha gratidão à Universidade de Brasília e aos professores do Departamento de Ciência da Computação, cujos ensinamentos foram fundamentais ao longo da minha trajetória acadêmica.

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

Resumo

A Realidade Virtual (RV) é uma tecnologia promissora que vem se tornando cada vez mais popular, sendo empregada em diversas áreas como educação, saúde, entretenimento e militar. No entanto, uma das principais preocupações relacionadas ao seu uso é a *Cybersickness* (CS), uma condição caracterizada por um mal-estar geral que afeta os usuários de RV. Técnicas não invasivas baseadas em biossinais têm demonstrado grande potencial para identificar tal condição, especialmente o Eletrogastrograma (EGG), que se mostrou bastante eficaz no diagnóstico de distúrbios gástricos, principalmente relacionados à náusea e vômito, sintomas comuns da CS. Este trabalho teve como objetivo validar a análise da atividade mioelétrica gástrica adquirida pelo EGG como um método de detecção de CS. Neste trabalho, foi feito um estudo comparativo entre os dados do EGG e os níveis de desconforto registrados, que foram obtidos a partir dos relatos verbais dos participantes durante a experiência e das predições do modelo simbólico de aprendizado de máquina desenvolvido por Porcino [1]. Ao todo, foram conduzidos experimentos com 50 participantes com jogos de RV, os quais mostraram que, no cenário geral, os dados do sensor EGG foram condizentes com os níveis de desconforto registrados em mais de 50% dos participantes. Já no melhor cenário, a coerência entre os dados ultrapassou 60%.

Palavras-chave: Cybersickness, realidade virtual, aprendizado de máquina simbólico, sinais fisiológicos, eletrogastrografia, EGG

Abstract

Virtual Reality (VR) is a promising technology that has become increasingly popular, with applications in various fields such as education, healthcare, entertainment, and the military. However, one of the main concerns regarding its use is Cybersickness (CS), a condition characterized by a general discomfort that affects VR users. Non-invasive biosignal-based techniques have shown great potential in identifying this condition, especially the Electrogastrogram (EGG), which has proven effective in diagnosing gastric disorders, particularly those related to nausea and vomiting, common symptoms of CS. This study aimed to validate the analysis of gastric myoelectric activity acquired by the EGG sensor as a method for detecting CS. A comparative analysis was conducted between EGG data and recorded discomfort levels, which were obtained from participants' verbal feedback during experiments and the predictions of the symbolic machine learning model developed by Porcino [1]. A total of 50 VR gaming experiments were conducted, showing that, in the general scenario, the EGG sensor data were consistent with the recorded discomfort levels in over 50% of participants. In the best scenario, the coherence between the data exceeded 60%.

Keywords: Cybersickness, virtual reality, symbolic machine learning, physiological data, electrogastrography, EGG

Sumário

1	Introdução	1
2	Fundamentação Teórica	3
2.1	Realidade Virtual	3
2.1.1	<i>Head-mounted Display</i>	4
2.2	<i>Motion Sickness</i> e <i>Cybersickness</i>	4
2.2.1	Teorias Sobre a Manifestação da CS	6
2.3	Técnicas de Medição de <i>Cybersickness</i>	7
2.3.1	Dados Subjetivos	7
2.3.2	Dados Fisiológicos	8
2.4	Aprendizado de Máquina	10
2.4.1	Classificadores Simbólicos	11
2.5	Trabalhos Relacionados	12
2.5.1	Análise de CS com Algoritmos Simbólicos de ML	12
2.5.2	Combinando EDA e ML Simbólico para Identificar CS	14
3	Proposta e Experimento	16
3.1	Apresentação da Proposta	16
3.2	Equipamentos e Programas	16
3.2.1	Placa BITalino	18
3.3	Procedimento	19
3.3.1	Roteiro do Experimento	19
4	Resultados e Discussão	21
4.1	Processamento dos Dados	21
4.1.1	Dados Descartados	21
4.1.2	Correções e Ajustes dos Dados	24
4.1.3	Filtragem do Sinal	25
4.2	Análise dos Resultados	25
4.2.1	Resultados Parciais - Jogo de Corrida	28

4.2.2	Resultados Parciais - Jogo de Voo	28
4.3	Discussão	30
4.3.1	Experimentos Interrompidos	31
4.3.2	Dificuldades e Problemas Encontrados	32
5	Conclusão	34
5.1	Trabalhos Futuros	35
	Referências	37
	Anexo	41
I	Termo de Consentimento Livre e Esclarecido	42
II	<i>Cybersickness Profile Questionnaire (CSPQ)</i>	44
III	<i>Virtual Reality Sickness Questionnaire (VRSQ)</i>	45

Lista de Figuras

2.1	Modelos populares de HMD [2].	4
2.2	Diagrama de <i>Motion Sickness</i> e suas subcategorias. Adaptado de [3].	5
2.3	Comparação de bandas de ondas cerebrais [4].	9
2.4	Configuração padrão dos eletrodos cutâneos do EGG no abdômen [5].	10
2.5	Representação esquemática de uma árvore de decisão e uma floresta aleatória. O modelo de <i>Random Forest</i> é composto por um conjunto de árvores de decisão e o resultado final é obtido pelo voto majoritário delas, ou seja, a classe mais votada entre as árvores é a previsão final [6].	12
2.6	Diagrama de atividades dos voluntários do experimento do estudo proposto por Porcino [7].	14
3.1	HMD HTC Vive.	17
3.2	Participantes realizando o experimento com o jogo de voo (parte superior) e o jogo de corrida (parte inferior) desenvolvidos por Porcino [1].	18
3.3	Placa BITalino e sensor EGG.	19
4.1	Sinal lido pelo sensor EGG durante o período de jogo do indivíduo 10.	22
4.2	Sinal lido pelo sensor EGG durante o período de repouso do indivíduo 15.	23
4.3	Sinal lido pelo sensor EGG durante o período de jogo do indivíduo 17.	23
4.4	Sinal de EGG do participante 38 antes (em azul) e após (em vermelho) a aplicação dos filtros.	26

Lista de Tabelas

3.1	Especificações do computador.	17
4.1	Tabela comparativa dos resultados de todos os participantes válidos.	27
4.2	Tabela comparativa dos resultados dos participantes do jogo de corrida.	29
4.3	Tabela comparativa dos resultados dos participantes do jogo de voo.	29
II.1	Adaptação do CSPQ para português [1].	44
III.1	Adaptação do VRSQ para português [8].	45

Lista de Abreviaturas e Siglas

ACC Acelerômetro.

CIC Departamento de Ciência da Computação.

CNN Rede Neural Convolucional.

CS *Cybersickness*.

CSPQ *Cybersickness Profile Questionnaire*.

CSQ *Cybersickness Questionnaire*.

ECG Eletrocardiograma.

EDA Atividade Eletrodérmica.

EEG Eletroencefalograma.

EGG Eletrogastrograma.

EMG Eletromiograma.

GSR Resposta Galvânica da Pele.

HMD *Head-mounted Display*.

IA Inteligência Artificial.

ML *Machine Learning*.

MS *Motion Sickness*.

MSQ *Pensacola Motion Sickness Questionnaire*.

PPG Fotopletismografia.

RNN Rede Neural Recorrente.

RV Realidade Virtual.

SS *Simulator Sickness.*

SSQ *Simulator Sickness Questionnaire.*

UnB Universidade de Brasília.

VIMS *Visually Induced Motion Sickness.*

VR *Virtual Reality.*

VRSQ *Virtual Reality Sickness Questionnaire.*

Capítulo 1

Introdução

Nos últimos anos, a tecnologia de Realidade Virtual tem se expandido consideravelmente, sendo amplamente utilizada em diversos setores, como entretenimento, militar, saúde, educação, engenharia, entre muitos outros [9]. O mercado de Realidade Virtual foi avaliado em aproximadamente 13 bilhões de dólares em 2023, com uma projeção de atingir até 123 bilhões em 2032 [10].

A popularização dessa tecnologia foi impulsionada pelos *Head-mounted Displays*, que favoreceram a disseminação da Realidade Virtual graças à sua acessibilidade ao público geral e, atualmente, são o meio mais comum de interação com ambientes virtuais [11]. Esses dispositivos são constituídos por duas telas posicionadas próximas aos olhos do usuário que exibem a mesma imagem com ângulos ligeiramente diferentes, criando assim uma noção de profundidade [2].

No entanto, uma exposição prolongada a ambientes virtuais pode desencadear a manifestação da *Cybersickness*, uma condição cujos sintomas variam conforme o indivíduo, mas geralmente incluem dor de cabeça, vertigem, náusea, fadiga ocular, ataxia, vômito, palidez, entre outros [12]. A ocorrência da *Cybersickness* tem se tornado uma preocupação crescente, pois seus efeitos podem comprometer a experiência do usuário, levando-o a desistir de utilizar tal tecnologia, o que resultaria em impactos negativos para o setor de Realidade Virtual na indústria tecnológica [7].

Em virtude disso, diversos estudos foram conduzidos com o objetivo de identificar e prever a manifestação desse fenômeno [13, 14, 15]. Com relação à identificação, as principais estratégias para detectar a *Cybersickness* estão divididas em abordagens subjetivas, que envolvem a coleta de respostas a questionários e informações sobre o perfil do usuário; e abordagens objetivas, que se baseiam na coleta de dados fisiológicos por meio de sensores externos, como o Eletrocardiograma e o Eletroencefalograma [16].

Um método não invasivo de aquisição de dados fisiológicos que tem se destacado no meio acadêmico é a eletrogastrografia, a qual utiliza o Eletrogastrograma (EGG) para

medir a atividade mioelétrica gástrica [17]. Os dados obtidos por esse sensor têm se mostrado eficazes na detecção de distúrbios gástricos, contribuindo para o diagnóstico de pacientes com náusea, vômito e outros sintomas relacionados à indigestão [5]. Como vômito e náusea são sintomas frequentes em usuários com *Cybersickness*, a aplicação desse método pode ser benéfica para a identificação dessa condição.

Quanto à previsão da *Cybersickness*, algoritmos de aprendizado de máquina têm sido amplamente utilizados em estudos recentes, com ênfase principalmente em modelos de *Deep Learning* [14, 15]. Por outro lado, Porcino [1] optou por seguir uma abordagem diferente ao propor um modelo simbólico de aprendizado de máquina para identificar a *Cybersickness* e classificar as suas causas potenciais. Sua hipótese era de que o uso de um modelo simbólico permitiria uma compreensão mais profunda dos resultados obtidos.

Contudo, Porcino não fez uso de dados fisiológicos na identificação de *Cybersickness*, limitando-se apenas aos questionários subjetivos. Diante dessa limitação, Nóbrega [18] buscou reproduzir a pesquisa de Porcino, com o diferencial de explorar o uso da Atividade Eletrodérmica como método para detectar esse fenômeno.

Dessa forma, este trabalho tem como objetivo avaliar a viabilidade da análise da atividade mioelétrica gástrica como método de detecção de *Cybersickness*. Para isso, foi adotada uma abordagem semelhante à metodologia proposta por Nóbrega, de modo que um estudo comparativo foi feito entre os dados coletados pelo sensor EGG e os níveis de desconforto registrados durante o experimento, que dizem respeito tanto ao desconforto relatado pelo participante quanto ao desconforto previsto pelo modelo simbólico de Porcino, de forma a validar a aplicação desse sensor na identificação da *Cybersickness*. Esta pesquisa coletou os dados de 50 participantes que realizaram experimentos com jogos de Realidade Virtual de duração de 5 minutos cada com monitoramento da atividade mioelétrica gástrica.

Além deste capítulo introdutório, que abordou a motivação e o objetivo do trabalho, esta monografia está organizada em mais quatro capítulos. O Capítulo 2 trata dos conceitos fundamentais para esta pesquisa, como Realidade Virtual, *Cybersickness* e Aprendizado de Máquina, além de realizar uma revisão de trabalhos relacionados. No Capítulo 3, são apresentadas a proposta deste estudo, a descrição dos experimentos realizados e os equipamentos utilizados. Já o Capítulo 4 detalha o processamento dos dados, analisa os resultados obtidos e promove uma discussão sobre eles. Por fim, o Capítulo 5 expõe as conclusões alcançadas e apresenta sugestões de trabalhos futuros.

