



Universidade de Brasília

Instituto de Ciências Exatas  
Departamento de Ciência da Computação

**Identificando a cybersickness: combinação da  
atividade eletrodérmica e aprendizado de máquina  
simbólico**

Fernando Sobral Nóbrega

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

Orientadora  
Prof.a Dr.a Carla Denise Castanho

Brasília  
2023



Universidade de Brasília

Instituto de Ciências Exatas  
Departamento de Ciência da Computação

**Identificando a cybersickness: combinação da  
atividade eletrodérmica e aprendizado de máquina  
simbólico**

Fernando Sobral Nóbrega

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

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

Prof. Dr. Tiago Barros Pontes e Silva    Prof. Dr. Maurício Miranda Sarmet  
DIN/UNB    IFPB

Prof. Dr. João Luiz Azevedo de Carvalho  
Coordenador do Curso de Engenharia da Computação

Brasília, 16 de fevereiro de 2023

# Dedicatória

*Dedico este trabalho à minha mãe por me permitir seguir minhas vontades mesmo que não fizessem sentido para ela; aos meus amigos que sempre estão ao meu lado mesmo quando não mereço; aos professores que me ensinaram a ter uma visão mais aberta e ao meu eu do passado por todos os seus erros e acertos que fizeram de mim quem eu sou hoje.*

# Agradecimentos

*Agradeço a minha orientadora e professora Carla Denise Castanho, aos professores Tiago Barros Pontes e Silva e Maurício Miranda por participarem da banca avaliadora, à professora Carla Cavalcante Koike por todo seu apoio durante a minha graduação, a todos os voluntários que participaram dos experimentos realizados e, principalmente, aqueles que me fizeram companhia ao longo dos dias de experimentos.*

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

*Atualmente, a indústria de jogos é a que mais cresce. O mercado global foi avaliado em 151,55 bilhões de dólares em 2019 e deve atingir um valor de 256,97 bilhões em 2025 [1]. Entre o grande número de gêneros, tecnologias e inovações que a permeiam, uma das mais relevantes e empolgantes é a Realidade Virtual (RV). No entanto, há grandes dificuldades que os desenvolvedores enfrentam ao adentrar este mercado. Um dos mais proeminentes é que muitas pessoas experienciam desconforto ou mal-estar quando expostos à Realidade Virtual (RV), termo conhecido como cybersickness.*

*Porcino et al. [2] criaram um software de simulação [3] contendo dois jogos em Realidade Virtual (RV), contendo os questionários Virtual Reality Sickness Questionnaire (VRSQ) e CyberSickness Profile Questionnaire (CSPQ), e apresentaram um código de aprendizado de máquina [4] para identificação e previsão dos sintomas da cybersickness.*

*Este trabalho apresenta uma abordagem de minimização do uso de dados subjetivos na identificação e previsão dos sintomas da cybersickness no trabalho proposto por Porcino et al. [2], fazendo-se o uso da atividade eletrodérmica da pele, um dado fisiológico, para validar a previsão e identificação desses sintomas geradas por aprendizado de máquina.*

**Palavras-chave:** Cybersickness, realidade virtual, aprendizado de máquina, sinais fisiológicos, EDA

# Abstract

*The virtual reality market has been growing in recent years due to an increase in access to the necessary equipment and the expansion of virtual reality applications. However, the effects of cybersickness, a malaise caused by immersion in virtual environments, serve as an obstacle in the general use of devices such as Head Mounted Display (HMD). With studies pointing out that a significant part of the population is susceptible to cybersickness, it is important to unravel its causes and develop methods to prevent or mitigate its symptoms.*

*Porcino et al. [2] created a simulation software [3] with two Realidade Virtual (RV) games where the Virtual Reality Sickness Questionnaire (VRSQ) e CyberSickness Profile Questionnaire (CSPQ) were used. They also implemented a machine learning algorithm [4] to identify and predict cybersickness symptoms during gameplay.*

*This work presents an approach to minimize the use of subjective data in predicting and identifying cybersickness symptoms proposed by Porcino et al. [2] and felt during virtual reality equipment usage by analyzing the skin's electrodermal activity, a physiological data, to validate the prediction and identification of these symptoms generated via machine learning.*

**Keywords:** Cybersickness, virtual reality, machine learning, physiological data, EDA

# Sumário

<b>1</b>	<b>Introdução</b>	<b>1</b>
1.1	Objetivos . . . . .	1
1.2	Estruturação . . . . .	2
<b>2</b>	<b>Fundamentação Teórica</b>	<b>3</b>
2.1	Realidade Virtual . . . . .	3
2.2	<i>Head Mounted Display</i> . . . . .	4
2.3	Tipos de desconforto em RV . . . . .	4
2.4	Causas da cybersickness . . . . .	5
2.5	Técnicas de mitigação da cybersickness . . . . .	6
2.5.1	Redução do campo de visão . . . . .	6
2.5.2	Desfoque de movimento . . . . .	7
2.5.3	Ponto de referência estático . . . . .	7
2.5.4	Head Lock . . . . .	8
2.6	Meios de quantificação da cybersickness . . . . .	9
2.6.1	Dados subjetivos . . . . .	9
2.6.2	Dados fisiológicos . . . . .	10
2.6.3	Dados de perfil . . . . .	12
2.7	Aprendizado de máquina . . . . .	12
2.8	Aprendizado de máquina simbólico . . . . .	13
<b>3</b>	<b>Proposta e experimentos</b>	<b>17</b>
3.1	Metodologia adotada . . . . .	17
3.1.1	Roteiro . . . . .	18
3.2	Equipamento . . . . .	18
<b>4</b>	<b>Resultados</b>	<b>20</b>
4.1	Obstáculos na coleta de dados fisiológicos . . . . .	20
4.2	Correções pré-treinamento . . . . .	21
4.3	Treino do aprendizado de máquina . . . . .	22

4.3.1	Resultados descartados . . . . .	22
4.3.2	Inconstância na frequência das aferições de previsão e medida de sintomas . . . . .	23
4.4	Análise de Resultados . . . . .	23
4.4.1	Resultados Gerais . . . . .	23
4.4.2	Resultados Parciais - Simulador de Vôo . . . . .	27
4.4.3	Resultados Parciais - Jogo de Corrida . . . . .	29
<b>5</b>	<b>Conclusão</b>	<b>31</b>
5.1	Trabalhos futuros . . . . .	31
	<b>Referências</b>	<b>34</b>
	<b>Anexo</b>	<b>38</b>
<b>I</b>	<b>Virtual Reality Sickenss Questionnaire - VRSQ</b>	<b>39</b>
<b>II</b>	<b>Cybersikenss Profile Questionnaire - CSPQ</b>	<b>40</b>



# Lista de Figuras

2.1	Modelos populares de HMDs. . . . .	4
2.2	Técnica Redução do campo de visão. . . . .	7
2.3	Desfoque de movimento acionado por rotação. . . . .	8
2.4	Nariz Virtual em um Simulador. . . . .	9
2.5	Metodologia original de Porcino. . . . .	15
2.6	Jogos disponíveis do software. . . . .	16
2.7	Diagrama das atividades dos voluntários no experimento. . . . .	16
3.1	HTC Vive, HMD usado nos experimentos. . . . .	19
3.2	Empatica E4 Wristband. . . . .	19
4.1	Falta de consistência da medida dos batimentos cardíacos. . . . .	20
4.2	Correção necessária na formação dos valores gerados nos experimentos. . . . .	21
4.3	Correção necessária na formação das sessões do VRSQ gerados nos experimentos. . . . .	21
4.4	Comparação entre o desconforto medido no software de simulação e a previsão gerada pelo código de aprendizado de máquina ao longo do tempo da experiência, em segundos, do usuário 1. . . . .	22
4.5	Medida da resposta galvânica da pele do usuário 18 em estado de repouso. . . . .	23
4.6	Medida da resposta galvânica da pele do usuário 18 durante o experimento. . . . .	23
4.7	Comparação entre o desconforto medido no software de simulação e a previsão gerada pelo código de aprendizado de máquina ao longo do tempo da experiência, em segundos, do usuário 11. . . . .	24
4.8	Comparação entre o desconforto medido no software de simulação e a previsão gerada pelo código de aprendizado de máquina ao longo do tempo da experiência, em segundos, do usuário 10. . . . .	24
4.9	Comparação entre o desconforto medido no software de simulação e a previsão gerada pelo código de aprendizado de máquina ao longo do tempo da experiência, em segundos, do usuário 9. . . . .	25

5.1 Interrupção do software E4 connect. . . . . 33

# Lista de Tabelas

4.1	Tabela comparativa de resultados. . . . .	25
4.2	Tabela comparativa dos resultados do simulador de vôo. . . . .	27
4.3	Tabela comparativa de resultados do jogo de corrida. . . . .	29
I.1	Adaptação do VRSQ para português [5]. . . . .	39
II.1	Adaptação do CSPQ para português [6]. . . . .	40

# Lista de Abreviaturas e Siglas

**AV** Ambiente Virtual.

**BVP** Pulso de Volume Sanguíneo.

**CNN** Redes Neurais Convolucionais.

**CSPQ** CyberSickness Profile Questionnaire.

**ECG** Eletrocardiograma.

**EDA** Atividade Eletrodérmica.

**EEG** Eletroencefalograma.

**EGG** Eletrogastrografia.

**GSR** Resposta Galvânica da Pele.

**HMD** Head Mounted Display.

**HRV** Variabilidade do Batimento Cardíaco.

**LSTM** Memória de Curto Prazo Longa.

**MSSQ** Motion Sickness Susceptibility Questionnaire.

**PPG** Fotopletismografia.

**RNN** Redes Neurais Recorrentes.

**RV** Realidade Virtual.

**SCL** Nível de Condutância da Pele.

**SCR** Resposta de Condutância da Pele.

**SSQ** Simulator Sickness Questionnaire.

**VIMS** Visually Induced Motion Sickness.

**VRSQ** Virtual Reality Sickness Questionnaire.

# Capítulo 1

## Introdução

A Realidade Virtual (RV) vem cada vez mais sendo adotada por diversas áreas distintas, jogos digitais, construção civil, educação, treinamento profissional, reabilitação de pacientes, dentre outras [1]. Ainda assim, ainda há dificuldades na popularização dessa tecnologia. Seja seu custo, a não disponibilidade em diferentes regiões do mundo, as sensações de enjôo e mal-estar que alguns usuários sofrem ao utilizar tais equipamentos, muitos fatores ainda tornam essa tecnologia não tão acessível.

