

**Predição de escolhas de baixa capacidade  
cognitiva baseada na variabilidade da  
frequência cardíaca**

Mario Muramatsu Júnior

DISSERTAÇÃO APRESENTADA AO  
INSTITUTO DE MATEMÁTICA E ESTATÍSTICA  
DA UNIVERSIDADE DE SÃO PAULO  
PARA OBTENÇÃO DO TÍTULO DE  
MESTRA EM CIÊNCIAS

Programa: Ciência da Computação  
Orientador: Prof. Dr. André Fujita

Durante o desenvolvimento deste trabalho, o autor recebeu  
auxílio financeiro da FAPESP – processo nº 2021/05658-0

São Paulo  
Agosto de 2024



**Predição de escolhas de baixa capacidade  
cognitiva baseada na variabilidade da  
frequência cardíaca**

Mario Muramatsu Júnior

Esta versão da dissertação contém  
as correções e alterações sugeridas  
pela Comissão Julgadora durante a  
defesa da versão original do trabalho,  
realizada em 18 de Junho de 2024.

Uma cópia da versão original está  
disponível no Instituto de Matemática e  
Estatística da Universidade de São Paulo.

Comissão julgadora:

Prof. Dr. André Fujita (orientador) – IME-USP

Prof.<sup>a</sup> Dr.<sup>a</sup> Katerina Lukasova – UFABC

Prof. Dr. João Paulo Papa – UNESP

*O conteúdo deste trabalho é publicado sob a licença CC BY 4.0  
(Creative Commons Attribution 4.0 International License)*

# Resumo

Mario Muramatsu Júnior. **Predição de escolhas de baixa capacidade cognitiva baseada na variabilidade da frequência cardíaca.** Dissertação (Mestrado). Instituto de Matemática e Estatística, Universidade de São Paulo, São Paulo, 2024.

A tomada de decisões é um aspecto fundamental da vida cotidiana. Ela ocorre em vários contextos, desde a escolha do que comer no café da manhã até decisões complexas, como escolhas de carreira ou estratégias de negócios. Nesse contexto, uma pergunta natural é: poderíamos prever a decisão de uma pessoa? Para ajudar a responder a essa pergunta, levantamos a hipótese de que o estado do corpo é fundamental para algumas classes de tomada de decisão, por exemplo, decisões de raciocínio rápido e intuitivo realizadas pelo Sistema 1 (modelo de Kahneman). Para medir o estado fisiológico do corpo, propomos usar a interocepção. É interessante notar que podemos medir a interocepção por meio da variabilidade da frequência cardíaca. Projetamos um experimento em que uma pessoa assiste a um trailer e decide se quer ou não assistir ao filme para testar nossa hipótese. Utilizando um modelo de *machine learning*, demonstramos que a previsão da escolha de uma pessoa é mais eficaz quando se combina a variabilidade da frequência cardíaca com medidas emocionais, em comparação ao uso isolado das emoções ou das preferências de gênero do filme, alcançando uma taxa de acurácia de 73%. Esses resultados evidenciam que o estado fisiológico do corpo está associado à tomada de decisões, as quais podem ser previstas com base nesses parâmetros com uma precisão aceitável.

**Palavras-chave:** Variabilidade da frequência cardíaca. Tomada de decisão. Emoções.



# Abstract

Mario Muramatsu Júnior. **Heart rate variability predicts low cognitive capacity choices**. Thesis (Master's). Institute of Mathematics and Statistics, University of São Paulo, São Paulo, 2024.

Decision-making is a fundamental aspect of everyday life. It takes place in a variety of contexts, from choosing what to eat for breakfast to complex decisions such as career choices or business strategies. In this context, a natural question is: could we predict a person's decision? To help answer this question, we hypothesized that the state of the body is fundamental to some classes of decision-making, for example, fast and intuitive reasoning decisions made by System 1 (Kahneman model). To measure the physiological state of the body, we propose using interoception. It is interesting to note that we can measure interoception through heart rate variability. We designed an experiment in which a person watches a trailer and decides whether or not to watch the movie to test our hypothesis. Using a *machine learning* model, we demonstrated that predicting a person's choice is more effective when heart rate variability is combined with emotional measures, compared to using emotions or movie genre preferences alone, achieving an accuracy rate of 73%. These results show that the physiological state of the body is associated with decision-making, which can be predicted based on these parameters with acceptable accuracy.