Capítulo 2

Fundamentação Teórica

Este capítulo apresenta os princípios que guiaram e fundamentaram a elaboração deste trabalho, incluindo conceitos como Realidade Virtual, *Cybersickness* e Aprendizado de Máquina. Além disso, também são abordadas tecnologias e técnicas associadas, bem como uma revisão de trabalhos anteriores.

2.1 Realidade Virtual

O termo Realidade Virtual, do inglês *Virtual Reality* (VR), foi utilizado pela primeira vez no final da década de 80 por Jaron Lanier, fundador da VPL Research [19], e pode ser compreendido como sendo uma simulação gerada por computador de um mundo virtual semelhante ao mundo real. Nesse mundo virtual devem estar presentes três elementos fundamentais: imersão, interatividade e imaginação [20]. A imersão diz respeito à sensação de estar dentro de outra realidade; a interatividade está associada à capacidade do usuário de atuar sobre o mundo simulado; e a imaginação, também chamada de presença [21], é a capacidade de se imaginar presente em um lugar diferente de onde se encontra no mundo real.

Segundo Pimentel e Teixeira [22], a Realidade Virtual é o uso de alta tecnologia para convencer o usuário de que ele se encontra em outra realidade. Já Latta e Oberg [23] enxergam a Realidade Virtual como sendo uma interface homem-máquina avançada que simula um ambiente realista e permite que os participantes interajam com ele. Outra definição refere-se ao uso de computadores e interfaces com o usuário para criar simulações de mundos tridimensionais que sejam imersivos e interativos, permitindo que os usuários os explorem e os modifiquem de maneira similar ao que acontece no mundo real [24].

2.1.1 *Head-mounted Display*

O conceito de *Head-mounted Display* (HMD) surgiu na década de 90 com um aparelho similar a um capacete que posicionava duas pequenas telas à frente de cada um dos olhos do usuário a fim de preencher grande parte do campo de visão e proporcionar uma sensação de imersão [20]. O HMD simula a visão humana no mundo virtual ao gerar imagens diferentes para cada olho, baseando-se na distância entre eles, o que possibilita uma percepção natural de profundidade dentro desse ambiente simulado [2].

Os HMDs são utilizados para diversos propósitos dentro da indústria tecnológica, como, por exemplo, entretenimento através de jogos, treinamento médico e militar, educação, terapia recreativa e simuladores para múltiplos contextos [1]. O avanço tecnológico tornou os HMDs mais acessíveis ao público geral, o que acabou popularizando as tecnologias de VR e consolidando seu lugar no mercado tecnológico [25]. Alguns modelos populares de HMD podem ser vistos na Figura 2.1.



Figura 2.1: Modelos populares de HMD [2].

2.2 *Motion Sickness e Cybersickness*

A *Motion Sickness* (MS), também conhecida como cinetose, ocorre quando há divergência de informação emitida pelos sistemas sensoriais, ou seja, os órgãos sensoriais responsáveis pela orientação e pelo posicionamento espacial entram em conflito [1]. Sua manifestação é comum, por exemplo, durante viagens de barco, aviões e carros [26, 27], podendo até

mesmo ocorrer em brinquedos de parques de diversões [16]. Seus sintomas podem variar de grau leve a severo, sendo os mais comuns: sonolência, tontura, palidez, suor frio e aumento da salivação, que pode levar a náusea e vômito [3].

De forma geral, a MS pode ser dividida em duas subcategorias [3, 28]: desconforto causado por transportes, que está relacionado ao mundo real, sendo específico ao meio (veículo) em que ocorre a manifestação do mal-estar; e desconforto causado por simulações, também chamado de *Simulator Sickness* (SS), que está associado ao mundo virtual, causado pelas limitações visuais e de movimento dos simuladores. O diagrama representando essas subdivisões pode ser visto na Figura 2.2.

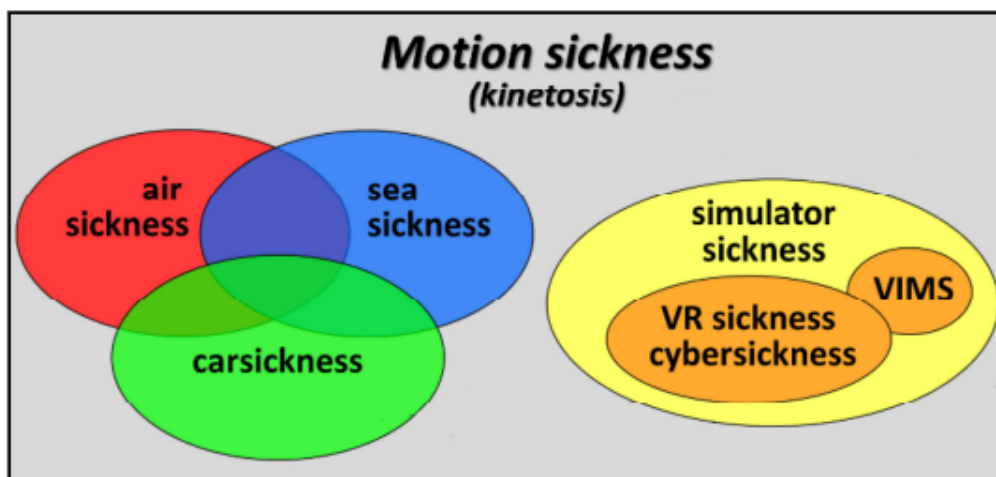


Figura 2.2: Diagrama de *Motion Sickness* e suas subcategorias. Adaptado de [3].

O *Visually Induced Motion Sickness* (VIMS) e a *Cybersickness* (CS) são termos presentes na subcategoria da SS que descrevem o desconforto visualmente induzido, geralmente experienciado durante ou após a exposição a ambientes virtuais. O VIMS é mais abrangente, não se limitando apenas a ambientes de VR, mas também sendo observado em jogos de videogame, filmes 3D e outras tecnologias digitais que promovam estímulos visuais [16]. Já a CS é um desconforto sensorial que ocorre em ambientes de VR, sendo compreendido como um caso específico de VIMS [29].

De acordo com LaViola [12], os principais sintomas da CS são: fadiga ocular, dor de cabeça, palidez, sudorese, boca seca, sensação de estômago cheio, desorientação, vertigem, ataxia (desequilíbrio postural e falta de coordenação), náusea e vômito. Mesmo que a MS e a CS produzam sintomas semelhantes, elas não são necessariamente a mesma condição. A diferença entre ambas se encontra em quais estímulos as induzem. No caso da MS, a estimulação vestibular por si só é suficiente para induzi-la [30], embora a estimulação

visual seja um fator contribuinte [31]. Já no caso da CS, o desconforto pode ocorrer estritamente com estimulação visual e sem estímulo vestibular [12].

No que diz respeito aos fatores que contribuem para o surgimento da CS, as principais causas podem ser categorizadas em relação ao hardware, software e usuário. As causas relativas ao hardware incluem o tipo de aparelho de VR utilizado e suas configurações, como resolução de tela, taxa de quadros, campo de visão, etc. Já as causas referentes ao software estão associadas à própria aplicação, como, por exemplo, a velocidade de movimento, os gráficos e a coloração, a interface com o usuário, o grau de controle, entre outros. Por fim, os fatores individuais se referem à idade, sexo, experiência prévia com VR, questões de saúde e de suscetibilidade [32, 13].

2.2.1 Teorias Sobre a Manifestação da CS

Existem diversas teorias na literatura que buscam explicar por que e como ocorre a manifestação da CS, mas três delas se destacam como sendo as principais: a Teoria do Conflito Sensorial, a Teoria do Veneno e a Teoria da Instabilidade Postural [12].

A Teoria do Conflito Sensorial é a mais antiga e aceita presente na literatura [27]. Essa teoria diz que o desconforto é causado pela discrepância de informação entre o sistema visual e o sistema vestibular, que provoca um conflito perceptivo com o qual o corpo humano não sabe lidar [1]. No caso, a informação que um sistema recebe é contraditória ao que o outro sistema recebe. Por exemplo, em simulação de corrida em VR, a visão recebe estímulos de movimentação, mas, como o indivíduo não está se movimentando de fato, o sistema vestibular entende que o mesmo se encontra parado, o que causa o conflito que provoca a CS.

Já a Teoria do Veneno busca explicar a manifestação da CS do ponto de vista evolutivo [33]. Essa teoria sugere que a ingestão de veneno provoca alterações fisiológicas relacionadas à coordenação dos sistemas sensoriais, as quais seriam entendidas pelo organismo como um alerta inicial para que ele buscasse a sobrevivência ao remover toxinas do estômago [12]. Dessa forma, a estimulação adversa comum em ambientes de VR poderia confundir o sistema visual e vestibular, fazendo com que o corpo interprete erroneamente que houve a ingestão de substância tóxica, levando a uma resposta emética.

Por fim, a Teoria da Instabilidade Postural está centrada na ideia de que é uma necessidade comportamental do ser humano manter uma postura estável no ambiente, que pode ser definida como o estado em que movimentos descontrolados dos sistemas de percepção e ação são minimizados [34]. Portanto, essa teoria afirma que a CS se manifesta devido à instabilidade postural prolongada e quanto maior for a duração dessa instabilidade, mais severos serão os sintomas do desconforto [12].

2.3 Técnicas de Medição de *Cybersickness*

Determinar uma estimativa para o nível de CS não é trivial, dado que não há uma variável única que indique precisamente o grau de desconforto. Um usuário pode apresentar diversos sintomas e efeitos adversos que podem ainda nem estar descritos na literatura. Além disso, cada indivíduo apresenta uma suscetibilidade diferente, sendo uns mais propensos à CS que outros [1].

Visando compreender melhor a CS, pesquisadores têm buscado medidas e estratégias para avaliar sua manifestação e gravidade. Uma forma de classificar essas medidas é dividi-las em duas categorias: dados qualitativos, obtidos por meio da coleta de feedback subjetivo de questionários; e dados quantitativos, adquiridos através de sinais fisiológicos, durante ou após a exposição do usuário ao ambiente de VR [16].

2.3.1 Dados Subjetivos

A estratégia mais difundida na literatura para apurar a manifestação de CS é por meio da coleta de feedback subjetivo mediante a aplicação de questionários aos usuários. É uma metodologia simples e historicamente utilizada, porém os resultados dependem diretamente da interpretação subjetiva dos participantes quanto aos sintomas sentidos [1].

O questionário mais relevante encontrado no meio científico é o *Simulator Sickness Questionnaire* (SSQ), proposto por Kennedy et al. [35]. O SSQ foi derivado do *Penacola Motion Sickness Questionnaire* (MSQ), o qual apresentava várias deficiências nas medições de SS e considerava alguns sintomas que não eram relevantes para tal condição. Dessa forma, o SSQ considera apenas 16 dos 28 sintomas do MSQ, agrupando-os em três categorias diferentes: náusea, oculomotor e desorientação. Ao responderem ao questionário, os participantes classificam cada um desses 16 sintomas conforme a seguinte escala de desconforto: 0 (nenhum), 1 (leve), 2 (moderado) ou 3 (severo).

Kim et al. [8] propuseram o *Virtual Reality Sickness Questionnaire* (VRSQ), uma versão modificada do tradicional SSQ que buscava atender às especificações do ambiente de VR. Esse novo questionário reduz a quantidade de sintomas considerados para 9 e descarta a categoria náusea, que menos contribuía para a manifestação de CS, restando apenas duas categorias: oculomotor e desorientação. Sevinc et al. [36] afirmam que o SSQ não é adequado para aplicações de VR baseadas em HMD, visto que o *Cybersickness Questionnaire* (CSQ) [37] e o VRSQ, os quais foram projetados especificamente para medir CS, têm as melhores qualidades psicométricas para avaliar tais aplicações.