O conjunto de sintomas de mal-estar como dor de cabeça, tontura, enjoo, náusea, vertigem, dentre outros, quando manifestado no uso de equipamentos de RV, é conhecido como cybersickness [7] e é uma dessas dificuldades, se não a maior delas. Apesar de documentações extensas sobre sua origem, quantificar e qualificar suas nuances individuais ainda é um problema. Não se sabe ao certo quais os fatores que explicam o fato de usuários sentirem ou não o mal-estar. Em adição, o quantificador de cybersickness mais utilizado em pesquisas é o Simulator Sickness Questionnaire (SSQ) [8], constantemente condenado pela sua parcialidade, uma vez que é totalmente baseado na avaliação subjetiva da pessoa que o responde, e pela sua impraticabilidade em realidade virtual [9], visto que possui muitas perguntas não relacionadas diretamente ao uso da tecnologia de RV.

Porcino et al. [2] fez o uso de aprendizado de máquina para identificar e prever manifestações da cybersickness em jogos de realidade virtual e ainda qualificar os sintomas e causas com base no tempo de uso e no perfil de cada usuário.

### 1.1 Objetivos

Este trabalho visa investigar a relação entre os dados fisiológicos e a identificação e predição dos sintomas da cybersickness geradas pelo aprendizado de máquina criado na pesquisa de Porcino et al. [2], que não faz o uso de nenhum dado fisiológico. Essa relação

será investigada por meio da apuração da atividade cardíaca e da atividade eletrodérmica de voluntários em experimentos.

## 1.2 Estruturação

O restante deste trabalho está organizado da seguinte forma:

- **Capítulo 2 - Fundamentação Teórica:** explicita os conceitos necessários para a compreensão total do trabalho;
- **Capítulo 3 - Proposta e Experimentos:** detalha a proposta e as direções tomadas ao decorrer da pesquisa;
- **Capítulo 4 - Resultados:** apresentação e análise dos resultados obtidos no experimento;
- **Capítulo 5 - Conclusão:** considerações finais e sugestões para pesquisas futuras.
- **Anexo I - Formulário VRSQ:** adaptação do Virtual Reality Sickness Questionnaire para português.
- **Anexo II - Formulário CSPQ:** adaptação do CyberSickness Profile Questionnaire para português.

# Capítulo 2

## Fundamentação Teórica

Este capítulo apresentará conceitos fundamentais no âmbito deste trabalho. Serão abordados conceitos como Realidade Virtual (RV), *Head Mounted Display* (HMD), Atividade Eletrodérmica (EDA), as diferentes doenças relacionadas e seus meios de apuração.

### 2.1 Realidade Virtual

A Realidade Virtual (RV) é uma simulação criada com gráficos computadorizados para a confecção de um mundo virtual similar ao mundo real, no qual devem estar presentes três elementos: imersão, interatividade e presença. A imersão é definida como a sensação de estar cercado por uma outra realidade; interatividade é a capacidade que o usuário tem de influenciar a realidade simulada; e presença é a percepção de se estar em um local diferente do qual se encontra no mundo real [10].

Slater et al. [11] definem a imersão como uma descrição quantificável de tecnologia, ou seja, uma tecnologia é imersiva quando ela é extensiva, circundante, inclusiva, vívida e casada. Ela é extensiva quando estimula vários sentidos; circundante quando os estímulos vêm de todas as direções e o usuário tem liberdade para interagir com seus arredores; inclusiva quando o usuário está incluído no Ambiente Virtual e desconectado do real e vivida quando o estímulo sensorial é rico e detalhado.

Outros autores também definem Realidade Virtual como um mundo tridimensional imersivo e interativo simulado em um sistema digital [12]. Uma definição para o entendimento de RV é a de Ambiente Virtual, e é tão importante que alguns autores não diferenciam Realidade Virtual de Ambiente Virtual [13]. O Ambiente Virtual pode ser definido como um ambiente 3D gerado por computador, interativo, no qual uma pessoa é imersa [14] ou como um ambiente sintético no qual um usuário consegue interagir com objetos e explorá-lo como um ambiente real [12].



## 2.2 *Head Mounted Display*

O conceito de *Head Mounted Display* (HMD) surgiu em 1990, com um equipamento para ser usado como um capacete que posiciona duas telas a frente aos olhos do usuário, uma para cada olho, e tenta preencher o máximo de seu campo de visão [10]. O HMD simula a visão humana dentro do Ambiente Virtual ao fornecer imagens diferentes para cada olho com base na distância existente entre eles. Com isso, é criada uma percepção natural de profundidade do ambiente exibido, tornando assim, mais plausível a imersão do usuário frente ao ambiente simulado.

Com o passar dos anos, a tecnologia do HMD se tornou cada vez mais acessível e, atualmente, é o meio mais comum no campo de realidade virtual. A Figura 2.1 contém alguns modelos populares de HMD. Sua aplicação vai para além do entretenimento, sendo utilizado comercialmente na melhoria da experiência de clientes, em prototipagens em 3D, em melhorias nas metodologias de ensino e treinamento de diversas áreas (atividades de alta precisão, como cirurgias na área de saúde, e atividades de alto risco, como as esportivas e as militares) [15].



Figura 2.1: Modelos populares de HMDs (Fonte: [1]).

## 2.3 Tipos de desconforto em RV

Há quatro formas de desconforto associadas à Realidade Virtual: Motion Sickness, Visually Induced Motion Sickness (VIMS), Simulator Sickness e Cybersickness. Todas muito

semelhantes entre si e, muitas vezes, casos específicos específicos umas das outras.

Motion Sickness, também conhecida como cinetose, ou ainda enjôo de movimento, é uma doença causada pela divergência de informações emitidas pelo sistema sensorial humano. Acontece quando há conflitos entre os órgãos sensores que definem a orientação e posição espacial de um indivíduo. Sua manifestação é definida como o desconforto (dor de cabeça, tontura, enjoo, náusea, vertigem, dentre outros) sentido na presença de um movimento visual forçado, ou seja, sem que haja o movimento do indivíduo, isso acontece por exemplo, durante uma viagem de avião, barco ou carro [16], [17], [18], o viajante não está se deslocando, mas está dentro de um veículo que se desloca e vê esse deslocamento sem senti-lo necessariamente com seus outros sentidos, causando assim o conflito entre os órgão sensores.

Visually Induced Motion Sickness (VIMS), ou ainda enjôo de movimento induzido visualmente, é a manifestação da motion sickness em ambientes virtuais. Merhi et al. [19] definiu o evento de VIMS como uma doença de jogo (gaming sickness) durante experimentos com videogames.

A Simulator Sickness é definida como a manifestação da VIMS em simuladores, por exemplo um simulador de corrida, um simulador vôo [20] ou mesmo alguma simulação médica ou militar.

Por fim, a Cybersickness é o fenômeno da VIMS manifestado em ambientes de realidade virtual [7]. Suas causas podem ser categorizadas em hardware, software e usuário. Hardware inclui resolução e tamanho da tela, monitores, etc. Software se refere à aplicação em si, como a velocidade de movimento do personagem, gráficos e interface com o usuário. A terceira categoria diz respeito a fatores individuais: idade, sexo, experiência com realidade virtual, entre outros [21]. Muitas dessas causas já possuem estratégias para minimizar a manifestação da doença [22].

## 2.4 Causas da cybersickness

Dentro da literatura atual, são encontradas diversas teorias das causas de cybersickness amplamente utilizadas em estudos [22].

A Teoria Evolutiva ou do Envenenamento é uma reação natural do organismo quando os sentidos humanos entram em conflito. Nessa situação, o corpo do indivíduo entende que está em estado de envenenamento e provoca vômitos na tentativa de expelir toxinas [22].

As cenas virtuais não necessariamente garantem a postura estável a qual o corpo de uma pessoa está acostumada, induzindo uma tentativa constante e inconsciente de se corrigir a postura atual e sem sucesso [22]. Esta é a chamada Teoria da Instabilidade Postural.

A Teoria do Conflito Sensorial é a teoria mais citada e mais aceita. Consiste no conflito causado quando o corpo recebe um sinal de um sentido, mas outro sentido recebe outro sinal diferente e inesperado, por exemplo, em um simulador de corrida em realidade virtual, os olhos recebem sinal de movimentação, mas os sistemas vestibulares não, induzindo assim o conflito sensorial [22].

O cérebro humano reconhece movimento de uma maneira específica. Normalmente, o plano de fundo é assumido como referência estática e o movimento é percebido em relação a ele. O que nem sempre é verdade em cenas virtuais, causando conflito na percepção cerebral ao não seguir o padrão [22]. Esta é a Teoria dos Quadros de Descanso ou Ponto Fixo.

A Teoria do Movimento Ocular se trata de quando uma imagem se move de uma forma inesperada pelo sistema visual humano, um caso comum em RV, os olhos humanos se movem de uma forma não natural na tentativa da retina estabilizar a imagem vista, gerando desconforto [22].

## 2.5 Técnicas de mitigação da cybersickness

Existem técnicas de software propostas para reduzir a cybersickness que consistem em funcionalidades implementadas tanto no Ambiente Virtual quanto na interface do HMD na tentativa de amenizar as causas da cybersickness de forma a interferir o mínimo possível na imersão. Entre as várias técnicas de mitigação que já foram propostas e testadas, a seguir são apresentadas algumas das principais técnicas mencionadas em uma grande diversidade de estudos.

### 2.5.1 Redução do campo de visão

A técnica de redução do campo de visão, ou Field of View (FOV), do HMD consiste no escurecimento gradual da tela a partir das extremidades em direção ao centro, de forma que o campo de visão diminui conforme mais próximo do centro o escurecimento chega. Alguns estudos [23], [24], [25], [26] conduziram experimentos com essa técnica e são consistentes no resultado de que ela tem sucesso em amenizar a Cybersickness e prolongar o tempo de permanência do usuário no Ambiente Virtual sem sentir mal estar, ao custo do sentimento de presença dele.