**Keywords:** Heart rate variability. Decision making. Emotions.





# Sumário

<b>Introdução</b>	<b>1</b>
<b>1 Motivações</b>	<b>3</b>
<b>2 Fundamentação teórica</b>	<b>5</b>
2.1 Tipos de processos cognitivos . . . . .	5
2.2 Sistema nervoso autônomo . . . . .	7
2.3 Interocepção . . . . .	10
2.4 ECG e HRV . . . . .	11
2.4.1 Pré-processamento de sinal cardíaco . . . . .	12
2.4.2 Índices de HRV . . . . .	13
2.5 Sistema de representação de emoções . . . . .	14
2.6 Relação entre emoção e <i>trailers</i> . . . . .	15
<b>3 Metodologia</b>	<b>17</b>
3.1 Participantes do experimento . . . . .	17
3.2 Experimento . . . . .	18
3.3 <i>Self-Assessment Manikin</i> . . . . .	21
3.4 <i>Software</i> para captura de sinais . . . . .	21
3.5 Aprendizado de máquina . . . . .	24
3.5.1 Máquina de vetores de suporte . . . . .	25
3.5.2 Validação cruzada . . . . .	30
3.6 Classificação de dados . . . . .	31
3.7 Análise estatística . . . . .	32
3.7.1 Método de Fisher . . . . .	32
<b>4 Resultados e discussões</b>	<b>33</b>
<b>5 Limitações do estudo</b>	<b>39</b>

<b>6 Conclusão</b>	<b>41</b>
<b>Referências</b>	<b>43</b>

# Introdução

A tomada de decisões é fundamental em nossa vida diária. A cada momento temos que decidir o que faremos a seguir. Por exemplo, onde e o que comerei? Qual universidade estudarei nos próximos anos? Assistirei a uma partida de futebol na TV ou sairei com meus amigos? Neste contexto, uma questão natural é: poderíamos prever a decisão que uma pessoa tomará?

Para responder a essa pergunta, primeiro precisamos entender o processo de tomada de decisão. Normalmente, consideramos vários fatores, como o valor do peso de um resultado pelo tempo que leva para obtê-lo, o valor de uma consequência desejável ou indesejável e o impacto da recompensa (ou punição) (HINSON *et al.*, 2003). Em outras palavras, a tomada de decisões prioriza geralmente as escolhas com o maior retorno e riscos mínimos. Consideramos um processo que produz os resultados desejados (LI *et al.*, 2020).

Kahneman dividiu a tomada de decisões em dois tipos de processos cognitivos: Sistema 1, no qual fazemos julgamentos e tomamos decisões de forma automática e rápida, e Sistema 2, ou seja, um modo controlado, no qual tomamos decisões de forma deliberada e mais lenta (KAHNEMAN, 2011; KAHNEMAN, 2003; STANOVICH e WEST, 2000).

O primeiro é tipicamente rápido, automático, sem esforço, associativo, implícito (não disponível para introspecção) e muitas vezes carregado de emoção. Os hábitos governam esse tipo de tomada de decisão. Assim, é mais difícil controlá-lo ou modificá-lo. O Sistema 1 requer um pouco de capacidade cognitiva e pode controlar o comportamento em condições abaixo do ideal (). Neste caso, as relações são ligações associativas entre elementos. Eles são formados conforme os princípios de contiguidade e similaridade. Por outras palavras, quanto mais familiar for a situação, mais automática será a tomada de decisão (JUNGERMANN, 2004; STRACK e DEUTSCH, 2004). Alguns exemplos de decisões tomadas pelo Sistema 1 são: “Qual bebida vou beber: água com gás gelada ou café quente?”, “Qual filme vou assistir no cinema?”, “Vou vestir saia ou calça para o meu encontro?”. Este tipo de decisão visa uma recompensa imediata e os estímulos que recebemos (MOELLER *et al.*, 2001).

Por outro lado, as operações do Sistema 2 são mais lentas, seriais, exigem esforço e têm maior probabilidade de serem monitoradas conscientemente e controladas deliberadamente. Eles também são relativamente flexíveis e potencialmente governados por regras. Este modo requer uma grande capacidade cognitiva e pode ter problemas com distração ou níveis extraordinariamente altos, ou baixos de excitação (STRACK e DEUTSCH, 2004). Alguns exemplos de escolhas são: “Onde devo investir meu dinheiro?”, “Que casa devo comprar?”, “Devo estudar no exterior?”. Todas essas questões exigem a análise racional de diversos fatores para encontrar a melhor opção. Ou seja, queremos escolher a opção que gere as

melhores consequências no longo prazo (FERNANDEZ, 2017).