Por sua vez, Porcino [1] conduziu um estudo que propôs o *Cybersickness Profile Questionnaire* (CSPQ), um questionário composto por 9 questões sobre o perfil do usuário, tais como: gênero, idade, experiência prévia com VR, sensibilidade a telas, pré-sintomas,

uso de óculos de grau, deficiências visuais, postura de jogo e olho dominante. A escolha dessas informações de perfil foi fundamentada na literatura e na experiência adquirida durante os testes-pilotos do estudo.

2.3.2 Dados Fisiológicos

A utilização de dados fisiológicos, também conhecidos como bio-sinais, como método de medição de CS serve não apenas como uma alternativa para os dados subjetivos, mas também como uma forma de complementação, visto que esses sinais fornecem uma visão mais objetiva dos sintomas experienciados, podendo ser usados para validar as avaliações subjetivas [16]. Amplamente utilizados em diversas áreas da saúde, os bio-sinais quantificam as reações fisiológicas que ocorrem no corpo humano devido à ocorrência de determinados estímulos e são adquiridos por meio de sensores fisiológicos tais como: Eletrocardiograma (ECG), Atividade Eletrodérmica (EDA), Eletroencefalograma (EEG), Eletrogastrograma (EGG), entre outros.

Conforme alguns estudos recentes [38, 39, 40], alterações na atividade elétrica do coração podem ser provocadas pela exposição ao ambiente de VR. Anomalias como o aumento da frequência cardíaca e modificações na variabilidade da frequência cardíaca são registradas pelo Eletrocardiograma (ECG), que avalia a atividade elétrica gerada pelo coração a partir da superfície do corpo [41]. Garcia-Agundez et al. [40] conduziram uma pesquisa que avaliava a possibilidade de identificar a CS focando-se em uma análise da média e do desvio padrão dos intervalos entre os batimentos cardíacos e reportaram que houve mudanças significativas desses parâmetros quando o usuário sofria de sintomas de CS.

Poh et al. [42] afirmam que mudanças na condutividade elétrica na superfície da pele humana refletem a atividade do sistema nervoso autônomo simpático e fornecem uma medida para avaliar alterações associadas à emoção, cognição e atenção. Dessa forma, a Atividade Eletrodérmica (EDA), também conhecida como Resposta Galvânica da Pele (GSR), é uma medida fisiológica obtida a partir da superfície da pele que associa a produção de suor pelas glândulas sudoríparas écrinas com o grau de excitação psicológica de um indivíduo [18]. Kim et al. [43] desenvolveram um sistema de detecção e mitigação de CS usando o sensor EDA em conjunto com diversos outros sensores como entrada para uma rede neural, o que resultou na redução na frequência de CS e em menores pontuações no SSQ.

A atividade elétrica do cérebro também aparenta desempenhar um papel significativo na análise de CS, uma vez que fornece dados que auxiliam na detecção de doenças e sintomas comportamentais do corpo humano [1]. O Eletroencefalograma (EEG) registra graficamente o sinal elétrico gerado pela ação cooperativa das células cerebrais [44], sendo

composto por ondas cerebrais (Figura 2.3) divididas em cinco bandas de frequência diferentes: Alfa, Beta, Teta, Delta e Gama [45]. Kim et al. [46] constataram em sua pesquisa que a seriedade da CS tem uma correlação positiva com a onda delta do EEG e negativa com a onda beta do EEG, sugerindo que a CS acompanha as mudanças de padrões das atividades dos sistemas nervosos central e autônomo.




Figura 2.3: Comparação de bandas de ondas cerebrais [4].

Por fim, a eletrogastrografia é uma técnica que vem recebendo uma atenção significativa por parte dos pesquisadores devido à sua natureza não invasiva [16]. Esse método utiliza-se do Eletrogastrograma (EGG) para medir a atividade mioelétrica gástrica através de eletrodos cutâneos posicionados na região abdominal do corpo (Figura 2.4) [47]. Em indivíduos saudáveis durante o jejum, a frequência normal do EGG é de 3 ciclos por minuto (cpm), podendo variar entre 2 a 4 cpm [17, 48].

Os sinais do EGG se mostraram clinicamente úteis para identificar disfunções motoras do estômago, particularmente disritmias como a taquigastria (4 a 9 cpm) e a bradigastria (0,5 a 2 cpm) [47, 17, 49]. Algumas pesquisas utilizando o EGG para detecção de CS

constatarem um aumento na taquigastria [46, 50] e, em algumas instâncias, uma redução da bradigastria [51] na presença dessa condição. Além disso, um estudo mais recente [52] que avaliou a CS usando os dados fisiológicos do EGG em relação a diferentes eixos de navegação determinou a existência de uma correlação positiva com a frequência dominante do EGG.




Figura 2.4: Configuração padrão dos eletrodos cutâneos do EGG no abdômen [5].

2.4 Aprendizado de Máquina

Aprendizado de máquina, do inglês *Machine Learning* (ML), é um ramo da Inteligência Artificial (IA) que se dedica ao desenvolvimento de algoritmos e modelos estatísticos que permitem aos sistemas computacionais melhorar seu desempenho em uma tarefa específica por meio da experiência (treinamento). Em vez de depender de programação explícita, o *Machine Learning* identifica padrões nos dados e usa esses padrões para fazer previsões ou decisões [53].

Segundo Alpaydin [54], ML consiste em programar computadores para otimizar um critério de desempenho usando dados de exemplo ou experiências anteriores. Já Mitchell [55] define que um programa “aprende” com uma experiência se seu desempenho na execução de um conjunto de tarefas, medido a partir de uma métrica de desempenho, melhora com a experiência.

Os algoritmos de ML podem ser categorizados quanto à aprendizagem em 3 diferentes paradigmas: supervisionado, não supervisionado e por reforço [56].

- **Aprendizado supervisionado:** envolve o treinamento de um modelo usando um conjunto de dados rotulados, em que as entradas (*features*) estão associadas às

saídas (*labels*) correspondentes. O modelo aprende a mapear entradas para saídas, generalizando a partir dos exemplos fornecidos.

- **Aprendizado não supervisionado:** diferente do aprendizado supervisionado, o modelo recebe um conjunto de dados não rotulados, sem associação entre entrada e saída, com o objetivo de encontrar padrões e estruturas ocultas nos dados.
- **Aprendizado por reforço:** nesse paradigma, os algoritmos utilizam um sistema de recompensas e punições à medida que interagem com um ambiente. O modelo aprende a tomar decisões por tentativa e erro, buscando maximizar a recompensa a longo prazo.

A utilização de algoritmos de ML para identificar e classificar o fenômeno da CS vem sendo amplamente empregada em estudos recentes. Kim et al. [14] propuseram uma arquitetura de *Deep Learning* usando modelos de redes neurais, tais como redes neurais convolucionais (CNN) e recorrentes (RNN), para estimar o estado cognitivo através de sinais cerebrais de forma a relacioná-los aos níveis de CS.

Outro exemplo foi o estudo conduzido por Islam et al. [57], em que apresentaram um *framework* automatizado para detectar níveis de CS durante uma experiência de imersão em VR. Os dados fisiológicos coletados durante a experiência por sensores externos serviram como entrada para uma rede neural pré-treinada que previa o nível de CS e ajustava o ambiente usando técnicas de mitigação conforme o nível previsto.

2.4.1 Classificadores Simbólicos

Apesar de alguns trabalhos anteriores sugerirem que os classificadores baseados em *Deep Learning* sejam uma abordagem mais adequada para a previsão de CS [14, 15], as redes neurais são como “caixas pretas” para o ser humano que, mesmo que produzam resultados melhores, não é trivial descobrir os motivos pelos quais a rede neural tomou uma determinada decisão. Em contraste, os modelos simbólicos de ML, como árvore de decisão e floresta aleatória (*Random Forest*), ilustrados na Figura 2.5, oferecem suporte à legibilidade humana, pois são modelos cujas representações são explícitas e facilmente interpretáveis.

Os classificadores simbólicos operam sobre símbolos e regras lógicas para descrever os padrões presentes nos dados de treinamento, cuja linguagem de descrição é dada por um conjunto de N_R regras não ordenadas ou disjuntas, ou seja, $h = \{R_1, R_2, \dots, R_{N_R}\}$ [58]. O termo “não ordenado” implica que uma regra pode ser individualmente usada e analisada sem a necessidade de considerar outras regras no conjunto.

Cada regra R assume a forma de “se B então H ” ou, simbolicamente, $B \rightarrow H$, onde H representa a cabeça, ou a conclusão da regra, e B é o corpo, ou a condição da regra.

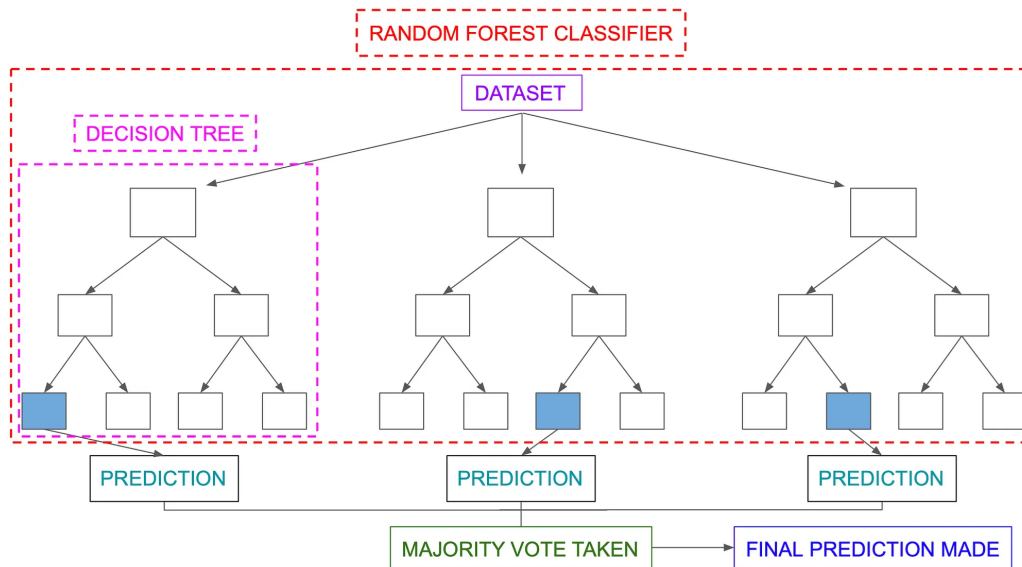


Figura 2.5: Representação esquemática de uma árvore de decisão e uma floresta aleatória. O modelo de *Random Forest* é composto por um conjunto de árvores de decisão e o resultado final é obtido pelo voto majoritário delas, ou seja, a classe mais votada entre as árvores é a previsão final [6].

O corpo consiste em uma disjunção de conjunções de atributos de teste na forma de $X_i \text{ op Value}$, onde X_i é o nome do atributo, op é um operador pertencente ao conjunto $\{=, \neq, <, \leq, >, \geq\}$ e $Value$ é um valor válido para o atributo X_i . Já a cabeça segue a forma $class = C_i$, onde $C_i \in \{C_1, C_2, \dots, C_{N_{Cl}}\}$, o conjunto de classes possíveis [58].

Algumas pesquisas [1, 59, 60] já vêm utilizando modelos simbólicos de aprendizado de máquina para estimar e prever níveis de CS. Um exemplo disso é o trabalho de Porcino [1], no qual foi proposta uma abordagem para identificar as potenciais causas de CS em ambiente de VR utilizando um modelo simbólico de ML, que possibilitaria, uma vez que ocorresse essa identificação, a sugestão direcionada de estratégias para mitigar os sintomas de CS de acordo com cada causa específica.

2.5 Trabalhos Relacionados

Serão descritos a seguir os estudos que serviram como base teórica para o desenvolvimento desta pesquisa.