Um trabalho recente bastante citado foi o de Fernandes et al. [23], nesse trabalho, foi pesquisado se a redução dinâmica do campo de visão do usuário imerso em um VE é capaz de mitigar a Cybersickness. O experimento consistiu em um usuário sentado estacionário imerso na Realidade Virtual, com um HMD, e que explorava um AV de uma vila pela qual ele caminhava. O tamanho do círculo que representava o campo de visão dele, mostrado

na Figura 2.2, era modificado gradualmente conforme ele se movia. A velocidade dessa modificação era calculada com uma função de acordo com a velocidade angular da rotação do gamepad feita pelo participante e a velocidade de translação do personagem no AV. O estudo chega no resultado de que é possível reduzir o campo de visão de forma sutil o suficiente para que o usuário não perceba porém ainda assim reduzindo a sensação de cybersickness.



Figura 2.2: Técnica Redução do campo de visão (Fonte: [23]).

### 2.5.2 Desfoque de movimento

Desfoque de movimento, ou Motion Blur, pode ser descrito como um mecanismo que borra a imagem mostrada na tela durante movimentos rápidos da câmera. Estudos [26], [27] propõem a ideia de que movimentos irregulares e variáveis aumentam a intensidade do sentimento de cybersickness, então, para combatê-la, a imagem é borrada uniformemente durante movimentos súbitos.

Budhiraja et al. [27] realizaram um estudo recente que avalia o uso de um tipo específico de desfoque, o Rotation Blur, onde o efeito de embaçamento não é aplicado a todo tipo de movimento do usuário, e sim apenas aos movimentos de rotação da cabeça dele (Figura 2.3). No estudo, os participantes foram colocados em um jogo de tiro em primeira pessoa, um dia com o Rotation Blur ativado e outro dia com ele desativado, e com uso do SSQ, as pontuações de cybersickness foram calculados. Os resultados desse estudo mostram que a técnica do Rotational Blue não reduziu os sintomas de todos os participantes, porém, os participantes nos quais a técnica funcionou foram os que apresentaram sintomas mais intensos.

### 2.5.3 Ponto de referência estático

Surgiu com base na teoria do conflito sensorial com o sistema vestibular que, como a cybersickness seria um resultado da divergência entre o movimento visto pelo sistema




Figura 2.3: Desfoque de movimento acionado por rotação (Fonte: [27]).

visual e sentido pelo sistema vestibular. Para reduzi-la, um ponto ou área de referência no campo de visão do usuário que estivesse estático em relação a ele aliviaria esse conflito. Alguns objetos de referência já foram propostos em alguns estudos [26], [28] como um nariz virtual, exemplificado na Figura 2.4, um capacete ou a cabine de um veículo.

Estudo que experimentaram com o nariz virtual [29], [26] observaram que houve uma redução de intensidade e ocorrência de cybersickness nos voluntários. Porém, comparado com outras técnicas de mitigação, o nariz virtual se mostrou menos eficaz.

Buhler et al. [14] sugeriram que efeitos periféricos sutis, que não ficam no centro da tela do usuário e que não chamariam muita atenção, mas ainda assim funcionariam na redução da Cybersickness. Nesse estudo, apesar das pontuações totais indicarem uma leve redução do mal estar com os efeitos ativados, não houve uma diferença significativa na cybersickness entre o cenário com e sem os efeitos. Os autores concluem que apesar de não terem sido capazes de comprovar a eficácia dos efeitos como foram implementados nos experimentos, observaram que redução de fluxo ótico na visão periférica do usuário é promissora e deve ser investigada.

#### 2.5.4 Head Lock

A técnica do Head Lock consiste de um bloqueio no movimento de rotação da câmera dentro do AV, de forma que o usuário só consegue explorá-lo com movimentos translacionais. Porém, esse tipo de limitação torna a navegação bastante limitada e prejudica a imersão, por isso, uma implementação comum desse bloqueio é feita de forma que ele só esteja ativo enquanto o usuário está de olhos abertos, ao fechar os olhos, o movimento rotacional é desbloqueado. Dessa forma, o usuário não vê enquanto a rotação está sendo feita, ou seja, durante o momento que mais induz à cybersickness.

Kemeny et al. [28] experimentaram com a técnica do Head Lock em HMD e observaram uma melhora significativa em ambas as tecnologias. Eles concluíram que o Head Lock tem




Figura 2.4: Nariz Virtual em um Simulador.

bastante sucesso em reduzir o fluxo ótico e que movimentos longitudinais não induzem tanto mal estar quanto movimentos rotacionais.

## 2.6 Meios de quantificação da cybersickness

Quantificar a cybersickness não é trivial. Há o problema de não existir só uma variável para nível de desconforto. Usuários de realidade virtual podem sentir múltiplos sintomas e efeitos ainda não descritos na literatura. Há também a dificuldade da considerável variação de susceptibilidade à cybersickness de cada usuário [22].

Alguns usuários são mais propensos a sofrer os sintomas de cybersickness do que outros. A literatura aponta várias maneiras de obtenção de dados para se quantificar sua manifestação. Tais dados podem ser classificados como subjetivos, biosinais (dados fisiológicos) e de perfil (biológico ou comportamental) [22].

### 2.6.1 Dados subjetivos

A coleta de dados subjetivos por meio de questionários é a forma mais difundida na apuração da manifestação da cybersickness. Há diversos questionários usados para tal.

O Motion Sickness Susceptibility Questionnaire (MSSQ) foi criado para medir o quão susceptível à motion sickness um indivíduo é e quais tipos de movimento causam desconforto a ele [30], [31]. Este questionário não foi criado voltado para realidade virtual, mas

já foi utilizado em estudos para tal [32] e também pode ser usado para determinar quanto tempo leva para um usuário de RV manifestar sintomas.

Proposto por Kennedy et. a [8], o Simulator Sickness Questionnaire (SSQ) foi criado como uma adaptação do MSSQ para simuladores e é o questionário mais utilizado na detecção de sintomas da manifestação da cybersickness em realidade virtual [33], [34].

Kim et al. [5] revisou e modificou o SSQ para atender melhor à realidade virtual, propondo o Virtual Reality Sickness Questionnaire (VRSQ). Sevinc concluiu que o SSQ não é adequado para aplicações em RV [9] e estudos recentes [35], [2] já têm aderido ao VRSQ. Uma versão adaptada para português pode ser encontrada no Anexo I.

Assim como o VRSQ, O cybersickness questionnaire é um questionário variante do SSQ voltado para atender melhor À realidade virtual, também foi validado por Sevinc [9].

## 2.6.2 Dados fisiológicos

São chamados dados fisiológicos as medições das reações fisiológicas do corpo humano quando na presença de determinados estímulos. Nas pesquisas envolvendo Cybersickness, os dados fisiológicos vêm sendo explorados como uma alternativa para se obter medidas objetivas da junto com os dados posicionais [36].

### Eleetroencefalograma

Eleetroencefalograma (EEG) é uma medição das ondas cerebrais produzidas espontaneamente ou durante atividades mentais. Ela mede a quantidade de ativações elétricas e a amplitude da atividade do cérebro através de certas localizações do couro cabeludo do indivíduo [37]. É importante sanitizar os dados coletados na utilização do EEG, pois há muita atividade cerebral que pode não ser alvo do estudo sendo realizado, como sinais correspondentes a movimentos involuntários de alguns músculos.

Celikcan [38] tentou utilizar o EEG para detectar e mitigar os sintomas de cybersickness, mas, dado que os voluntários estavam sendo expostos a um ambiente muito conturbado, os sinais foram muito amortecidos, e por isso, não foi possível tirar muitas conclusões sobre sua correlação com a Cybersickness.

Outros estudos que utilizam esse sinal mostram que ele pode ser usado, para medir o estado emocional do usuário, como no trabalho de Amores et al. [39] que, a partir de sinais do EEG, apresentou um método de calcular uma pontuação de estresse para avaliar os efeitos de um Ambiente Virtual e de estímulos olfativos na redução da sensação subjetiva do estresse.

## **Eletrocardiograma**

Normalmente medido em batidas por minuto, o Eletrocardiograma (ECG) é uma medida da frequência dos batimentos cardíacos de uma pessoa. Podem ser retirados de seus resultados as amplitudes máximas, fatores de frequências baixas e altas, variabilidade da Variabilidade do Batimento Cardíaco (HRV), entre outros, para análise.

Em 2019, Garcia-Agundez et al. [40] realizaram um estudo que avalia a possibilidade de detectar-se a Cybersickness utilizando somente sinais de ECG e propõe um equipamento simples e barato para extração da média e do desvio padrão da média do intervalo entre batimentos cardíacos, average duration of N-N intervals (AVGNN) e standard deviation of N-N intervals (STDNN). O estudo reportou que houve uma mudança significativa nessas medições quando o usuário sofria com cybersickness, que há uma correlação entre esses parâmetros e algumas pontuações do SSQ e que, talvez, seja possível desenvolver um aparato simples que detecte cybersickness baseado nesses sinais fisiológicos.

## **Eletrogastrografia**

Eletrogastrografia (EGG) é um método não invasivo de medição da atividade mioelétrica gástrica. Essa medição é feita com o uso de eletrodos colocados externamente na pele do abdome do paciente. Como é muito sensível a interferências elétricas vindas de outros órgãos na região e se faz necessário muita precisão na preparação e medição [41]. Um estudo que avaliou as mudanças de diversos tipos de sinais [42] biológicos durante a interação em um ambiente de Realidade Virtual observou que uma das respostas fisiológicas com melhores correlações com as pontuações calculadas pelo SSQ foi a taquiarritmia gástrica, uma resposta associada a um aumento da ativação do sistema parassimpático que ocorre quando náusea é induzida.

## **Atividade Eletrodérmica**

A Atividade Eletrodérmica (EDA), ou Resposta Galvânica da Pele (GSR), é uma medida da condutividade elétrica da pele que associa a produção de suor pelas glândulas écrinas com o grau de excitação psicológica de um indivíduo quando exposto a um estímulo psicológico pontual ou constante, ou seja, é uma medida que permite perceber variações na excitação de um indivíduo ao longo do tempo, mas não classificá-la como boa ou ruim. Estar estressado ou ficar animado, por exemplo, poderiam demonstrar um valor de condutância na pele muito próximo, mas seria impossível dizer, pelo seu valor, se o indivíduo estava animado ou estressado. A condutividade da pele é uma função da atividade das glândulas sudoríparas, que são controladas pelo sistema nervoso simpático,



pois conforme suor é produzido, a capacidade da pele de conduzir eletricidade aumenta. Essas glândulas são ativadas como uma resposta involuntária ao estresse e à ansiedade.