Assim, acreditamos que informações sobre a condição fisiológica do corpo poderiam ajudar a prever as decisões tomadas pelo Sistema 1. Suponha que estamos com sede e a temperatura local está alta. Nesse caso, tendemos a preferir uma bebida gelada a um café quente. Ou em relação a qual filme vou assistir, suponha que estou de bom humor e muito animado. Nesse caso, assistirei um filme de ação. A questão que permanece é, como poderíamos medir o estado fisiológico para prever a tomada de decisões. A condição fisiológica resulta da complexa interação entre o corpo, estímulos externos e órgãos internos. Portanto, é um desafio medir e analisar todas essas características. Propomos utilizar a interocepção (CRAIG, 2003), ou seja, a percepção das condições fisiológicas do corpo. Também pode ser interpretado como informação compactada sobre o estado fisiológico do corpo.

Curiosamente, podemos medir a interocepção monitorando o *heart rate variability* (HRV) (H. PARK *et al.*, 2016). O HRV é uma medida da variação no tempo entre os batimentos cardíacos. Essa variação é controlada pelo sistema nervoso autônomo (SNA), que regula as ações inconscientes do corpo, como a força de contração do coração, digestão, frequência respiratória, resposta pupilar, micção e excitação sexual (GIBBONS, 2019). Podemos subdividir o SNA em dois grandes componentes: o sistema nervoso simpático e o parassimpático. O primeiro estimula a resposta de luta ou fuga do corpo (GIBBONS, 2019). Em contraste, o sistema nervoso parassimpático, o antagonista do sistema nervoso simpático, estimula o corpo a “alimentar-se e procriar” e a “descansar e digerir” (GIBBONS, 2019).

Portanto, devido à forte relação entre o HRV e o corpo, levantamos a hipótese de que, ao utilizar o HRV, podemos prever as decisões tomadas pelo Sistema 2.

# Capítulo 1

## Motivações

A compreensão do processo de tomada de decisão é de extrema importância em diversas áreas do conhecimento, pois permite explicar a resposta comportamental do ser humano diante de situações ou estímulos específicos. Conhecemos, inicialmente, que as decisões são influenciadas por sinais psicofisiológicos, como estado emocional ou estresse. O estudo de [NOWACKI \*et al.\*, 2018](#) investiga o impacto do estresse fisiológico e da combinação de estresse fisiológico e psicossocial na tomada de decisões sob risco, analisando possíveis diferenças entre mulheres e homens. Nesta pesquisa, noventa estudantes participaram de uma tarefa de tomada de decisão após serem expostos a estresse fisiológico, estresse fisiológico e psicossocial combinados ou nenhum estresse. No geral, os resultados indicam que a interação entre o sexo do indivíduo e o tipo de estressor tem influência na tomada de decisões em condições de risco.

Outra pesquisa que explora a relação entre a tomada de decisão e o estado do corpo é apresentada por [NOVAK e MRÁZOVÁ, 2015](#). Este artigo aborda os fatores fisiológicos que podem ter um impacto significativo no desempenho dos pilotos, comprometendo potencialmente a segurança do voo. No decorrer desse estudo, os pilotos foram submetidos a diversas condições desconfortáveis, como calor extremo, fadiga, barulho e hipoglicemia. Ao analisar as estatísticas de erros dos pilotos relacionadas ao impacto de fatores fisiológicos no desempenho, o estudo identificou os estressores que representam as maiores ameaças às tarefas de voo.

Finalmente, o estudo conduzido por [GAMBLE \*et al.\*, 2018](#) examinou 26 militares do sexo masculino submetidos a um teste de discriminação entre amigos e inimigos em condições de estresse manipuladas. Na situação de alto estresse, os participantes foram submetidos a choques por decisões incorretas, enquanto na condição de baixo estresse, vibrações acompanhavam os erros. A análise de desempenho, utilizando a teoria de detecção de sinais, revelou que sob alto estresse, os participantes apresentaram mais alarmes falsos, confundindo amigos com inimigos, juntamente com um aumento na variabilidade da frequência cardíaca de alta frequência. O estudo também investigou a relação entre tomada de decisão e fisiologia, revelando perfis comportamentais e fisiológicos adaptativos associados a diferentes níveis de estresse. Esse perfil adaptativo sugere que o treinamento especializado em ambientes de alto estresse desenvolve respostas arraigadas que operam

sem controle consciente, atuando como um mecanismo para mitigar o impacto negativo do estresse no desempenho.