2.5.1 Análise de CS com Algoritmos Simbólicos de ML

No estudo conduzido por Porcino [1], foi proposta uma nova análise experimental utilizando aprendizado de máquina simbólico para classificar as causas potenciais de CS em

jogos de VR e, uma vez que as causas sejam identificadas, sugerir uma ou mais estratégias para atenuar essa condição.

A hipótese central da pesquisa é que os modelos simbólicos de ML permitem uma interpretação compreensível e previsível dos resultados, o que possibilitaria compreender as razões da manifestação de desconforto nos jogos experimentais, os quais foram desenvolvidos especificamente para essa pesquisa, sendo eles um jogo de corrida em primeira pessoa e um jogo de voo em terceira pessoa (Figura 3.2). Os experimentos foram realizados usando esses 2 jogos e 6 protocolos experimentais, resultando em 37 amostras válidas de um total de 88 voluntários.

No jogo de voo, o jogador controla a movimentação de um pássaro com o objetivo de passar por aros distribuídos em intervalos regulares em um percurso infinito. Para cada aro que o pássaro atravessa, ocorre um aumento em sua velocidade. Caso o pássaro bata em algum objeto ou erre um aro, sua velocidade é redefinida para o padrão. Nesse jogo, o usuário tem controle sobre a direção em que o pássaro se movimenta, mas não sobre a aceleração.

Já no jogo de corrida, o jogador é um piloto de carro de corrida e tem como objetivo fazer o maior número de voltas em um percurso fechado. Ao contrário do jogo de voo, o jogador tem controle sobre a aceleração, podendo até mesmo usar a marcha ré. Em ambos os jogos, a movimentação da cabeça é livre e há uma funcionalidade de reconhecimento de voz para que os participantes relatem o nível de desconforto, em uma escala de 0 a 3, no decorrer da atividade.

Os participantes do experimento, em suas duas últimas versões, deveriam inicialmente responder aos questionários CSPQ e VRSQ, para a coleta de dados subjetivos. Após isso, realizavam a experiência de VR ao jogarem um dos dois jogos por 5 minutos (protocolo P5) ou 20 minutos (protocolo P6). Por fim, deveriam responder novamente ao VRSQ para que fosse possível a verificação da diferença após a experiência. O fluxo dessas atividades pode ser visto no diagrama da Figura 2.6.

O modelo simbólico desenvolvido por Porcino era, então, treinado utilizando os dados coletados do jogo e dos questionários. Para isso, foi adotado o método de validação cruzada *Leave-one-out*, que consistia em dividir o conjunto de dados de forma que uma única instância fosse usada para teste, enquanto o restante servia para treino. Esse processo era repetido para cada instância do conjunto, assegurando que todas as instâncias fossem treinadas ao menos uma vez. Após o treinamento, o modelo gerava uma previsão do nível de desconforto experienciado pelo participante e classificava os atributos que mais contribuíram para o desconforto previsto.

No final, o trabalho conseguiu alcançar uma solução capaz de sugerir se o usuário de VR está entrando em uma situação de CS com 99,0% de acurácia no melhor caso por

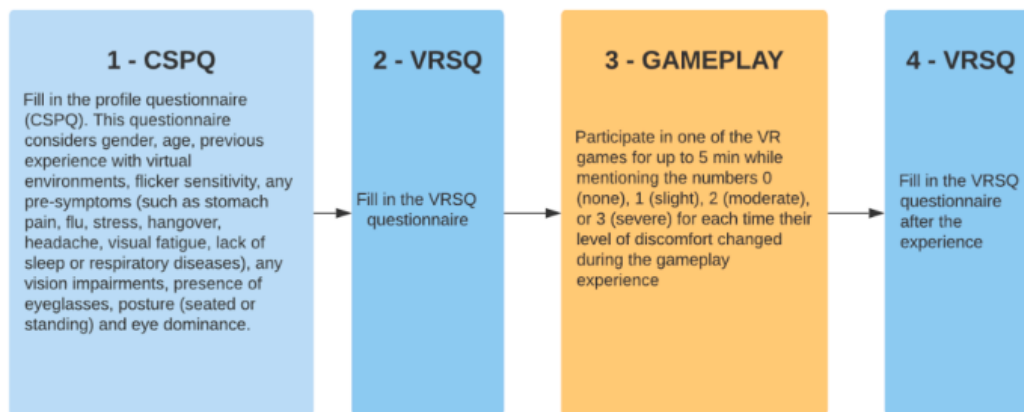


Figura 2.6: Diagrama de atividades dos voluntários do experimento do estudo proposto por Porcino [7].

meio do classificador *Random Forest*. Além disso, o autor observou que os atributos mais relevantes para a manifestação de CS foram o tempo de exposição, rotação no eixo z e atributos de perfil do indivíduo, tais como gênero, idade e experiência com VR. Por fim, o estudo conclui que diferentes causas de CS surgem com base em exposições de VR de curto ou longo prazo. Os códigos tanto dos dois jogos¹ quanto do modelo de aprendizado de máquina² estão publicamente disponíveis na plataforma GitHub.

2.5.2 Combinando EDA e ML Simbólico para Identificar CS

O trabalho realizado por Nóbrega [18] tinha como objetivo inserir a análise de dados fisiológicos na metodologia apresentada no estudo de Porcino [1], de forma a reduzir a dependência dos dados subjetivos fornecidos pelos participantes. A proposta inicial era utilizar um sensor de EDA para medir a condutividade elétrica da pele e um sensor de Fotopletismografia (PPG) para calcular a frequência dos batimentos cardíacos. Porém, foi verificado que os dados do PPG eram inconsistentes e não seriam adequados para o estudo.

O experimento realizado por Nóbrega foi bastante similar ao de Porcino, adicionando apenas a leitura do biossinal. Dessa forma, inicialmente o participante tinha seus sinais fisiológicos captados durante 3 minutos de repouso. Após isso, ele responderia o CSPQ e o VRSQ e realizaria uma sessão de 5 minutos de experiência em VR. No final, o VRSQ deveria ser preenchido novamente. Os dados fisiológicos do participante foram coletados durante toda a experiência.

¹<https://github.com/tmp1986/UFFCSData>

²https://github.com/tmp1986/ML_CS_PREDICTOR_PYTHON

Nóbrega fez ajustes no código do modelo simbólico de ML para a inclusão dos dados do sensor EDA na análise, o que pode ser visualizado no repositório do GitHub³. Para verificar se os dados desse sensor poderiam ser utilizados para detectar CS, Nóbrega realizou uma análise comparativa entre a variação no sinal do EDA e os níveis de desconforto, a fim de avaliar a consistência entre esses dados.

O resultado final alcançado foi uma porcentagem de 63% (29 casos de 46 possíveis) de coerência entre os dados do sensor EDA e o desconforto previsto pelo modelo. Essa mesma porcentagem também foi encontrada com o desconforto relatado pelo participante durante o experimento.

Embora Nóbrega tenha considerado esses resultados satisfatórios, é importante destacar que ele identificou diversas incongruências nos dados coletados pelos sensores, como valores nulos e falhas de leitura, o que pode ter impactado os resultados obtidos.

³https://github.com/Fernando-S/ML_CS_PREDICTOR_PYTHON-GOOGLE-COLAB

Capítulo 3

Proposta e Experimento

Neste capítulo, será apresentada uma visão geral da proposta deste trabalho, bem como os procedimentos adotados para a condução dos experimentos, com ênfase nas ferramentas e tecnologias que tornaram sua realização possível.

3.1 Apresentação da Proposta

A proposta desta pesquisa é realizar uma análise da viabilidade do uso da atividade mioelétrica gástrica na detecção de CS em jogos de VR. Para isso, busca-se demonstrar a existência de uma coerência entre esse dado e os níveis de desconforto registrados, tanto os previstos pelo modelo simbólico de ML desenvolvido por Porcino [1] quanto os relatados pelo participante durante o experimento.

Nesse contexto, a hipótese central do trabalho é que os dados da atividade mioelétrica gástrica sejam condizentes tanto com a predição do modelo simbólico quanto com o relato individual, ou seja, se for determinado que não houve manifestação de CS, os valores do bio sinal devem apresentar pouca alteração com relação à linha de base; caso contrário, deve haver uma alteração significativa.

3.2 Equipamentos e Programas

Para a realização desse trabalho, foi necessário o uso de diversas ferramentas, tanto de hardware quanto de software. No que diz respeito aos componentes de hardware, um dos equipamentos essenciais foi um computador capaz de executar aplicações de realidade virtual, cujas especificações podem ser vistas na Tabela 3.1. Além disso, também foi necessário um HMD para permitir a visualização do ambiente virtual pelo usuário. Nesse caso, optou-se pelo HTC Vive (2016), conforme ilustrado na Figura 3.1. Por fim, foi

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 3.1: Especificações do computador.

utilizado um sensor EGG, por meio da placa BITalino, para realizar a captação dos dados da atividade mioelétrica gástrica.



Figura 3.1: HMD HTC Vive.

Em relação aos softwares, as aplicações de VR utilizadas no experimento foram os dois jogos desenvolvidos por Porcino [1] (Figura 3.2), os quais foram detalhados no Capítulo 2. Quanto ao modelo simbólico de ML, foi usada a versão modificada por Nóbrega [18], que adaptava o programa para o ambiente em nuvem do Google Colab, com algumas alterações para incluir o código de análise dos dados do EGG e corrigir conflitos de versão, a fim de garantir sua execução com o Python 3.10. O código dessa nova versão e os dados analisados estão publicamente disponíveis na plataforma GitHub¹. Ademais, utilizou-se também o aplicativo OpenSignals, que é uma plataforma de aquisição e visualização de dados em tempo real compatível com a placa BITalino².

¹https://github.com/StrawHat972/ML_CS_PREDICTOR_PYTHON-GOOGLE_COLAB-EGG_DATA

²<https://www.pluxbiosignals.com/pages/opensignals>



Figura 3.2: Participantes realizando o experimento com o jogo de voo (parte superior) e o jogo de corrida (parte inferior) desenvolvidos por Porcino [1].

3.2.1 Placa BITalino

Para realizar a coleta dos dados fisiológicos, foi empregado o uso da placa BITalino (r)evolution (Figura 3.3), que é um sistema de código aberto desenvolvido pela Plux Biosignals³ que permite a aquisição precisa e não invasiva de sinais biológicos. Sua composição conta com sensores específicos para cada tipo de sinal, que podem ser facilmente conectados e configurados conforme a necessidade do usuário. Esse dispositivo possibilita a coleta de diversos tipos de biossinais, incluindo Acelerômetro (ACC), Eletrocardiograma (ECG), Eletroencefalograma (EEG), Eletrogastrograma (EGG), Eletromiograma (EMG), entre outros.

Sua utilização para a captura de sinais fisiológicos oferece algumas vantagens significativas. A principal delas é o seu preço acessível, especialmente quando comparado a outros sistemas de mesma finalidade disponíveis no mercado, tornando-se uma opção viável para pesquisadores com recursos limitados. Além disso, por ser um dispositivo compacto e portátil, oferece grande flexibilidade quanto ao local de coleta dos dados, permitindo a captura em diversos ambientes.

³<https://www.pluxbiosignals.com/collections/bitalino>




Figura 3.3: Placa BITalino e sensor EGG.

3.3 Procedimento

Os experimentos conduzidos nesse trabalho se basearam na metodologia adotada por Porcino [1] com as adições feitas por Nóbrega [18] para a inclusão de biossinais. Todos os voluntários que participaram do experimento forneceram consentimento explícito, formalizado pela assinatura do Termo de Consentimento Livre e Esclarecido disponível no Anexo I, no qual concordaram em contribuir de forma anônima para a pesquisa.