Os sinais da EDA podem ser divididos em dois componentes principais. Um tônico, referente a medida do Nível de Condutância da Pele, ou ainda Skin Conductance Level (SCL), que consiste em mudanças de sinal de forma lenta e constante; e outro fásico, que representa mudanças rápidas e pontuais nas medidas dos dados captados e corresponde à Resposta de Condutância da Pele, ou ainda Skin Conductance Response (SCR) [43].

Os sensores que mensuram a EDA são, em geral, pouco intrusivos, de baixo custo e geram dados de fácil interpretação, devido à sua relação quase direta com excitação [43]. Entretanto, é preciso garantir que os sinais da EDA sejam captados em um ambiente controlado, uma vez que a temperatura e a umidade do espaço de captação dos dados podem interferir com a atividade das glândulas écrinas, gerando ruído.

A EDA já foi utilizada em estudos como o de Kim et al. [44] que desenvolveram um sistema de detecção e mitigação de Cybersickness utilizando o sensor EDA em conjunto com diversos outros sensores como entrada para uma inteligência artificial obtendo resultados positivos em sua aplicação.

### 2.6.3 Dados de perfil

#### Cybersickness Profile Questionnaire

A literatura aponta diversas causas da cybersickness intrinsecamente atreladas ao indivíduo [22]. Porcino [6] propôs o CyberSickness Profile Questionnaire (CSPQ) tornando possível uma melhor identificação das causas a depender de cada usuário. Uma versão adaptada para português pode ser encontrada no Anexo II.

## 2.7 Aprendizado de máquina

Aprendizado de máquina é um subcampo da Engenharia e da Ciência da Computação que evoluiu do estudo de reconhecimento de padrões e da teoria do aprendizado computacional em inteligência artificial. Esse campo explora o estudo e construção de algoritmos que podem aprender de seus erros e fazer previsões sobre dados. Tais algoritmos operam construindo um modelo a partir de inputs amostrais a fim de fazer previsões ou decisões guiadas pelos dados ao invés de simplesmente seguindo inflexíveis e estáticas instruções programadas.

Diversos estudos usam modelos de deep learning como Redes Neurais Convolucionais (CNN) e Redes Neurais Recorrentes (RNN) para prever manifestações de cybersickness. Kim, J. et al. [45], propôs uma arquitetura de deep learning para estimar o estado cogni-

tivo usando sinais cerebrais e para investigar sua relação com os níveis da cybersickness. Esse estudo é baseado no modelo de deep learning, como Memória de Curto Prazo Longa (LSTM), CNN e RNN [46], [47], [48]. Os algoritmos aprendem as características individuais dos participantes que levam à manifestações dos sintomas da cybersickness quando assistindo o vídeo em RV.

Jin et al. [49] agrupou as causas da cybersickness da seguinte forma: características intrínsecas ao hardware (configurações e recursos dos dispositivos de RV), características de software (conteúdo nas aplicações em RV) e características baseadas em usuários individuais. Os autores usaram classificadores para estimar níveis de desconforto. Um total de três algoritmos de aprendizado de máquina foram usados: CNN, RNN e LSTM-RNN. Segundo os autores, o LSTM-RNN obteve os melhores resultados.

Jeong et al. [50] fez o uso de aplicações de vídeo 360° em RV ao analisar cenários de cybersickness usando sinais cerebrais de 24 usuários. Seu objetivo foi identificar características comuns ao cérebro ao assistir vídeos 360° associados à manifestação da cybersickness. Segmentos de vídeo foram examinados e destacados nos momentos em que os usuários sentiram desconforto, mas os autores não chegaram a encontrar causas específicas e individuais da manifestação da cybersickness.

Garcia-Agundez et al. [51] focou na classificação dos níveis de cybersickness propondo um modelo que usa a combinação de biosinais e configurações de jogo. A respiração e a condutividade da pele de 66 participantes foi coletada e os autores obtiveram uma acurácia na classificação de 82% por máquina de vetores de suporte em classificações binárias e 56% por k-Nearest Neighbors em classificações ternárias.

Porcino et al. [52] propôs uma abordagem que é passível a predição da manifestação dos sintomas em tempo real. Os autores conseguiram atingir uma acurácia média de 96.54% com o uso de floresta aleatória (random forest) considerando um total de 16 algoritmos de aprendizado de máquina diferentes e em diferentes cenários além de identificar os atributos responsáveis pelos estados de desconforto em RV em jogos.

## 2.8 Aprendizado de máquina simbólico

Neste paradigma, um conceito é representado em uma estrutura simbólica e o aprendizado é realizado através da apresentação de exemplos e contraexemplos deste conceito. As estruturas simbólicas estão tipicamente representadas em alguma expressão lógica, como por exemplo: regras de produção.

Um exemplo clássico do aprendizado de máquina simbólico é o identificador de felinos e caninos em imagens. O treinamento é feito usando-se imagens de gatos e de cachorros como inputs indicando-se quando são felinos e quando são caninos. Dessa forma, após o

treinamento ser completado, se a imagem de um leopardo for usada com input, o aprendizado de máquina o classificará como felino, visto suas características, como formato do focinho e das orelhas e os bigodes, semelhantes a dos gatos, que foram inputs anteriores usados no treinamento. Se a imagem de um lobo for introduzida como input, será classificado como um canino, novamente, pela sua semelhança com inputs anteriores de treinamento, no caso, imagens de cachorros. Agora, se a imagem de um jacaré for usada como input, não será classificado nem como felino nem como canino devido a sua falta de semelhança com qualquer um dos inputs usados no treinamento.

Porcino utilizou uma abordagem [2] [52] [6] que consiste no uso do aprendizado de máquina simbólico para análise e identificação de uma ou mais causas de desconforto, que é específico a contexto e usuário. Em outras palavras, é uma abordagem para reconhecimento da presença de desconforto não genérica, anteriormente não abordada na literatura. Em contraste, ela permite avaliar e estimar causas da cybersickness em tempo real e sensível a contexto e usuário.

Em seus experimentos, Porcino calculou a pontuação do VRSQ como sendo a diferença absoluta entre os questionários pré e pós jogo. Para validar os dados de cada participante, os resultados do VRSQ foram comparados com a resposta verbal de cada usuário da seguinte forma: se o voluntário obteve uma pontuação positiva no VRSQ (significando a presença do desconforto), mas reportou não sentir desconforto de forma verbal (significando a ausência do desconforto), os dados deste participante eram considerados inválidos e descartados da análise no aprendizado de máquina. Devido a isso e ao fato de que os participantes poderiam optar por deixar a experiência a qualquer momento, seja por se sentirem mal ou qualquer outro motivo, o que invalidaria esses dados como inputs no treinamento devido a limitações no aprendizado de máquina, apenas 35 dos 86 voluntários foram considerados como dados válidos. É importante ressaltar, também, que cada participante foi contabilizado apenas uma vez independente do jogo escolhido, ou seja, voluntários que participaram no jogo de corrida, não foram contabilizados no de vôo e vice-versa. Após a validação de todos os dados de usuários gerados na simulação, este conjunto de dados é introduzido como entrada no código de aprendizado de máquina [4] para a identificação e classificação dos sintomas relacionados à cybersickness [2] [52] [6]. Este código não será detalhado neste trabalho, uma vez que avaliar sua arquitetura não é um dos objetivos dessa pesquisa. A Figura 2.5 ilustra esta metodologia.

O software de simulação criado por Porcino [6] [2] [52] consiste no conjunto de dois jogos, um de vôo e um de corrida, Figura 2.6. Cada um explora teorias de causas da cybersickness diferentes, por exemplo, os usuários controlam a aceleração no jogo de corrida, mas não no de vôo na tentativa de investigar a teoria de que a aceleração está diretamente relacionada com a manifestação dos sintomas. Em ambos, os participantes

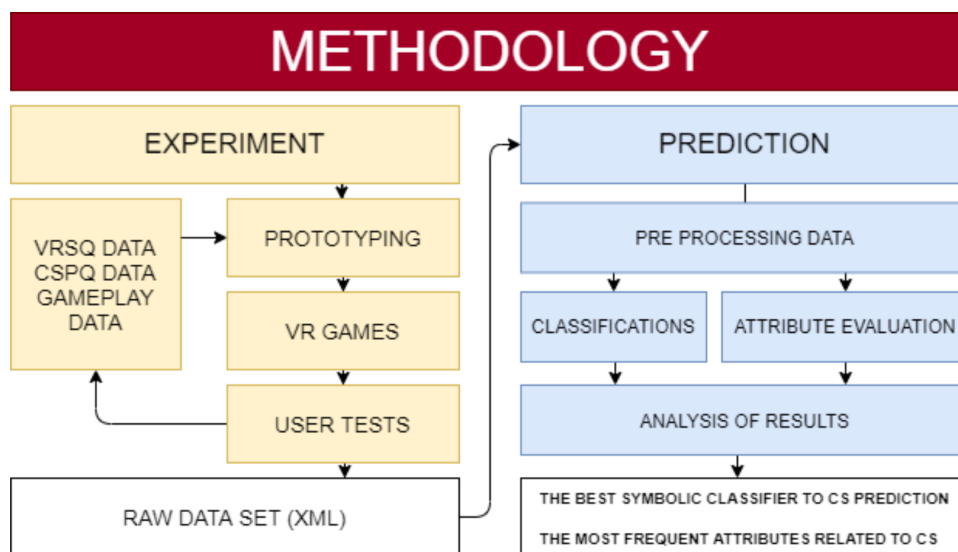


Figura 2.5: Metodologia original de Porcino (Fonte: [52]).

primeiro preenchem o CSPQ uma única vez e duas vezes o VRSQ, uma antes e outra depois da experiência, como mostrado na Figura 2.7. Ao final de cada sessão, o software exporta os dados coletados nos questionários e da sessão de jogo em um formato que o algoritmo de aprendizado de máquina possa interpretar. Na plataforma GitHub, estão disponíveis abertamente tanto o software com os jogos [3] como o código de aprendizado de máquina [4].