Neste estudo investigaremos as decisões de baixa capacidade cognitiva realizadas pelo Sistema 1, conforme detalhado na seção 2.1. Sabemos que a tomada de decisão ocorre por meio de um processamento cognitivo. No entanto, o êxito desta pesquisa implicará na habilidade de prever decisões com base nas respostas fisiológicas do corpo. Isso destacará que o processo de tomada de decisões não se limita apenas ao raciocínio cognitivo, mas também é influenciado por respostas fisiológicas do corpo. Nesse contexto, o objetivo deste trabalho é compreender se existe correlação e, potencialmente, identificar os impactos das variações na frequência cardíaca na tomada de decisões.

# Capítulo 2

## Fundamentação teórica

Nesta seção apresentaremos a fundamentação teórica estudadas para o desenvolvimento do projeto. Na seção 2.1, apresentamos os dois tipos de processos cognitivos, suas características e peculiaridades. Na seção 2.2, apresentamos uma explicação sobre o Sistema nervoso autônomo, suas componentes e sua relação com a frequência cardíaca. Na seção 2.3, apresentamos o conceito de interocepção e detalhamos sua ligação com o HRV. Na seção 2.4 detalharemos o que são os sinais de eletrocardiograma (ECG) e como o analisaremos usando HRV. Na seção 2.5 definiremos qual sistema de representação de emoções vai ser utilizado no projeto.

### 2.1 Tipos de processos cognitivos

Para compreender o conceito proposto por Kahneman, que envolve a divisão do processamento cognitivo em dois sistemas distintos, é fundamental abordar os dois modelos publicados anteriormente: o Modelo Heurístico-Sistêmico (HSM) e a Teoria do Processo Duplo.

O Modelo Heurístico-Sistêmico (HSM) (CHAIKEN, 1980; CHEN e CHAIKEN, 1999), concebido por Chaiken em 1980, fornece explicações sobre como os indivíduos processam informações e tomam decisões por meio de dois modos principais: o processamento heurístico e o processamento sistemático.

O processamento heurístico implica o uso de atalhos cognitivos rápidos, intuitivos e eficientes, ou regras práticas que possibilitam a tomada rápida de decisões com base em pistas prontamente disponíveis. Embora seja eficaz, o processamento heurístico pode propiciar distorções e erros quando empregado inadequadamente ou em situações que demandam uma reflexão mais minuciosa. Por outro lado, o processamento sistemático se caracteriza por uma análise deliberada e cuidadosa. Exige um esforço cognitivo mais intenso e adota uma abordagem analítica, considerando diversos fatores e examinando as informações de maneira mais aprofundada. O processamento sistemático é menos propenso a enviesamentos e erros, tornando-se mais apropriado para tomadas de decisões complexas.

Uma das principais características desse modelo é a capacidade dos indivíduos de

alternar entre o processamento heurístico e sistemático, influenciados por fatores como motivação, recursos cognitivos e a complexidade da tarefa de decisão. Essa flexibilidade nos modos de processamento destaca a natureza dinâmica da cognição humana.

A Teoria do Processo Duplo, desenvolvida por [STANOVICH e WEST, 2000](#), constitui um modelo psicológico que diferencia entre dois sistemas cognitivos: um sistema associativo automático e um sistema algorítmico baseado em regras. Assim como o Modelo Heurístico-Sistemático, esta teoria investiga os processos duais que fundamentam a tomada de decisões humanas e o processamento de informações.

O processamento associativo automático é marcado por operações cognitivas rápidas, intuitivas e descomplicadas. Ele se apoia em associações e padrões adquiridos por meio da experiência, possibilitando julgamentos e respostas rápidas. No entanto, devido à sua natureza, está sujeito a enviesamentos e pode não incluir uma análise aprofundada. O processamento algorítmico baseado em regras, por outro lado, é mais cuidadoso e analítico. Ele envolve raciocínio sistemático, pensamento lógico e a aplicação de regras ou algoritmos explícitos. Esse modo de processamento demanda esforço consciente e é menos suscetível a enviesamentos, proporcionando uma abordagem mais ponderada à tomada de decisões.