A divulgação ocorreu por meio do envio de mensagens em grupos de WhatsApp e abordagens individuais no Departamento de Ciência da Computação (CIC). Como resultado dessa estratégia, a maioria desses voluntários foi de estudantes da Universidade de Brasília (UnB). O experimento foi realizado no decorrer de 2 semanas e, ao todo, contou com a participação de 50 voluntários, 33 do sexo masculino e 17 do sexo feminino, com idades variando entre 18 a mais de 50 anos. Quanto à escolha dos jogos, 31 participantes preferiram o jogo de voo, enquanto 19 optaram pelo jogo de corrida.

3.3.1 Roteiro do Experimento

Antes de dar início ao experimento, reservava-se um tempo para que o voluntário lesse o termo de consentimento e recebesse orientações acerca da condução da experiência. Essas instruções consistiam principalmente em explicar o que deveria ser feito em cada um dos jogos e detalhar o funcionamento dos controles. O participante tinha total liberdade para escolher qual jogo desejava jogar e podia interromper o experimento a qualquer momento, seja por se sentir mal ou simplesmente por querer encerrar a atividade.

Além disso, ele também era instruído a descrever verbalmente seu nível de desconforto, utilizando a seguinte escala: 0 (zero) para ausência de sintomas, 1 (um) para sintomas leves, 2 (dois) para moderados e 3 (três) para severos. A fala era captada por um sistema de reconhecimento de voz, que registrava o nível de desconforto relatado. Então, era realizada a fixação adequada dos eletrodos no participante (ver Figura 2.4 para o posicionamento dos eletrodos do sensor EGG).

Depois de fixar o sensor EGG, o jogador deveria permanecer em repouso por 3 minutos para a coleta da linha de base da atividade mioelétrica gástrica antes de qualquer interação com o ambiente de VR. Em seguida, o participante respondia ao questionário CSPQ, disponível no Anexo II, e ao questionário VRSQ, presente no Anexo III, e colocava o HMD. Após isso, a experiência era iniciada e o jogador deveria completar uma sessão de 5 minutos de atividade com o jogo escolhido, enquanto eram coletadas a avaliação verbal do desconforto sentido e os dados do jogo e do sensor EGG. A Figura 3.2 ilustra a execução de duas instâncias do experimento, uma com o jogo de voo e outra com o jogo de corrida.

Com a conclusão da sessão de jogo, todos os dispositivos conectados ao participante eram removidos e solicitava-se que ele preenchesse novamente o questionário VRSQ após a experiência. Por fim, os equipamentos eram higienizados com lenços umedecidos e os eletrodos usados eram descartados.

Capítulo 4

Resultados e Discussão

Este capítulo apresenta os resultados obtidos com a realização dos experimentos descritos no Capítulo 3, detalhando todo o processamento dos dados, incluindo os critérios de descarte e os ajustes e correções realizados nos dados válidos. Além disso, é fornecida uma análise comparativa dos resultados, acompanhada de uma discussão que apresenta algumas interpretações sobre esses resultados alcançados.

4.1 Processamento dos Dados

Ao todo, foram coletados dados de 50 voluntários anônimos, dos quais 4 decidiram interromper a experiência antes de seu término devido a um mal-estar extremo, que os fez não se sentirem aptos a continuar. Diferente da abordagem adotada por Nóbrega [18], que descartava os dados dos participantes que interrompiam o experimento precocemente, nesta pesquisa optou-se pela manutenção dos dados desses indivíduos, pois, nesses casos, era evidente a manifestação severa da CS, tornando tais dados relevantes para análise. Todos os dados analisados estão disponíveis publicamente no repositório GitHub¹.

4.1.1 Dados Descartados

Mesmo mantendo os dados dos participantes que encerraram prematuramente o experimento, houve casos em que foi necessário fazer o descarte dos dados de alguns indivíduos devido a erros na coleta. De maneira geral, os descartes ocorreram por causa de dois tipos de erros diferentes: erro na coleta dos dados do jogo e erro na leitura do sensor EGG.

Os participantes 27, 41 e 48 tiveram seus dados descartados devido a erros na coleta dos dados do jogo. O participante 27 teve seus dados registrados por 2 minutos e 57 segundos

¹https://github.com/StrawHat972/ML_CS_PREDICTOR_PYTHON-GOOGLE_COLAB-EGG_DATA/tree/main/DATABASE_EGG

até que a gravação parou e não retornou mais, gerando um intervalo de aproximadamente 3 minutos de perda de informação. O participante 41 teve seus dados gravados por 29 segundos, mas ficou por 2 minutos e 49 segundos sem coleta, até que a gravação fosse retomada. Por fim, o participante 48 apresentou um lapso de 53 segundos sem coleta, após 2 minutos e 8 segundos realizando o experimento.

É importante ressaltar que todos os três participantes concluíram os 5 minutos de experiência sem nenhuma interrupção, o que torna a presença desses lapsos de tempo algo anômalo. O motivo que provocou essas falhas não foi investigado, mas todos os três casos ocorreram durante o jogo de voo. Uma hipótese plausível é que, durante a atividade, o sistema operacional tenha sofrido algum travamento, o que impactou a captação dos dados. No entanto, não se pode ter certeza sem antes realizar uma investigação mais detalhada.

Por sua vez, os dados dos indivíduos 2, 4, 6, 7, 8, 16, 17, 19, 36 e 45 do jogo de voo, e dos indivíduos 10, 12, 13, 15, 28, 37, 42 e 46 do jogo de corrida, foram desconsiderados devido a falhas de leitura do sensor EGG durante a coleta da linha de base ou durante a atividade. As Figuras 4.1 a 4.3 apresentam exemplos de sinais descartados devido a problemas com o sensor. Nesses casos, observa-se a presença de diversos picos e oscilações constantes, variando entre o valor máximo (0,28 mV) e o valor mínimo (-0,28 mV) da faixa de operação do sensor, evidenciando a saturação do sinal captado. A Figura 4.2 indica que esse comportamento do sinal não é decorrente da manifestação de CS, visto que foi observado também durante a coleta da linha de base.




Figura 4.1: Sinal lido pelo sensor EGG durante o período de jogo do indivíduo 10.




Figura 4.2: Sinal lido pelo sensor EGG durante o período de repouso do indivíduo 15.




Figura 4.3: Sinal lido pelo sensor EGG durante o período de jogo do indivíduo 17.

O sensor EGG é altamente sensível a ruídos de movimento, por causa disso, existe uma interferência significativa por parte dos outros órgãos presentes na região abdominal, o que poderia explicar os problemas na captura. Por outro lado, como esta pesquisa é pioneira na utilização do sensor EGG integrado ao modelo de ML simbólico desenvolvido

por Porcino [1], alguns cuidados essenciais para a aquisição adequada dos dados não foram seguidos.

Por exemplo, alguns experimentos foram conduzidos com participantes que não estavam em jejum e que haviam acabado de almoçar, o que provavelmente contribuiu para a saturação do sinal devido aos movimentos de contração típicos do processo digestivo. Além disso, era incomum que o participante permanecesse completamente imóvel durante toda a experiência, o que pode ter gerado ruídos por causa dessas pequenas movimentações ou do atrito com as roupas. Por fim, considerando a sensibilidade da região abdominal, era solicitado aos próprios participantes que colocassem os eletrodos no corpo, o que pode ter levado a erros de posicionamento ou uma fixação inadequada.

Devido aos problemas mencionados anteriormente, os dados de 21 participantes foram descartados. Assim, a análise deste trabalho contou com apenas 29 amostras válidas, sendo 18 provenientes do jogo de voo e 11 do jogo de corrida.

4.1.2 Correções e Ajustes dos Dados

Para realizar a análise dos dados dos 29 participantes que não foram descartados, primeiro foi necessário fazer algumas correções na formatação dos dados, tanto do jogo quanto do sensor EGG.

Em relação aos dados do jogo, foram feitas duas correções. A primeira delas foi a conversão dos números decimais, que foram salvos de acordo com a formatação brasileira (com vírgula), para o formato utilizado pelo modelo de ML, que segue o padrão do inglês (com ponto). A outra correção foi o ajuste das *tags* das respostas dos dois questionários VRSQ, as quais foram geradas com os rótulos *Session 0* e *Session 1*, mas o modelo esperava *Session A* e *Session B*. O motivo pelo qual os dados foram gerados seguindo esses padrões não foi investigado, mas deve estar relacionado ao idioma do sistema operacional.

Quanto aos dados do sensor EGG, a placa BITalino converte o sinal analógico do sensor para valores digitais variando entre 0 e 2^{n-1} , sendo n a resolução de amostragem. Em razão disso, é importante converter o sinal digital de volta à unidade física original do sinal do EGG, que é em milivolts (mV), a fim de permitir uma análise adequada. Essa conversão é realizada por meio da função de transferência fornecida no manual do sensor², que é descrita pela seguinte fórmula:

$$EGG(mV) = \left(\frac{\left(\frac{ADC}{2^n} - \frac{1}{2} \right) \times VCC}{G_{EGG}} \right) \times 1000, \quad (4.1)$$

²<https://support.pluxbiosignals.com/wp-content/uploads/2021/11/egg-sensor-datasheet-revb.pdf>

onde $EGG(mV)$ representa o valor da amostra do sinal em milivolts, ADC é o valor digital dessa amostra, VCC é a voltagem de operação, G_{EGG} é o ganho do sensor e n é a resolução de amostragem.

Além disso, uma vez realizada essa conversão para milivolts, é necessário fazer outro ajuste no sinal, agora referente à taxa de amostragem. De forma geral, o sinal do EGG é capturado com frequência de amostragem de até 4 Hz [5], porém, neste trabalho, a sua aquisição foi feita com uma frequência de 100 Hz pela placa BITalino. Por conta disso, foi preciso reduzir a frequência de amostragem para 4 Hz por meio de um *downsampling* do sinal.

4.1.3 Filtragem do Sinal

Apesar de todos os ajustes realizados, os dados do EGG ainda não estão prontos para a fase de análise, pois continuam sendo afetados pela presença de ruídos no sinal. Embora esses ruídos não sejam intensos o bastante para danificar a informação do sinal, é essencial removê-los para garantir uma análise adequada.

Para filtrar o ruído presente no sinal do EGG, foram aplicados dois filtros, seguindo uma abordagem semelhante à descrita nos estudos de Komorowski et al. [5] e Tian et al. [52]. Primeiramente, o sinal foi submetido a um filtro passa-banda Butterworth de quarta ordem, com faixa de frequência de 0,015 a 0,5 Hz. Posteriormente, foi aplicado um filtro passa-baixa Butterworth, também de quarta ordem, com frequência de corte de 0,16 Hz.

Essa combinação de filtros permite preservar apenas as frequências características do sinal de EGG, que se situam no intervalo de 0,015 a 0,15 Hz. A Figura 4.4 ilustra um exemplo desse processo, exibindo no lado esquerdo, em azul, o sinal original do participante 38, onde é evidente a presença de ruídos. Enquanto no lado direito, em vermelho, encontra-se o sinal resultante após a aplicação dos dois filtros.

Com todas as correções e ajustes devidamente realizados, os dados agora podem ser inseridos no modelo de *Machine Learning*, dando início à fase de análise dos resultados obtidos.

4.2 Análise dos Resultados

A finalidade desta pesquisa é investigar a viabilidade da utilização do sensor EGG em conjunto com o modelo de *Machine Learning* desenvolvido por Porcino [1] para identificar *Cybersickness*. Para tanto, foi realizado um estudo comparativo entre os dados gerados pelo sensor e os dados do desconforto relatado durante o experimento, bem como o desconforto previsto pelo modelo. Contudo, para realizar essa comparação, é necessário estabelecer algumas convenções para a interpretação desses dados.




Figura 4.4: Sinal de EGG do participante 38 antes (em azul) e após (em vermelho) a aplicação dos filtros.

Para analisar os dados do sensor EGG, foi feita a extração da frequência dominante do sinal, em ciclos por minuto (cpm), por meio da transformada de Fourier. Em seguida, calculou-se a diferença absoluta entre a frequência dominante da linha de base e a do sinal durante o experimento. Caso essa diferença fosse inferior a 1 cpm, considerou-se que o sinal não apresentou variação.