Porcino fez experimentos em 6 diferentes ocasiões (P1, P2, P3, P4, P5 E P6) ao longo de meses e cada ocasião era encerrada assim que um problema era percebido para a concepção uma versão aprimorada do experimento:

- P1: apenas com o jogo de corrida tendo duração de 5 minutos e a jogabilidade do usuário era gravada a cada segundo;
- P2: o jogo de vôlei foi introduzido e os usuários poderiam escolher livremente entre ele o jogo de corrida. O SSQ foi adicionado à experiência e a jogabilidade de cada usuário parou de ser gravada a cada segundo a fim de reduzir a queda na taxa de quadros dos experimentos;
- P3: o relato verbal de desconforto de cada usuário passou a ser coletado;
- P4: o simulador foi levado à público no evento Symposium on Virtual and Augmented Reality (SVR) e aqui foi colocado o VRSQ antes e após cada jogo;
- P5; foram usados dois HMDs diferentes nessa ocasião, Oculus Rift CV1 and HTC Vive;

- P6: nessa ocasião, foram conduzidos experimentos de 20 minutos cada para avaliar longas exposições a RV.




Figura 2.6: Jogos disponíveis do software (Fonte: [52]).

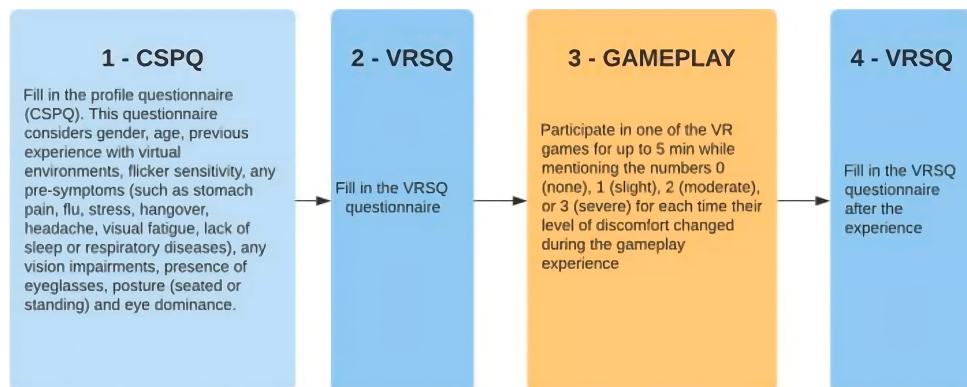


Figura 2.7: Diagrama das atividades dos voluntários no experimento (Fonte: [2]).

# Capítulo 3

## Proposta e experimentos

Este trabalho visa investigar a relação entre os dados fisiológicos e a identificação e predição dos sintomas da cybersickness geradas pelo aprendizado de máquina criado na pesquisa de Porcino et al. [2]. Para isso, foram conduzidos experimentos em realidade virtual no Departamento de Ciência da Computação, seguindo uma metodologia muito próxima à descrita por Porcino [2] com a adição da apuração da atividade cardíaca e da atividade eletrodérmica dos voluntários nos experimentos.

O uso de dados fisiológicos é uma adição relevante ao experimento por proporcionar informações não subjetivas dos usuários, principal problema abordado no uso de questionários [22], e já utilizado em pesquisas e quantificação e mitigação da cybersickness [44].

Neste capítulo, será abordada toda a metodologia usada nos experimentos e, também, todas as alterações feitas em relação ao trabalho de Porcino [2] [52] e necessárias para a adição dos dados fisiológicos, bem como todos os equipamentos utilizados nos experimentos.

### 3.1 Metodologia adotada

O código de aprendizado de máquina de Porcino [4] foi criado usando-se Jupyter Notebook em ambiente Anaconda local. Neste trabalho, foi desejada a mudança desse código para o Google Colab, que é em nuvem, e, para tal, foi necessária uma adaptação para sua utilização visto a necessidade de diferentes importações de biblioteca de códigos devido à diferença entre as versões da linguagem de programação Python usada no ambiente Anaconda e no ambiente do Google Colab. Esta adaptação também está disponível abertamente na plataforma Github e contém todos os dados analisados [53].

### 3.1.1 Roteiro

O roteiro utilizado neste trabalho foi, de forma geral, muito próximo à abordagem na ocasião P5 de Porcino, citada no Capítulo 2, exceto pelas aquisições de dados fisiológicos. Antes do preenchimento do CSPQ, cada voluntário teve seu batimento cardíaco e sua atividade eletrodérmica medidos por 3 minutos em estado de repouso para adquirir-se uma linha de referência específica a usuário. Após isso, o jogador respondeu tanto o CSPQ quanto o primeiro VRSQ e então seu batimento cardíaco e sua atividade eletrodérmica foram medidos novamente durante os 5 minutos da experiência. É importante ressaltar que aqui foi usada a versão do software com experiências de 5 minutos, pois esta foi a disponibilizada na plataforma Github mencionada no Capítulo 2. Encerrado o período da experiência, o voluntário preencheu o segundo VRSQ. As medidas dos dados foram feitas de acordo com o guia oficial da Empatica E4 [54].

Diferentemente da metodologia original, os dados considerados inválidos foram considerados apenas aqueles em que voluntários pediram para encerrar a experiência antes do término dos 5 minutos, o que invalidaria esses dados como inputs no treinamento devido a limitações no aprendizado de máquina. Uma vez que o objetivo deste trabalho é minimizar o uso de dados subjetivos na identificação e predição dos sintomas da cybersickness, o relatório verbal de desconforto do usuário foi substituído pela análise dos dados fisiológicos coletados. Outra diferença é que, apesar do CSPQ ter uma pergunta em relação à postura de jogo (em pé ou sentado), 100% dos participantes optaram por jogarem sentados.

## 3.2 Equipamento

Os experimentos fizeram uso dos seguintes equipamentos:

- Um computador capaz de rodar aplicações em Realidade Virtual;
- HMD HTC da Vive (Figura 3.1);
- Empatica E4 Wristband (Figura 3.2).

### Empatica E4 Wristband

A pulseira Empatica E4 Wristband, Figura 3.2 é um dispositivo vestível que oferece aquisição de dados fisiológicos em tempo real e ferramentas para análise e visualização destes a partir de sensores de condutância elétrica; temperatura por meio de um termopilha infravermelho; acelerômetro de 3 eixos; sensor de Fotopletismografia (PPG), que mede o Pulso de Volume Sanguíneo (BVP), do qual a Variabilidade do Batimento Cardíaco (HRV)

pode ser derivada. Este dispositivo foi escolhido em contraste com as outras formas de apuração de dados fisiológicos citados no Capítulo 2 por ser um equipamento já utilizado em outros trabalhos no Departamento de Ciência da Computação da Universidade de Brasília [1] [21].



Figura 3.1: HTC Vive, HMD usado nos experimentos.



Figura 3.2: Empatica E4 Wristband (Fonte: [55]).



# Capítulo 4

## Resultados

Neste capítulo, serão apresentadas as análises exploratórias a partir dos dados obtidos nos experimentos descritos no Capítulo 3 bem como as adaptações e correções necessárias para a análise dos mesmos.

### 4.1 Obstáculos na coleta de dados fisiológicos

Originalmente, este trabalho tinha o objetivo de utilizar o batimento cardíaco dos voluntários como um dado fisiológico a ser analisado, mas, devido à falta de consistência na mensuração desse dado por parte da pulseira Empatica E4 Wristband em vários usuários, exemplo mostrado na Figura 4.1, esse dado não foi utilizado para análise.


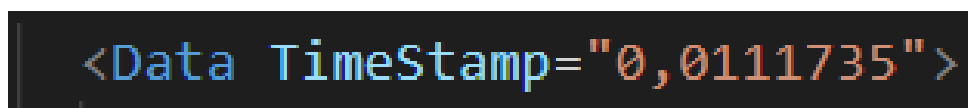


Figura 4.1: Falta de consistência da medida dos batimentos cardíacos.

## 4.2 Correções pré-treinamento

Os dados gerados pelo software de Porcino [6] [2] [52] precisaram de três correções antes de servirem de entrada para o código de aprendizado de máquina: a formatação de valores gerados pelo simulador; a formatação das sessões do VRSQ pelo simulador e a duplicação das respostas do VRSQ nas sessões de alguns usuários.

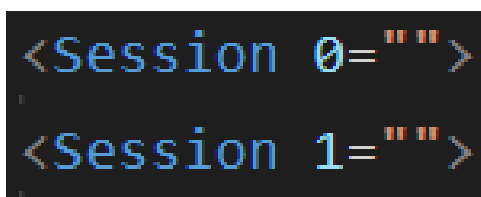
Os valores reais foram gerados no padrão brasileiro, 1,4059 por exemplo, mas o código de aprendizado de máquina espera entradas no formato estado-unidense, 1.4059 por exemplo. A Figura 4.2 contém um exemplo da geração original.



```
<Data TimeStamp='0,0111735'>
```

Figura 4.2: Correção necessária na formação dos valores gerados nos experimentos.

As sessões de resposta do VRSQ também precisaram de correção em sua formatação. Como ilustrado na Figura 4.3, Os dados foram gerados com *Session 0* e *Session 1*, mas o código de aprendizado de máquina espera entradas com formato *Session A* e *Session B*



```
<Session 0=' '>
<Session 1=' '>
```

Figura 4.3: Correção necessária na formação das sessões do VRSQ gerados nos experimentos.

O motivo dos dados terem sido gerados nesse formato não foi investigado a fundo, mas acredita-se estar relacionado com o sistema operacional no qual foram gerados, Windows 10 e no formato UTF-8. Ambas correções foram facilmente realizadas utilizando-se a função *Localizar e Substituir* do editor Visual Code.

Houve dois casos em que foram geradas mais que duas sessões de respostas do VRSQ, sendo elas sempre duplicatas das verdadeiras sessões. Novamente, o motivo dessas duplicatas não foi investigado a fundo, mas acredita-se ter sido algum problema na conectividade do HMD com o computador durante os experimentos.

## 4.3 Treino do aprendizado de máquina

No total, foram coletados dados de forma anônima de 61 voluntários, dos quais 4 optaram por encerrar a experiência antes de seu término, totalizando 57 dados válidos para treinamento. Todos os dados considerados para análise podem ser encontrados na plataforma Github em [53].