Já os dados de desconforto, tanto os relatados quanto os previstos, eram registrados em intervalos de um segundo ao longo da experiência. Dessa maneira, um participante que completasse os 5 minutos de experimento teria no mínimo 300 instâncias de coleta de desconforto.

Um ponto importante a ser destacado é que os níveis de desconforto relatados pelos participantes eram classificados segundo uma escala quartenária, variando de 0 a 3. Por outro lado, os níveis de desconforto previstos pelo modelo seguiam uma classificação binária. Para padronizar a análise, os valores de desconforto relatados pelos participantes foram convertidos para a escala binária, de modo que qualquer valor acima de 0 era transformado em 1.

Assim, definiu-se que a leitura do sinal do sensor EGG será considerada coerente quando, na presença de variação na frequência dominante, o desconforto registrado indicar *Cybersickness* por pelo menos 50% do tempo de experimento. Em outras palavras, ao menos metade das instâncias coletadas do participante deve ser classificada como 1 para o desconforto. Caso contrário, a leitura do sensor será considerada incoerente.

A Tabela 4.1 apresenta uma comparação dos resultados obtidos para todos os participantes válidos da pesquisa. Na coluna “Variação EGG”, a ocorrência de variação da frequência dominante é indicada pelo valor da diferença absoluta, com a célula correspondente destacada em amarelo. As colunas “Desconforto relatado” e “Desconforto previsto”

Participante	Varição EGG	Desconforto relatado	Desconforto previsto
1	Sem variação	Coerente	Coerente
3	1,9 cpm	Coerente	Coerente
5	1,3 cpm	Coerente	Incoerente
9	1,9 cpm	Incoerente	Incoerente
11	Sem variação	Incoerente	Coerente
14	Sem variação	Coerente	Coerente
18	Sem variação	Coerente	Coerente
20	1,1 cpm	Incoerente	Incoerente
21	1,3 cpm	Incoerente	Incoerente
22	Sem variação	Coerente	Coerente
23	Sem variação	Coerente	Coerente
24	2,4 cpm	Incoerente	Incoerente
25	Sem variação	Coerente	Coerente
26	Sem variação	Coerente	Coerente
29	Sem variação	Incoerente	Incoerente
30	1,2 cpm	Coerente	Incoerente
31	1,2 cpm	Coerente	Incoerente
32	Sem variação	Coerente	Coerente
33	Sem variação	Incoerente	Coerente
34	Sem variação	Coerente	Coerente
35	1,7 cpm	Incoerente	Incoerente
38	1,2 cpm	Coerente	Coerente
39	2,0 cpm	Incoerente	Coerente
40	1,6 cpm	Coerente	Incoerente
43	1,6 cpm	Incoerente	Incoerente
44	Sem variação	Coerente	Incoerente
47	Sem variação	Coerente	Coerente
49	Sem variação	Coerente	Coerente
50	Sem variação	Coerente	Incoerente

Tabela 4.1: Tabela comparativa dos resultados de todos os participantes válidos.

dependem da variação do sinal do EGG, conforme a definição estabelecida para a coerência dos dados. Nessas duas colunas, os dados considerados coerentes são destacados em verde, enquanto os dados incoerentes são marcados em vermelho.

Por exemplo, ao analisar a linha do participante 5 na Tabela 4.1, observou-se uma variação de 1,3 cpm na frequência dominante do sinal do EGG. Em relação ao desconforto relatado, essa variação mostrou-se coerente, uma vez que, em mais de 50% do tempo, o nível de desconforto relatado foi 1. Contudo, em relação ao desconforto previsto, a variação foi considerada incoerente, já que, em mais de 50% do tempo, o nível de desconforto previsto foi 0.

Agora, analisando a linha do participante 1, verificou-se a ausência de variação na frequência dominante, provavelmente devido a uma alteração inferior a 1 cpm. Tanto o desconforto relatado quanto o previsto mostraram-se condizentes com essa ausência de variação, visto que, em mais de 50% do tempo, o desconforto registrado foi 0.

A análise geral da Tabela 4.1 revelou os seguintes resultados: 65,52% (19 casos) de coerência entre a variação do EGG e o desconforto relatado pelos participantes; 55,17% (16 casos) de coerência entre a variação do EGG e o desconforto previsto pelo modelo de *Machine Learning*; e 44,83% (13 casos) de coerência simultânea entre a variação do EGG, o desconforto relatado e o desconforto previsto.

4.2.1 Resultados Parciais - Jogo de Corrida

Além da análise geral que abrange todos os participantes válidos, é interessante realizar uma análise específica considerando apenas os jogadores de cada jogo. Nesse contexto, a Tabela 4.2 apresenta a comparação dos resultados obtidos exclusivamente dos participantes que escolheram jogar o jogo de corrida.

Levando em conta apenas os 11 participantes que optaram pelo jogo de corrida, os seguintes resultados foram obtidos: 72,73% (8 casos) de coerência entre a variação do EGG e o desconforto relatado pelos participantes; 63,64% (7 casos) de coerência entre a variação do EGG e o desconforto previsto pelo modelo; e 54,55% (6 casos) de coerência simultânea entre a variação do EGG, o desconforto relatado e o desconforto previsto.

4.2.2 Resultados Parciais - Jogo de Voo

Já a Tabela 4.3 apresenta a comparação dos resultados obtidos unicamente dos participantes que optaram por jogar o jogo de voo.

Considerando todos os 18 participantes que jogaram o jogo de voo, foram alcançados os resultados a seguir: 61,11% (11 casos) de coerência entre a variação do EGG e o desconforto relatado pelos participantes; 50,0% (9 casos) de coerência entre a variação do

Participante	Variação EGG	Desconforto relatado	Desconforto previsto
3	1,9 cpm	Coerente	Coerente
14	Sem variação	Coerente	Coerente
21	1,3 cpm	Incoerente	Incoerente
22	Sem variação	Coerente	Coerente
24	2,4 cpm	Incoerente	Incoerente
25	Sem variação	Coerente	Coerente
31	1,2 cpm	Coerente	Incoerente
38	1,2 cpm	Coerente	Coerente
39	2,0 cpm	Incoerente	Coerente
44	Sem variação	Coerente	Incoerente
49	Sem variação	Coerente	Coerente

Tabela 4.2: Tabela comparativa dos resultados dos participantes do jogo de corrida.

Participante	Variação EGG	Desconforto relatado	Desconforto previsto
1	Sem variação	Coerente	Coerente
5	1,3 cpm	Coerente	Incoerente
9	1,9 cpm	Incoerente	Incoerente
11	Sem variação	Incoerente	Coerente
18	Sem variação	Coerente	Coerente
20	1,1 cpm	Incoerente	Incoerente
23	Sem variação	Coerente	Coerente
26	Sem variação	Coerente	Coerente
29	Sem variação	Incoerente	Incoerente
30	1,2 cpm	Coerente	Incoerente
32	Sem variação	Coerente	Coerente
33	Sem variação	Incoerente	Coerente
34	Sem variação	Coerente	Coerente
35	1,7 cpm	Incoerente	Incoerente
40	1,6 cpm	Coerente	Incoerente
43	1,6 cpm	Incoerente	Incoerente
47	Sem variação	Coerente	Coerente
50	Sem variação	Coerente	Incoerente

Tabela 4.3: Tabela comparativa dos resultados dos participantes do jogo de voo.

EGG e o desconforto previsto pelo modelo; e 38,89% (7 casos) de coerência simultânea entre a variação do EGG, o desconforto relatado e o desconforto previsto.

4.3 Discussão

Ao observar os resultados dos três cenários avaliados (todos os participantes, apenas os que jogaram o jogo de corrida e apenas os que jogaram o jogo de voo), verificou-se que, em todos os casos, a coerência entre os dados do EGG e o desconforto relatado pelos participantes foi superior a 60%. Similarmente, a coerência entre os dados do EGG e o desconforto previsto pelo modelo alcançou, no mínimo, 50% nos três cenários.

O cenário com o melhor resultado foi o que considerou somente os jogadores do jogo de corrida, alcançando 72,73% de coerência com o desconforto relatado e 63,64% com o previsto. Em contrapartida, o cenário com o pior desempenho foi o dos jogadores do jogo de voo, que apresentaram apenas 61,11% de coerência com o desconforto relatado e 50,0% com o previsto.

Com relação à coerência simultânea entre os dados do EGG, o desconforto relatado e o desconforto previsto, apenas o cenário que considerou exclusivamente os jogadores do jogo de corrida apresentou uma coerência superior a 50%. O pior desempenho foi registrado no cenário do jogo de voo, com apenas 38,89% de coerência simultânea.

Essa baixa coerência simultânea pode ter sido influenciada pela discrepância entre os níveis de desconforto relatados e previstos, já que apenas em 68,97% dos casos esses níveis coincidiram. Em outras palavras, embora o modelo ofereça uma previsão mais do que satisfatória para a manifestação da *Cybersickness*, ele ainda não é capaz de prever com 100% de certeza o desconforto sentido.

Agora, comparando os resultados deste trabalho com os obtidos por Nóbrega [18] em sua pesquisa, observa-se que, no cenário geral, Nóbrega alcançou 63,04% de coerência entre os dados do sensor EDA e o desconforto registrado, tanto o relatado quanto o previsto, além de uma coerência simultânea de 36,96%. Por outro lado, este trabalho apresentou resultados superiores no cenário geral, com 65,52% de coerência com o desconforto relatado e 44,83% de coerência simultânea, porém teve desempenho inferior na coerência com o desconforto previsto, que foi de 55,17%.

Além disso, diferentemente do estudo de Nóbrega, que identificou a melhor coerência com o desconforto relatado no cenário que considerava apenas o jogo de voo (66,67%) e a melhor coerência com o desconforto previsto no cenário que abrangia exclusivamente o jogo de corrida (73,68%), neste trabalho, ambos os melhores resultados foram alcançados no cenário do jogo de corrida, com 72,73% de coerência com o desconforto relatado e 63,64% com o previsto.

Dessa forma, percebe-se que a utilização do sensor EGG para identificar a manifestação da *Cybersickness* apresentou resultados satisfatórios, uma vez que a análise da variação da frequência dominante do sinal desse sensor demonstrou coerência em mais de 50% dos casos no cenário geral, tanto com o relato individual quanto com a previsão do modelo. Esses resultados estão alinhados com os encontrados na pesquisa de Nóbrega, que demonstrou a viabilidade do uso do sensor EDA para identificação de CS no contexto do modelo simbólico de aprendizado de máquina desenvolvido por Porcino [1].

Embora a viabilidade da utilização do EGG para detectar CS no contexto analisado tenha sido verificada, o sensor ainda apresenta diversos desafios e limitações que indicam oportunidades de melhoria, especialmente no que se refere à análise e ao processamento do sinal. No entanto, no contexto deste trabalho, o objetivo de avaliar o uso do sensor EGG para identificar CS foi alcançado.

4.3.1 Experimentos Interrompidos

Outro ponto importante a ser discutido são os casos específicos dos participantes que optaram por interromper o experimento antes do seu término. Ao todo, foram 4 participantes que solicitaram a interrupção: os participantes 10, 21 e 42 do jogo de corrida, e o participante 34 do jogo de voo. Em todos os casos, essa interrupção ocorreu devido a um mal-estar extremo.

O participante 10 realizou o experimento por cerca de 3 minutos, até solicitar a interrupção devido a um enjoo forte. O mesmo sintoma foi relatado pelo participante 21, que interrompeu a experiência faltando cerca de 30 segundos para sua conclusão. O participante 34, por sua vez, realizou o experimento por apenas 20 segundos, até apresentar uma vertigem intensa. Por fim, o participante 42 completou 3 minutos e 20 segundos do experimento antes de decidir interrompê-lo devido a uma forte tontura.