### 4.3.1 Resultados descartados

Mesmo entre os dados considerados válidos para o treinamento, ou seja, dados de sessões cujos voluntários completaram toda a experiência, foram encontrados resultados inesperados ou nulos sem motivo aparente. Foi o caso de 11 usuários: o usuário 1 completou os 5 minutos da experiência, mas o software do simulador [3] apenas considerou pouco mais que os primeiros 40 segundos para realizar a previsão da manifestação dos sintomas, mostrado na Figura 4.4; o usuário 12 teve sua previsão e análise da influência de causas completamente nulas por parte do aprendizado de máquina; houve alguma falha na comunicação da pulseira Empatica E4 Wristband no usuário 38 e sua EDA em estado de repouso não foi gravada; os usuários 4, 6, 18, 24, 31, 34, 48 e 57 tiveram quedas súbitas nos valores de sua Atividade Eletrodérmica durante o experimento indicando falha na aferição por parte da pulseira Empatica E4 Wristband, podendo estar frouxa por exemplo, exemplos mostrados na Figura 4.5 e na Figura 4.6. Por consequência, os resultados destes 11 usuários gerados no simulador foram descartados como entrada no treinamento.

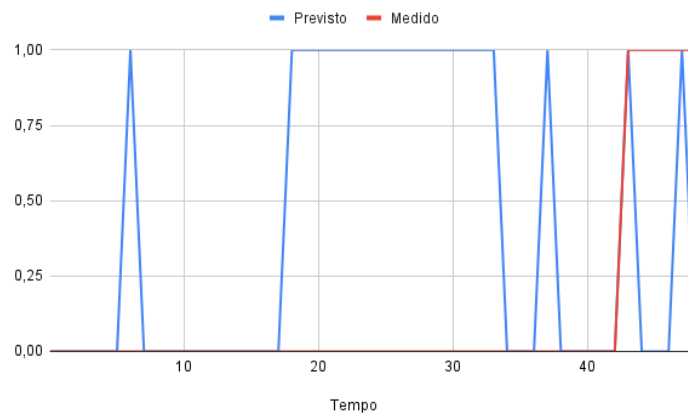


Figura 4.4: Comparação entre o desconforto medido no software de simulação e a previsão gerada pelo código de aprendizado de máquina ao longo do tempo da experiência, em segundos, do usuário 1.




Figura 4.5: Medida da resposta galvânica da pele do usuário 18 em estado de repouso.




Figura 4.6: Medida da resposta galvânica da pele do usuário 18 durante o experimento.

### 4.3.2 Inconstância na frequência das aferições de previsão e medida de sintomas

O software projetado por Porcino [3] apresentou variações na quantidade de aferições no momento de previsão e medida dos sintomas da cybersickness. Este problema não foi investigado a fundo, mas acredita-se que essas aferições estejam sendo realizadas de forma dependente da taxa de quadros da aplicação em realidade virtual.

## 4.4 Análise de Resultados

O simulador criado por Porcino [3] contém dois resultados quanto ao desconforto: O medido, calculado pelos questionários e dados de jogo de cada usuário, e o previsto, calculado com base no seu perfil pelo código de aprendizado de máquina. A seguir, estão presentes análises para todos os usuários, independente do jogo escolhido, e, logo após, é feita a separação dos resultados por jogo.

### 4.4.1 Resultados Gerais

A Tabela 4.1 contém a comparação dos resultados de todos os usuários. Seus resultados são ditos incoerentes quando os valores da Atividade Eletrodérmica da pele aparentam não ter relação com o desconforto medido ou com o desconforto previsto em pelo menos

50% do tempo e coerentes caso aparentem. A Figura 4.7 e a Figura 4.8 mostram exemplos de coerência e a Figura 4.9 mostra um de incoerência.




Figura 4.7: Comparação entre o desconforto medido no software de simulação e a previsão gerada pelo código de aprendizado de máquina ao longo do tempo da experiência, em segundos, do usuário 11.

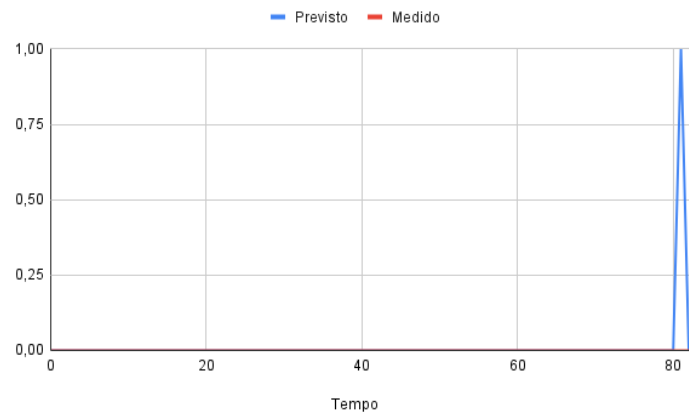


Figura 4.8: Comparação entre o desconforto medido no software de simulação e a previsão gerada pelo código de aprendizado de máquina ao longo do tempo da experiência, em segundos, do usuário 10.




Figura 4.9: Comparação entre o desconforto medido no software de simulação e a previsão gerada pelo código de aprendizado de máquina ao longo do tempo da experiência, em segundos, do usuário 9.

Tabela 4.1: Tabela comparativa de resultados.

Usuário	EDA	Desconforto medido	Desconforto previsto
1	Descartado	Descartado	Descartado
2	Sem variação	Incoerente	Coerente
3	Aumentou	Coerente	Coerente
4	Descartado	Descartado	Descartado
5	Aumentou	Coerente	Incoerente
6	Descartado	Descartado	Descartado
7	Aumentou	Coerente	Coerente
8	Aumentou	Incoerente	Coerente
9	Aumentou	Coerente	Incoerente
10	Aumentou	Incoerente	Incoerente
11	Aumentou	Coerente	Coerente
12	Descartado	Descartado	Descartado
13	Sem variação	Coerente	Incoerente
14	Sem variação	Coerente	Incoerente
15	Aumentou	Coerente	Coerente
16	Sem variação	Coerente	Incoerente
17	Sem variação	Coerente	Incoerente
18	Descartado	Descartado	Descartado
19	Aumentou	Coerente	Coerente

Continua na página seguinte

Tabela 4.1 – continuação da página anterior

Usuário	EDA	Desconforto medido	Desconforto previsto
20	Aumentou	Coerente	Coerente
21	Sem variação	Coerente	Incoerente
22	Sem variação	Coerente	Incoerente
23	Sem variação	Coerente	Incoerente
24	Descartado	Descartado	Descartado
25	Aumentou	Coerente	Coerente
26	Aumentou	Incoerente	Coerente
27	Aumentou	Incoerente	Coerente
28	Aumentou	Incoerente	Coerente
29	Aumentou	Coerente	Coerente
30	Aumentou	Incoerente	Coerente
31	Descartado	Descartado	Descartado
32	Sem variação	Incoerente	Incoerente
33	Sem variação	Incoerente	Incoerente
34	Descartado	Descartado	Descartado
35	Aumentou	Coerente	Coerente
36	Sem variação	Incoerente	Coerente
37	Sem variação	Incoerente	Incoerente
38	Descartado	Descartado	Descartado
39	Aumentou	Incoerente	Coerente
40	Aumentou	Coerente	Coerente
41	Aumentou	Coerente	Coerente
42	Aumentou	Incoerente	Coerente
43	Aumentou	Incoerente	Coerente
44	Aumentou	Coerente	Coerente
45	Aumentou	Coerente	Coerente
46	Aumentou	Coerente	Incoerente
47	Aumentou	Coerente	Coerente
48	Descartado	Descartado	Descartado
49	Aumentou	Incoerente	Coerente
50	Aumentou	Coerente	Coerente
51	Sem variação	Incoerente	Incoerente
52	Aumentou	Coerente	Coerente
53	Aumentou	Incoerente	Coerente

Continua na página seguinte

Tabela 4.1 – continuação da página anterior

Usuário	EDA	Desconforto medido	Desconforto previsto
54	Aumentou	Coerente	Coerente
55	Aumentou	Coerente	Incoerente
56	Aumentou	Coerente	Incoerente
57	Descartado	Descartado	Descartado

Ao total dos 46 resultados de medição da Atividade Eletrodérmica não descartados, 29 (63%) foram coerentes tanto com a identificação dos sintomas de cybersickness quanto com sua previsão, não necessariamente simultâneos e ambos gerados pelo código de aprendizado de máquina.

É importante ressaltar que o desconforto medido e o desconforto previsto nem sempre se espelharam. Em todos os 56 casos em que foram gerados, eles se assemelham em apenas 27 (48%) e, em nenhum voluntário, o desconforto previsto superou o valor 1, em uma escala de 0 a 3, o que mostra que ainda há espaço para melhorias no algoritmo de predição e identificação.

#### 4.4.2 Resultados Parciais - Simulador de Vôo

A Tabela 4.2 contém a comparação dos resultados dos usuários que optaram em jogar o simulador de vôo. Novamente, seus resultados são ditos incoerentes quando os valores da Atividade Eletrodérmica da pele aparentam não ter relação com o desconforto medido ou com o desconforto previsto em pelo menos 50% do tempo e coerentes caso aparentem.

Tabela 4.2: Tabela comparativa dos resultados do simulador de vôo.

Usuário	EDA	Desconforto medido	Desconforto previsto
1	Descartado	Descartado	Descartado
2	Sem variação	Incoerente	Coerente
3	Aumentou	Coerente	Coerente
4	Descartado	Descartado	Descartado
5	Aumentou	Coerente	Incoerente
6	Descartado	Descartado	Descartado
7	Aumentou	Coerente	Coerente

Continua na página seguinte



Tabela 4.2 – continuação da página anterior

Usuário	EDA	Desconforto medido	Desconforto previsto
8	Aumentou	Incoerente	Coerente
9	Aumentou	Coerente	Incoerente
10	Aumentou	Incoerente	Incoerente
11	Aumentou	Coerente	Coerente
12	Descartado	Descartado	Descartado
13	Sem variação	Coerente	Incoerente
14	Sem variação	Coerente	Incoerente
15	Aumentou	Coerente	Coerente
16	Sem variação	Coerente	Incoerente
17	Sem variação	Coerente	Incoerente
18	Descartado	Descartado	Descartado
19	Aumentou	Coerente	Coerente
20	Aumentou	Coerente	Coerente
21	Sem variação	Coerente	Incoerente
22	Sem variação	Coerente	Incoerente
23	Sem variação	Coerente	Incoerente
24	Descartado	Descartado	Descartado
25	Aumentou	Coerente	Coerente
26	Aumentou	Incoerente	Coerente
27	Aumentou	Incoerente	Coerente
28	Aumentou	Incoerente	Coerente
29	Aumentou	Coerente	Coerente
30	Aumentou	Incoerente	Coerente
31	Descartado	Descartado	Descartado
32	Sem variação	Incoerente	Incoerente
33	Sem variação	Incoerente	Incoerente
34	Descartado	Descartado	Descartado
35	Aumentou	Coerente	Coerente

Dos 35 usuários que optaram pelo simulador de vôo, 8 tiveram seus dados descartados, totalizando 27 dos quais 18 (67%) foram coerentes com a identificação dos sintomas de cybersickness e 15 (54%) com sua previsão.