Quanto aos dados do sensor EGG, os dados dos participantes 10 e 42 apresentaram erros de leitura e, por isso, foram descartados, impossibilitando qualquer interpretação dos mesmos. Por outro lado, o participante 21 apresentou uma variação de 1,3 cpm na frequência dominante durante o experimento, porém tanto o desconforto relatado quanto o previsto foram incoerentes com essa variação.

Como a definição adotada de coerência considerava que o nível de desconforto fosse 1 por pelo menos 50% do tempo na presença de variação do EGG, é provável que o participante 21 tenha sentido os efeitos da CS próximo da metade do tempo normal do experimento. Como ele interrompeu a experiência antes de sua conclusão, a quantidade de instâncias com valor 0 de desconforto foi superior ao número de instâncias com valor 1, o que gerou os resultados não condizentes.

O participante 34, por sua vez, não apresentou variação na frequência dominante, o que foi coerente tanto com o desconforto relatado quanto o previsto. No entanto, esse resultado provavelmente se deve ao fato de que não houve tempo suficiente de coleta de dados, pois assim que a experiência começou, o participante solicitou a interrupção. Considerando que esse participante é um indivíduo com mais de 50 anos e sem experiência prévia com VR, é possível que ele tenha estranhado o ambiente virtual, o que pode ter provocado a sensação de vertigem.

Além dos participantes 10 e 21, diversos outros também relataram a ocorrência de enjoo após o experimento. Porém, a metodologia adotada pelo modelo utiliza o questionário VRSQ, que não leva em consideração os sintomas relacionados ao grupo de náusea, o que pode ter impactado os resultados. Mesmo assim, a ocorrência da náusea nesses participantes sugere que a atividade mioelétrica gástrica, que apresenta um comportamento atípico na presença do enjoo, está diretamente relacionada com a manifestação de CS.

4.3.2 Dificuldades e Problemas Encontrados

Por fim, é relevante destacar as dificuldades e problemas enfrentados na realização desse trabalho. Além dos problemas já mencionados relacionados aos dados do jogo e do sensor EGG, que resultaram no descarte de quase metade dos dados dos voluntários (21 descartados de um total de 50), outras adversidades também surgiram ao longo da realização do experimento.

Uma das principais adversidades enfrentadas diz respeito a um problema de conexão entre a placa BITalino e o computador que executava a aplicação em VR. Esse problema ocorria, sobretudo, durante a preparação dos equipamentos antes do início dos experimentos. A conexão Bluetooth da placa não era reconhecida pelo sistema operacional, de modo que ela não aparecia na lista de dispositivos disponíveis.

A única solução encontrada para tal problema foi reiniciar o computador, o que fazia com que o dispositivo BITalino voltasse a ser exibido na lista. Embora esse problema não tenha causado erros nas medições, ele gerava atrasos na preparação do material.

Outra dificuldade enfrentada esteve relacionada à coleta do relato individual de desconforto pelos participantes. Em tese, os participantes deveriam informar seu nível de desconforto, de acordo com a escala de 0 a 3, sempre que percebessem alguma alteração durante o experimento. Contudo, na prática, muitos ficavam imersos na atividade e frequentemente esqueciam de relatar seu nível de desconforto, sendo necessário realizar uma quebra de imersão para lembrá-los de fazer o relato. Além disso, houve casos em que o reconhecimento de voz não funcionou de forma adequada, falhando ocasionalmente em reconhecer os comandos em português dados pelos participantes.

Houve também problemas relacionados ao dispositivo de VR utilizado. Alguns voluntários que usavam óculos tentaram realizar o experimento com eles, o que frequentemente resultava em uma fixação inadequada do HMD. Em casos em que os óculos não cabiam dentro do dispositivo, os participantes precisaram realizar o experimento sem eles, o que, em algumas situações, comprometeu sua imersão na atividade devido à visão prejudicada.

Os controles do HTC Vive (Figura 3.1) se mostraram problemáticos para utilização com o público geral, uma vez que seu formato era pouco usual para a maioria dos participantes. Isso gerava uma confusão inicial em seu uso, que era agravada pela dessincronização frequente devido à inatividade dos controles durante o intervalo entre os experimentos.

Em alguns casos, essa dessincronização causava a inversão dos controles direito e esquerdo. Além disso, enquanto o jogo de voo utilizava apenas um controle, o de corrida exigia ambos. Por conta da dessincronização, era comum que os participantes do jogo de voo iniciassem com o controle incorreto, o que tornava necessária a substituição durante o experimento.

Apesar desses problemas, não houve erros significativos que levassem a mais descartes de dados. No entanto, essas situações, especialmente as relacionadas à coleta do relato individual e à confusão com os controles, podem ter influenciado alguns dos resultados. Embora não tenha sido realizada uma análise para determinar o impacto dessas questões, seria ideal considerar essas adversidades em estudos futuros, a fim de obter resultados mais precisos e confiáveis.

Capítulo 5

Conclusão

Este trabalho teve como objetivo analisar a utilização do Eletrogastrograma (EGG) na identificação da *Cybersickness*. Para isso, foi conduzida uma análise comparativa entre os dados coletados por esse sensor e os níveis de desconforto, tanto os relatados pelos participantes durante o experimento quanto os previstos pelo modelo simbólico de aprendizado de máquina desenvolvido por Porcino [1]. O objetivo era verificar a existência de uma coerência entre essas informações e, assim, validar a análise da atividade mioelétrica gástrica como método para detectar essa condição.

Os dados foram obtidos por meio de um experimento em Realidade Virtual, em que os participantes eram expostos a um ambiente virtual por aproximadamente 5 minutos, enquanto, utilizando um *Head-mounted Display*, jogavam um dos dois jogos de VR disponíveis, podendo escolher entre um jogo de corrida ou um de voo. Para coletar os dados do sensor EGG, contou-se com o auxílio da placa BITalino. Ao todo, foram conduzidos 50 experimentos, dos quais 21 foram descartados devido a erros de leitura, resultando em 29 amostras válidas.

Para interpretar as alterações no sinal do EGG, adotou-se uma análise baseada na frequência dominante do sinal. Os dados foram considerados coerentes quando, diante de uma variação na frequência dominante, o participante apresentava desconforto por pelo menos metade da duração do experimento.

No caso geral, que considerou todos os participantes válidos, os resultados indicaram uma coerência de 65,52% com o desconforto relatado pelos participantes, 55,17% com o desconforto previsto pelo modelo simbólico e 44,83% com ambos os desconfortos avaliados. Já no melhor caso, o qual considerava exclusivamente os participantes do jogo de corrida, observou-se uma coerência de 72,73% com o desconforto relatado, 63,64% com o desconforto previsto e 54,55% com ambos.

Esses resultados demonstram que é possível identificar *Cybersickness* por meio da análise da atividade mioelétrica gástrica, uma vez que a variação do sinal do EGG em todos

os cenários considerados foi condizente tanto ao desconforto relatado pelos participantes quanto ao desconforto previsto pelo modelo, embora não de forma simultânea, em pelo menos 50,0% dos casos. Tais resultados foram similares aos encontrados em outro trabalho que buscou estudar a viabilidade da utilização da Atividade Eletrodérmica na detecção de *Cybersickness* [18].

Durante a realização desta pesquisa, diversos problemas e dificuldades foram encontrados, os quais podem ter prejudicado os resultados alcançados. Isso fica evidente ao observar que a quantidade de dados descartados foi quase equivalente à metade do total de experimentos realizados. Além disso, a coerência simultânea entre os três dados analisados só foi superior a 50,0% no melhor caso. Dessa forma, para estudos futuros, seria interessante focar em aprimorar esses resultados, seja por meio de ajustes no modelo ou pela adoção de novas abordagens para a coleta e análise do sinal do EGG.

5.1 Trabalhos Futuros

O tempo de duração do experimento é um fator importante a ser considerado em estudos futuros. Na metodologia adotada, era registrado o sinal do EGG por cerca de 3 minutos em repouso e 5 minutos durante a atividade. Uma alteração pertinente seria padronizar tanto o tempo de repouso quanto o de atividade para 5 minutos. Além disso, uma exposição mais prolongada poderia oferecer novas interpretações sobre os resultados obtidos, como uma possível relação entre a coerência dos dados e o tempo de exposição. Uma possível abordagem para essa ideia seria utilizar a versão do modelo de Porcino [1] que considera experimentos com duração de 20 minutos.

Outra sugestão refere-se ao aprimoramento dos algoritmos de *Machine Learning* utilizados. Como foi pontuado neste trabalho, o desconforto previsto correspondeu ao relatado pelo participante em apenas 68,97% das vezes. Por esse motivo, ajustes no código do modelo são necessários para melhorar essa correspondência. Além disso, poderia ser considerada a inclusão dos dados do EGG como atributo para a classificação, a fim de investigar o impacto dessa adição na predição de desconforto.

Um dos principais problemas deste trabalho foi o descarte significativo de dados. Nesse sentido, é encorajada a reprodução da pesquisa adotando uma abordagem de coleta mais cuidadosa que assegure que os aparelhos estejam corretamente fixados e posicionados, e que os participantes se encontrem em condições ideais para obtenção da atividade mioelétrica gástrica, de forma a reduzir a perda de dados válidos para análise. Também seria igualmente relevante investigar os erros de leitura ocorridos durante o experimento, especialmente aqueles relacionados à captura dos dados do jogo.

Considerando que este estudo não incluiu uma comparação entre os dados do EGG e os resultados do questionário VRSQ, uma possível linha de pesquisa seria realizar um estudo comparativo entre a variação do sinal do EGG e as pontuações obtidas no questionário VRSQ. Além disso, a análise da alteração do EGG foi realizada tendo como base uma abordagem que considera a variação da frequência dominante. No entanto, existem outras abordagens possíveis, como analisar a amplitude do sinal ou identificar a presença de arritmias nas contrações do estômago.

Por fim, a replicação desta pesquisa usando outros sensores, como EEG ou EMG, pode contribuir para investigar a viabilidade de suas aplicações na identificação de CS. Embora este trabalho tenha realizado uma breve comparação entre os resultados obtidos de dois sensores diferentes (EGG e EDA), tal análise foi feita com resultados provenientes de conjuntos de dados distintos. Dessa forma, um possível trabalho futuro seria reproduzir este estudo utilizando um ou mais sensores adicionais, o que permitiria comparar os resultados de diferentes sensores a partir do mesmo conjunto de dados.