### 4.4.3 Resultados Parciais - Jogo de Corrida

A Tabela 4.3 contém a comparação dos resultados dos usuários que optaram em jogar o jogo de corrida. Mais uma vez, seus resultados são ditos incoerentes quando os valores da Atividade Eletrodérmica da pele aparentam não ter relação com o desconforto medido ou com o desconforto previsto em pelo menos 50% do tempo e coerentes caso aparentem.

Tabela 4.3: Tabela comparativa de resultados do jogo de corrida.

Usuário	EDA	Desconforto medido	Desconforto previsto
1	Sem variação	Incoerente	Coerente
2	Sem variação	Incoerente	Incoerente
3	Descartado	Descartado	Descartado
4	Aumentou	Incoerente	Coerente
5	Aumentou	Coerente	Coerente
6	Aumentou	Coerente	Coerente
7	Aumentou	Incoerente	Coerente
8	Aumentou	Incoerente	Coerente
9	Aumentou	Coerente	Coerente
10	Aumentou	Coerente	Coerente
11	Aumentou	Coerente	Incoerente
12	Aumentou	Coerente	Coerente
13	Descartado	Descartado	Descartado
14	Aumentou	Incoerente	Coerente
15	Aumentou	Coerente	Coerente
16	Sem variação	Incoerente	Incoerente
17	Aumentou	Coerente	Coerente
18	Aumentou	Incoerente	Coerente
19	Aumentou	Coerente	Coerente
20	Aumentou	Coerente	Incoerente
21	Aumentou	Coerente	Incoerente
22	Descartado	Descartado	Descartado

Dos 22 usuários que optaram pelo jogo de corrida, 3 tiveram seus dados descartados, totalizando 19 dos quais 11 (58%) foram coerentes com a identificação dos sintomas de cybersickness e 14 (74%) com sua previsão.

Como os resultados indicam, o simulador de vôo mostrou uma coerência maior com o desconforto medido enquanto o jogo de corrida demonstrou uma coerência maior com o desconforto previsto.

O algoritmo de aprendizado de máquina de Porcino [2] não foi criado pensando-se no uso de dados fisiológicos e o trabalho aqui presente foi pioneiro em utilizar-se esse tipo de dado em sua implementação. Sendo validados em 63% dos casos tanto na identificação quanto na previsão. Mesmo analisando-se os jogos separadamente, os dados fisiológicos foram coerentes em mais de 50% dos casos tanto para a previsão quanto para a identificação dos sintomas da cybersickness, o que indica, por maioria simples, um resultado satisfatório no uso de sensores fisiológicos, mais especificamente o EDA, nesta pesquisa,

# Capítulo 5

## Conclusão

Este trabalho teve como objetivo minimizar o uso de dados subjetivos e validar a identificação e predição dos sintomas da cybersickness do aprendizado de máquina da pesquisa de Porcino et al. [2] fazendo-se o uso de sinais fisiológicos de voluntários em experimentos. Ao todo, 61 voluntários participaram dos experimentos, dos quais 57 foram considerados dados válidos para a entrada do código de aprendizado de máquina e 11 resultados foram descartados, totalizando 46 análises.

O uso de dados fisiológicos em conjunto com o aprendizado de máquina foi validado em 63% dos casos e, avaliando-se os jogos separadamente, em mais de 50% dos casos em ambas previsão e identificação. Uma vez que o algoritmo de aprendizado de máquina de Porcino [2] não foi criado pensando-se no uso de dados fisiológicos e o trabalho aqui presente foi pioneiro em utilizar esse tipo de dado em sua implementação, este resultado foi considerado satisfatório, por maioria simples, para o uso de sensores fisiológicos, mais especificamente o EDA.

É importante ressaltar a limitação deste trabalho de que os dados fisiológicos podem representar várias respostas do corpo humano, não só a manifestação de cybersickness e isso pode ser um ruído na interpretação dos dados.

### 5.1 Trabalhos futuros

Durante a etapa de análise de resultados desse trabalho, houve uma dificuldade em conseguir logar no E4 connect, software onde ficam armazenados os dados coletados pela pulseira Empatica E4 Wristband. Foi possível logar abrindo o navegador em modo anônimo, mas descobriu-se que o serviço será descontinuado no dia 24 de Agosto de 2023, Figura 5.1. A realização da coleta de dados de uma forma independente deste serviço torna-se necessária a futuros trabalhos.

Constituem objetos de estudo para trabalhos futuros:

- Alguns dos voluntários ficaram visivelmente suados nas palmas das mãos, mas não registraram uma grande EDA nos pulsos. A realização do mesmo trabalho alterando-se os locais de coleta desse dado fisiológico é um caminho válido para continuação da pesquisa;
- Replicar a pesquisa fazendo-se o uso de outros dados fisiológicos que não a Atividade Eletrodérmica;
- Replicar a pesquisa fazendo-se o uso software de Porcino et al. [52] na versão de 20 minutos para identificar relações da EDA com um maior tempo de uso;
- Aprimorar o algoritmo de predição e identificação dos sintomas da cybersickness presente no código de aprendizado de máquina de Porcino et al. [2];
- Investigar a não geração de dados com uma entrada válida no código de aprendizado de máquina de Porcino et al. [2];
- Em casos mais moderados e severos de Cybersickness, os participantes relataram uma piora dos sintomas depois de alguns minutos após o experimento. Não existem muitas pesquisas sobre a análise da duração e intensidade dos sintomas ao longo de grandes períodos de tempo;
- Uma dificuldade deste trabalho foi em sincronizar o início da experiência com o início da coleta de dados fisiológicos tanto durante os experimentos quanto na etapa de análise dos resultados. A sincronização automática desses seria um bom avanço no processo como um todo.

# Welcome to E4 connect

Review recorded data in the **sessions** tab.

**We are sunsetting the E4 to make room for more powerful technology, bringing our real-world research suite to EmbracePlus.**

The E4 wristband software suite (E4 connect, E4 manager, E4 realtime, E4 streaming server, and E4 SDK) will remain available until August 2024.

The software suite will continue to undergo regular maintenance until the software is fully phased out, and all E4 devices within the warranty period will be serviced as normal. For any questions please visit our [support centre](#).

Figura 5.1: Interrupção do software E4 connect.

# Referências

- [1] Tengan, Bruno Takashi: *Analisando a cybersickness: Dados fisiológicos e informações contextuais como possíveis indicativos de causas*. Monografia para obtenção de grau bacharelado em Engenharia de Controle e Automação, Brasília, DF, mai, 2021. v, 1, 4, 19
- [2] Thiago Porcino, Erick O. Rodrigues, Flavia Bernardini Daniela Trevisan Esteban Clua: *Identifying cybersickness causes in virtual reality games using symbolic machine learning algorithms*. Entertainment Computing, Volume 41, 100473, 2022. v, vi, 1, 10, 14, 16, 17, 21, 30, 31, 32
- [3] *Repositório no github do software com os dois jogos criados por thiago porcino*. <https://github.com/tmp1986/UFFCSDData>. v, vi, 15, 22, 23
- [4] *Repositório no github do código de aprendizado de máquina criado por thiago porcino*. [https://github.com/tmp1986/ML\\_CS\\_PREDICTOR\\_PYTHON](https://github.com/tmp1986/ML_CS_PREDICTOR_PYTHON). v, vi, 14, 15, 17
- [5] H. K.Kim, J. Park, Y. Choi M. Choe: *Virtual reality sickness questionnaire (vrsq): Motion sickness measurement index in a virtual reality environment*. Applied ergonomics 69, p66–73, 2018. xi, 10, 39
- [6] Porcino, Thiago: *Cybersickness analysis using symbolic machine learning algorithms*. Thesis presented to the Graduate School of Computer Science of Universidade Federal Fluminense as a partial requirement for obtaining the Doctor of Science degree in Computer Science. Field: Computer Science, 2021. xi, 12, 14, 21, 40
- [7] M. E. McCauley, T. J. Sharkey: *Cybersickness: Perception of self-motion in virtual environments*. Presence: Teleoperators Virtual Environments 1, 3, p311–318, 1992. 1, 5
- [8] R. S. Kennedy, N. E. Lane, K. S. Berbaum M. G. Lilienthal: *Simulator sickness questionnaire: An enhanced method for quantifying simulator sickness*. The international journal of aviation psychology 3, 3, p203–220, 1993. 1, 10
- [9] V. Sevinc, M. I Berkman: *Psychometric evaluation of simulator sickness questionnaire and its variants as a measure of cybersickness in consumer virtual environments*. Applied Ergonomics 82, 102958, 2020. 1, 10
- [10] Grigore C. Burdea, Philippe Coiffet: *Virtual reality technology*. John Wiley and Sons, 2003. 3, 4

- [11] Slater, Mel, Vasilis Linakis Martin Usuh Rob Kooper: *Immersion, presence, and performance in virtual environments: An experiment with tri-dimensional chess*. ACM Virtual Reality Software and Technology (VRST), 1999. 3
- [12] Davis, Simon, Keith Nesbitt Eugene Nalivaiko: *Motion sickness, console video games, and head-mounted displays*. Human factors 49, 5, p920–934, 2007. 3
- [13] LaViola, J. Joseph: *A discussion of cybersickness in virtual environments*. ACM SIGCHI Bull 32(1), p47–56, 2000. 3
- [14] H. Buhler, S. Misztal, J. Schild: *Reducing vr sickness through peripheral visual effects*. 2018 IEEE Conference on Virtual Reality and 3D User Interfaces (VR) p517–519, 2018. 3, 8
- [15] Isabell Wohlgenannt, Alexander Simons, Stefan Stieglitz: *Virtual reality*. Business Information and Systems Engineering, 2020. 4
- [16] Irwin, J. A.: *The pathology of sea-sickness*. The Lancet Volume 118, Número 3039, p907-909, 1881. 5
- [17] A. Lawther, M. Griffin: *A survey of the occurrence of motion sickness amongst passengers at sea*. Aviation, space, and environmental medicine 59, 5, p399–406, 1988. 5
- [18] W. Bles, J. E. Bos; B. De Graaf, E. Groen A. H. Wertheim: *Motion sickness: only one provocative conflict?* Brain research bulletin 47, 5, p481–487, 1988. 5
- [19] O. Merhi, E. Faugloire, M. Flanagan T. A. Stoffregen: *Motion sickness, console video games, and head-mounted displays*. Human factors 49, 5, p920–934, 2007. 5
- [20] J. O.Brooks, R. R. Goodenough, M. C. Crisler N. D. Klein R. L. Alley B. L. Koon W. C. Logan Jr J. H. Ogle R. A. Tyrrell R. F. Wills: *Simulator sickness during driving simulation studies*. Accident Analysis and Prevention 42, 3, p788–796, 2010. 5
- [21] Souza, Danilo Neves: *Cybersickness e dados fisiológicos: Um estudo exploratório*. Monografia para obtenção de grau bacharelado em Engenharia da Computação, Brasília, DF, dez, 2020. 5, 19
- [22] Thiago Porcino, Daniela Trevisan, Esteban Clua: *A cybersickness review: causes, strategies, and classification methods*. Journal on Interactive Systems 12, 1, p269–282, 2021. 5, 6, 9, 12, 17
- [23] A. S. Fernandes, S. K. Feiner: *Combating vr sickness through subtle dynamic fieldof-view modification*. 2016 IEEE Symposium on 3D User Interfaces (3DUI) p201–210, 2016. 6, 7
- [24] Kim, Young, Hyun Kim M. J. Park K. S. Park Eun Kim Heedong Ko Hyun Taek Kim: *The application of biosignal feedback for reducing cybersickness from exposure to a virtual environment*. Presence 17, p1–16, 2008. 6



- [25] Bala, Paulo, Dina Dionisio Valentina Nisi Nuno Nunes: *Visually induced motion sickness in 360 videos: Comparing and combining visual optimization techniques*. 2018 IEEE International Symposium on Mixed and Augmented Reality Adjunct (ISMAR-Adjunct) p244–249, 2018. 6
- [26] Choroś, Kazimierz, Piotr Nippe: *Software techniques to reduce cybersickness among users of immersive virtual reality environments*. Intelligent Information and Database Systems, p638–648, Springer International Publishing, 2019. 6, 7, 8
- [27] Budhiraja, Pulkit, Mark Miller Abhishek Modi David Forsyth: *Rotation blurring: Use of artificial blurring to reduce cybersickness in virtual reality first person shooters*, 2017. 7, 8
- [28] Kemeny, Andras, Paul George Frédéric Merienne Florent Colombet: *New vr navigation techniques to reduce cybersickness*. Electronic Imaging p48-53, 2017. 8
- [29] C. Wienrich, C. K. Weidner, C. Schatto D. Obremski J. H. Israel: *A virtual nose as a rest-frame - the impact on simulator sickness and game experience*. 2018 10th International Conference on Virtual Worlds and Games for Serious Applications (VS-Games), p1–8, 2018. 8
- [30] J.T. Reason, J.J. Brand: *Motion sickness*. Academic press, 1975. 9
- [31] Golding, J.F.: *Motion sickness susceptibility questionnaire revised and its relationship to other forms of sickness*. Brain research bulletin 47, 5, p507–516, 1998. 9
- [32] L. Rebenitsch, C. Owen: *Review on cybersickness in applications and visual displays*. Virtual Reality 20, 2, p101–125, 2016. 10
- [33] K. Carnegie, T. Rhee: *Reducing visual discomfort with hmds using dynamic depth of field*. IEEE computer graphics and applications 35, 5, p34–41, 2015. 10
- [34] S. Bruck, P. A.Watters: *Cybersickness and anxiety during simulated motion: Implications for vret*. Annual Review of Cybertherapy and Telemedicine 144, p169–173, 2009. 10
- [35] Y. Yan, K. Chen, Y. Xie Y. Song Y. Liu: *The effects of weight on comfort of virtual reality devices*. In International Conference on Applied Human Factors and Ergonomics 20, 2, p239–248. Springer, 2018. 10
- [36] Eunhee Chang, Hyun Taek Kim, Byounghyun Yoo: *Virtual reality sickness: A review of causes and measurements*. International Journal of Human-Computer Interaction, 2020. 10
- [37] V. Cmiel, O. Janousek, J. Kolarova: *Eeg biofeedback*. ISABEL '11: Proceedings of the 4th International Symposium on Applied Sciences in Biomedical and Communication Technologies 54, p1-5, 2011. 10
- [38] Celikcan, U.: *Detection and mitigation of cybersickness via eeg-based visual comfort improvement*. 3rd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT) p1-4, 2019. 10

- [39] J. Amores, R. Richer, N. Zhao P. Maes B. M. Eskofier: *Promoting relaxation using virtual reality, olfactory interfaces and wearable eeg*. IEEE 15th International Conference on Wearable and Implantable Body Sensor Networks (BSN) p98-101, 2018. 10
- [40] Garcia-Agundez, Augusto, Christian Reuter Polona Caserman Robert Konrad Stefan Göbel: *Identifying cybersickness through heart rate variability alterations*. International Journal of Virtual Reality, 2019. 11
- [41] Yin, Jieyun, Jiande Chen: *Electrogastrography: Methodology, validation and applications*. Journal of neurogastroenterology and motility 19, p5-17, 2013. 11
- [42] Kim, Young, Hyun Kim Eun Kim Heedong Ko Hyun Taek Kim: *Characteristic changes in the physiological components of cybersickness*. Psychophysiology 42, p616-25, 2005. 11
- [43] J. Braithwaite, D. Watson, R. Jones M. A. Rowe: *Guide for analysing electrodermal activity and skin conductance responses for psychological experiments*. CTIT technical reports series, 2013. 12
- [44] Young Youn Kim, Eun Nam Kim, Min Jae Park Kwang Suk Park Hee Dong Ko Hyun Taek Kim: *The application of biosignal feedback for reducing cybersickness from exposure to a virtual environment*. Presence: Teleoperators and Virtual Environments, 2008. 12, 17
- [45] J. Kim, W. Kim, H. Oh S. Lee S. Lee: *A deep cybersickness predictor based on brain signal analysis for virtual reality contents*. Proceedings of the IEEE International Conference on Computer Vision 2019, p10580-10589, 2019. 12
- [46] S. Lawrence, C.L. Giles, A.C. Tsoi A.D. Back: *Face recognition: A convolutional neural-network approach*. IEEE transactions on neural networks 8, 1, p98-113, 1997. 13
- [47] A. Graves, A.-r. Mohamed, G. Hinton: *Speech recognition with deep recurrent neural networks*. 2013 IEEE international conference on acoustics, speech and signal processing, p6645-6649, 2005. 13
- [48] H. Sak, A.W. Senior, F. Beaufays: *Long short-term memory recurrent neural network architectures for large scale acoustic modeling*. 13
- [49] W. Jin, J. Fan, D. Gromala P. Pasquier: *Automatic prediction of cybersickness for virtual reality games*. 2018 IEEE Games, Entertainment, Media Conference (GEM), p1-9, 2018. 13
- [50] D. Jeong, S. Yoo, J. Yun: *Cybersickness analysis with eeg using deep learning algorithms*. 2019 IEEE Conference on Virtual Reality and 3D User Interfaces (VR), p827-835, 2019. 13
- [51] A. Garcia-Agundez, C. Reuter, H. Becker R. Konrad P. Caserman A. Miede S. Göbel: *Development of a classifier to determine factors causing cybersickness in virtual reality environments*. Games for health journal 8, 6, p439-444, 2019. 13

- [52] Thiago Porcino, Erick O. Rodrigues, Flavia Bernardini Daniela Trevisan Esteban Clua: *Using the gameplay and user data to predict and identify causes of cybersickness manifestation in virtual reality games*. 2020 IEEE 8th International Conference on Serious Games and Applications for Health (SeGAH), 2020. 13, 14, 15, 16, 17, 21, 32
- [53] *Repositório no github do código de aprendizado de máquina criado por thiago porcino adaptado para ser usado no google colab*. [https://github.com/Fernando-S/ML\\_CS\\_PREDICTOR\\_PYTHON-GOOGLE-COLAB](https://github.com/Fernando-S/ML_CS_PREDICTOR_PYTHON-GOOGLE-COLAB). 17, 22
- [54] *Empatica e4 led guide*. <https://support.empatica.com/hc/en-us/articles/360050783752-E4-Led-Guide-FW-3-0-1-6612-and-higher->. 18
- [55] *Empatica e4 wristband*. <https://www.empatica.com/en-int/research/e4/>. 19

# Anexo I

## Virtual Reality Sickness Questionnaire - VRSQ

1. Desconforto geral	Nenhum	Leve	Moderado	Severo
2. Fadiga (cansaço)	Nenhum	Leve	Moderado	Severo
3. Fadiga (ocular)	Nenhum	Leve	Moderado	Severo
4. Dificuldade de concentração	Nenhum	Leve	Moderado	Severo
5. Dor de cabeça	Nenhum	Leve	Moderado	Severo
6. "Cabeça Pesada"	Nenhum	Leve	Moderado	Severo
7. Visão embaçada	Nenhum	Leve	Moderado	Severo
8. Tontura	Nenhum	Leve	Moderado	Severo
9. Vertigem	Nenhum	Leve	Moderado	Severo

Tabela I.1: Adaptação do VRSQ para português [5].

# Anexo II

## Cybersikenss Profile Questionnaire - CSPQ

1. Gênero	Feminino	Masculino	
2. Idade	18 a 36	37 a 50	+50
3. Experiência	Nenhum	Alguma	Muita
4. Pré-Sintomas	Nenhum	Algum	
5. Sensibilidade a cintilação	Nenhum	Alguma	
6. Uso de óculos de grau	Não	Sim	
7. Postura de jogo	Sentado	Em pé	
8. Olho dominante	Esquerdo	Direito	

Tabela II.1: Adaptação do CSPQ para português [6].