Referências

- [1] Porcino, Thiago Malheiros: *Cybersickness Analysis Using Symbolic Machine Learning Algorithms*. Tese de Doutorado, Universidade Federal Fluminense - UFF, Niterói-RJ, Brasil, 2021. v, vi, ix, x, 2, 4, 6, 7, 8, 12, 14, 16, 17, 18, 19, 24, 25, 31, 34, 35, 44
- [2] Tengan, Bruno Takashi: *Analisando a cybersickness: Dados fisiológicos e informações contextuais como possíveis indicativos de causas*. Trabalho de Conclusão de Curso, Universidade de Brasília - UnB, Brasília-DF, Brasil, 2021. ix, 1, 4
- [3] Bos, Jelte, Ben D. Lawson, Jonathan Allsop, Paolo Rigato e Stefano Secci: *Guidelines for mitigating cybersickness in virtual reality systems*. Relatório Técnico TR-HFM-MSG-323, NATO Science & Technology Organization, 2021. ix, 5
- [4] NeuroSky: *Making sense of eeg bands*, 2015. <https://neurosky.com/2015/05/greek-alphabet-soup-making-sense-of-eeg-bands/>, acesso em 2024-11-19. ix, 9
- [5] 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), 2015. ix, 2, 10, 25
- [6] Mishra, Sushruta, Lambodar Jena, Hrudaya Kumar Tripathy e Tarek Gaber: *Prioritized and predictive intelligence of things enabled waste management model in smart and sustainable environment*. PLoS ONE, 17(8):1–22, 2022. ix, 12
- [7] Porcino, Thiago, Erick O. Rodrigues, Flavia Bernardini, Daniela Trevisan e Esteban Clua: *Identifying cybersickness causes in virtual reality games using symbolic machine learning algorithms*. Entertainment Computing, 41:100473, 2022. ix, 1, 14
- [8] 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. x, 7, 45
- [9] Martirosov, Sergo e Pavel Kopecek: *Cyber sickness in virtual reality - literature review*. Em *Proceedings of the 28th DAAAM International Symposium*, páginas 718–726. DAAAM International, 2017. 1
- [10] Fortune Business Insights: *Virtual reality market size, share & industry analysis*, 2023. <https://www.fortunebusinessinsights.com/industry-reports/virtual-reality-market-101378>, acesso em 2024-12-15. 1

- [11] Wohlgenannt, Isabell, Alexander Simons e Stefan Stieglitz: *Virtual reality*. Business & Information Systems Engineering, 62(5):455–461, 2020. 1
- [12] LaViola, Joseph J.: *A discussion of cybersickness in virtual environments*. ACM SIGCHI Bulletin, 32(1):47–56, 2000. 1, 5, 6
- [13] Jin, Weina, Jianyu Fan, Diane Gromala e Philippe Pasquier: *Automatic prediction of cybersickness for virtual reality games*. Em *2018 IEEE Games, Entertainment, Media Conference (GEM)*, páginas 1–9, 2018. 1, 6
- [14] Kim, Jinwoo, Woojae Kim, Heeseok Oh, Seongmin Lee e Sanghoon Lee: *A deep cybersickness predictor based on brain signal analysis for virtual reality contents*. Em *2021 IEEE/CVF International Conference on Computer Vision (ICCV)*, 2019. 1, 2, 11
- [15] Jeong, Daekyo, Sangbong Yoo e Jang Yun: *Cybersickness analysis with EEG using deep learning algorithms*. Em *2019 IEEE Conference on Virtual Reality and 3D User Interfaces (VR)*, 2019. 1, 2, 11
- [16] Silva, Wedrey Nunes da: *Análise da cybersickness através de biosinais: uma abordagem com machine learning simbólico*. Tese de Mestrado, Universidade de Brasília - UnB, Brasília-DF, Brasil, 2024. 1, 5, 7, 8, 9
- [17] Chen, Jiande e Richard W. McCallum: *Electrogastrography: Measurement, analysis and prospective applications*. Medical & Biological Engineering & Computing, 29(4):339–350, 1991. 2, 9
- [18] Nóbrega, Fernando S.: *Identificando a cybersickness: combinação da atividade eletrodérmica e aprendizado de máquina simbólico*. Trabalho de Conclusão de Curso, Universidade de Brasília - UnB, Brasília-DF, Brasil, 2023. 2, 8, 14, 17, 19, 21, 30, 35
- [19] Lowood, Henry E.: *Virtual reality (vr) | definition, development, technology, examples, & facts*. <https://www.britannica.com/technology/virtual-reality>, acesso em 2024-11-13. 3
- [20] Burdea, Grigore C. e Philippe Coiffet: *Virtual Reality Technology*. John Wiley & Sons, 2ª edição, 2003. 3, 4
- [21] Walsh, Kenneth R. e Suzanne D. Pawlowski: *Virtual reality: a technology in need of IS research*. Communications of the Association for Information Systems, 8, 2002. 3
- [22] Pimentel, Ken e Kevin Teixeira: *Virtual reality - through the new looking glass*. Windcrest, 1993. 3
- [23] Latta, J. N. e D. J. Oberg: *A conceptual virtual reality model*. IEEE Computer Graphics and Applications, 14(1):23–29, 1994. 3
- [24] Merhi, Omar, Elise Faugloire, Moira Flanagan e Thomas A. Stoffregen: *Motion sickness, console video games, and head-mounted displays*. Human Factors, 49(5):920–934, 2007. 3

- [25] Tollini, Gabriel C.: *Avaliação do Virtual Reality Sickness Questionnaire (VRSQ) como preditor de cybersickness*. Trabalho de Conclusão de Curso, Universidade de Brasília - UnB, Brasília-DF, Brasil, 2020. 4
- [26] Irwin, J. A.: *The pathology of sea-sickness*. The Lancet, 118(3039):907–909, 1881. 4
- [27] Reason, J. T. e J. J. Brand: *Motion sickness*. Academic Press, 1975. 4, 6
- [28] Kemeny, Andras, Jean Rémy Chardonnet e Florent Colombet: *Getting Rid of Cybersickness: In Virtual Reality, Augmented Reality, and Simulators*. Springer International Publishing, 2020. 5
- [29] McCauley, Michael E. e Thomas J. Sharkey: *Cybersickness: Perception of self-motion in virtual environments*. Presence: Teleoperators & Virtual Environments, 1(3):311–318, 1992. 5
- [30] Money, K. E.: *Motion sickness*. Physiological Reviews, 50(1):1–39, 1970. 5
- [31] Kennedy, R. S., L. J. Hettinger e M. G. Lilienthal: *Simulator sickness*. Motion and space sickness, páginas 317–341, 1988. 6
- [32] Souza, Danilo Neves: *Cybersickness e dados fisiológicos: Um estudo exploratório*. Trabalho de Conclusão de Curso, Universidade de Brasília - UnB, Brasília-DF, Brasil, 2020. 6
- [33] Treisman, Michel: *Motion sickness: An evolutionary hypothesis*. Science, 197:493–495, 1977. 6
- [34] Riccio, Gary E. e Thomas A. Stoffregen: *An ecological theory of motion sickness and postural instability*. Ecological Psychology, 3(3):195–240, 1991. 6
- [35] Kennedy, Robert S., Norman E. Lane, Kevin S. Berbaum e Michael G. Lilienthal: *Simulator sickness questionnaire: An enhanced method for quantifying simulator sickness*. International Journal of Aviation Psychology, 3(3):203–220, 1993. 7
- [36] 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, 2019. 7
- [37] Stone III, William Bruce: *Psychometric evaluation of the Simulator Sickness Questionnaire as a measure of cybersickness*. Tese de Doutorado, Iowa State University, 2017. 7
- [38] 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. 8
- [39] 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, 2020. 8

- [40] 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. 8
- [41] Berbari, Edward J.: *The Biomedical Engineering Handbook*, capítulo 13. CRC Press LLC, 2ª edição, 2000. 8
- [42] Poh, Ming Zher, Nicholas C. Swenson e Rosalind W. Picard: *A wearable sensor for unobtrusive, long-term assessment of electrodermal activity*. IEEE Transactions on Biomedical Engineering, 57(5):1243–1252, 2010. 8
- [43] Kim, Young Youn, Eun Nam Kim, Min Jae Park, Kwang Suk Park, Hee Dong Ko e Hyun Taek Kim: *The application of biosignal feedback for reducing cybersickness from exposure to a virtual environment*. Presence, 17(1):1–16, 2008. 8
- [44] Blinowska, Katarzyna e Piotr Durka: *Electroencephalography (eeg)*. Wiley Encyclopedia of Biomedical Engineering, 2006. 8
- [45] 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. 9
- [46] Kim, Young Youn, Hyun Ju Kim, Eun Nam Kim, Hee Dong Ko e Hyun Taek Kim: *Characteristic changes in the physiological components of cybersickness*. Presence, 42(5):616–625, 2005. 9, 10
- [47] Yin, Jieyun e Jiande D. Z. Chen: *Electrogastrography: Methodology, validation and applications*. Journal of Neurogastroenterology and Motility, 19(1):5–17, 2013. 9
- [48] 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, 2013:1–14, 2013. 9
- [49] Koch, Kenneth L.: *Gastric dysrhythmias: A potential objective measure of nausea*. Experimental Brain Research, 232(8):2553–2561, 2014. 9
- [50] Farmer, Adam D., Vin F. Ban, Steven J. Coen, Gareth J. Sanger, Gareth J. Barker, Michael A. Gresty, Vincent P. Giampietro, Steven C. Williams, Dominic L. Webb, Per M. Hellström, Paul L. R. Andrews e Qasim Aziz: *Visually induced nausea causes characteristic changes in cerebral, autonomic and endocrine function in humans*. The Journal of Physiology, 593(5):1183–1196, 2015. 10
- [51] Dennison, Mark S., A. Zachary Wisti e Michael D’Zmura: *Use of physiological signals to predict cybersickness*. Displays, 44:42–52, 2016. 10
- [52] Tian, Nana, Khalil Haroun Achache, Ali Raed Ben Mustapha e Ronan Boulic: *EGG objective characterization of cybersickness symptoms towards navigation axis*. Em 2023 IEEE Conference on Virtual Reality and 3D User Interfaces Abstracts and Workshops (VRW), páginas 289–297, 2023. 10, 25

- [53] Vieira, Sandra, Walter Hugo Lopez Pinaya e Andrea Mechelli: *Introduction to Machine Learning*. Elsevier, 2019. 10
- [54] Alpaydin, Ethem: *Introduction to Machine Learning*. MIT Press, 2004. 10
- [55] Mitchell, Tom Michael: *Machine Learning*. McGraw-Hill Science/Engineering/Math, 1997. 10
- [56] Bochie, Kaylani, Mateus S. Gilbert, Luana Gantert, Mariana S. M. Barbosa, Dianne S. V. Medeiros e Miguel E. M. Campista: *Aprendizado profundo em redes desafiadoras: Conceitos e aplicações*. Em *Minicursos do XXXVIII Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos (SBRC 2020)*, 2020. 10
- [57] Islam, Rifatul, Samuel Ang e John Quarles: *Cybersense: A closed-loop framework to detect cybersickness severity and adaptively apply reduction techniques*. Em *2022 IEEE Conference on Virtual Reality and 3D User Interfaces Abstracts and Workshops (VRW)*, 2021. 11
- [58] Bernardini, Flávia Cristina, Maria Carolina Monard e Ronaldo C. Prati: *Constructing ensembles of symbolic classifiers*. *International Journal of Hybrid Intelligent Systems*, 3(3):159–167, 2006. 11, 12
- [59] Padmanaban, Nitish, Timon Ruban, Vincent Sitzmann, Anthony M. Norcia e Gordon Wetzstein: *Towards a machine-learning approach for sickness prediction in 360° stereoscopic videos*. *IEEE Transactions on Visualization and Computer Graphics*, 24(4):1594–1603, 2018. 12
- [60] Garcia-Agundez, Augusto, Christian Reuter, Hagen Becker, Robert Konrad, Polona Caserman, André Miede e Stefan Göbel: *Development of a classifier to determine factors causing cybersickness in virtual reality environments*. *Games for Health Journal*, 8(6):439–444, 2019. 12

Anexo I

Termo de Consentimento Livre e Esclarecido

Você está sendo convidado a participar da pesquisa **Análise da Atividade Mioelétrica Gástrica e Aprendizado de Máquina Simbólico na Detecção de Cybersickness**, de responsabilidade de JOÃO VÍCTOR SIQUEIRA DE ARAUJO, estudante de graduação da Universidade de Brasília. O objetivo desta pesquisa é **Investigar a viabilidade da aplicação do eletrogastrograma (EGG) para identificação de Cybersickness no contexto de 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 trabalho de conclusão de curso, 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 *joaovictorsa972@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 _____

Anexo II

Cybersickness Profile Questionnaire (CSPQ)

#	Pergunta	Opções
1	Gênero	Feminino, Masculino
2	Idade	18 a 36, 37 a 50, +50
3	Experiência com VR	Nenhuma, Alguma, Muita
4	Desconforto atual	Nenhum, Algum, Muito
5	Usa óculos de grau	Não, Sim
6	Deficiências visuais	Nenhuma, Miopia, Hipermetropia, Astigmatismo
7	Desconforto com telas	Nenhum, Algum, Muito
8	Olho Dominante	Esquerdo, Direito
9	Postura de jogo	Sentadado, Em pé

Tabela II.1: Adaptação do CSPQ para português [1].

Anexo III

Virtual Reality Sickness Questionnaire (VRSQ)

#	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 III.1: Adaptação do VRSQ para português [8].