Um elemento essencial da Teoria do Processo Duplo é a interação entre esses dois sistemas. Tanto os processos automáticos quanto os algorítmicos contribuem para o funcionamento cognitivo geral, e a natureza dessa interação varia conforme a tarefa em questão, as diferenças individuais e os fatores contextuais. A eficiência do processamento automático o torna adequado para tarefas rotineiras e familiares, ao passo que o processamento algorítmico está associado a situações que demandam análise e raciocínios cuidadosos. Os autores destacam que os indivíduos podem favorecer um sistema sobre o outro, dependendo da complexidade da tarefa e dos seus recursos cognitivos.

Por fim, a estrutura delineada por Daniel Kahneman, um psicólogo ganhador do Prêmio Nobel, em seu livro “Thinking, Fast and Slow” ([KAHNEMAN, 2011](#)), que descreve os Sistemas 1 e 2, oferece um modelo abrangente para compreender os processos duais de cognição humana e tomada de decisão.

O Sistema 1, caracterizado pelo pensamento intuitivo e rápido, assemelha-se a um piloto automático mental. Destaca-se na rápida interpretação de informações familiares e na resposta a situações rotineiras, possibilitando julgamentos ágeis sem demandar um esforço mental significativo. Contudo, essa eficiência não vem sem custos, uma vez que é mais propenso a enviesamentos cognitivos, baseando-se em heurísticas que podem resultar em erros de julgamento.

Em contraste, o Sistema 2 representa o modo deliberado, analítico e de pensamento mais lento. É ativado quando as tarefas demandam uma consideração cuidadosa, incluindo raciocínio lógico e pensamento crítico. Funciona como um freio mental, capaz de anular respostas automáticas do Sistema 1 e atenuar enviesamentos. Apesar de sua maior precisão, o Sistema 2 é cognitivamente exigente e necessita de esforço consciente.

A interação dinâmica entre esses sistemas é fundamental para a compreensão da tomada de decisão humana. O Sistema 1 serve como o padrão, permitindo que os indivíduos naveguem na vida diária com eficiência, embora possa levar a julgamentos precipitados e atalhos cognitivos. Por outro lado, o Sistema 2, mesmo sendo mais exigente, intervém



diante de problemas complexos, proporcionando uma abordagem mais fundamentada e ponderada.

O modelo proposto por Kahneman encontra aplicações em diversos campos. Na economia comportamental, [KAHNEMAN e TVERSKY, 1979](#) esclarecem os desvios das decisões racionais previstas pelos modelos econômicos clássicos, ajudando a compreender como os indivíduos podem tomar decisões irracionais com base em viesamentos cognitivos. Em marketing, a teoria é utilizada para analisar os processos de tomada de decisão do consumidor. Como evidenciado na pesquisa conduzida por [SHIV e FEDORIKHIN, 1999](#), os participantes foram confrontados com a escolha entre duas alternativas. A primeira estava associada a um resultado afetivo positivo, embora apresentasse cognições menos favoráveis. A segunda, por sua vez, estava vinculada a um resultado afetivo menos favorável, mas contava com cognições mais vantajosas. O estudo indicou que, quando os recursos de processamento são limitados, os indivíduos tendem a favorecer reações afetivas em detrimento de considerações cognitivas (Sistema 1). No entanto, no cenário oposto, onde há recursos disponíveis para o processamento cognitivo, as cognições relacionadas às consequências das alternativas ganham maior influência na tomada de decisão (Sistema 2).

Por mais que os três modelos apresentados sejam muito semelhantes, existem diferenças sutis entre eles. Essencialmente, o modelo de Kahneman, diferente dos outros dois, consegue evidenciar mais a dualidade dos dois tipos de processos cognitivos, indicando com maior clareza as diferenças e vieses de cada um dos modos. Segundo [KAHNEMAN, 2003](#), o Sistema 1 fundamenta-se em hábitos estabelecidos e é notoriamente difícil de modificar ou influenciar, sendo muitas vezes influenciado por vínculos emocionais, já o Sistema 2 é mais volátil, estando sujeito a julgamentos e atitudes conscientes.

Embora o Sistema 2 esteja envolvido em decisões lógicas, ele não está isento da influência das emoções. Segundo [HEILMAN \*et al.\*, 2016](#), os humanos frequentemente fazem esforços para controlar suas experiências emocionais, o que indica que diferentes estratégias de regulação emocional podem gerar diferentes implicações em decisões complexas. Assim, dependendo da regulação emocional do indivíduo, a influência das emoções na tomada de decisão pode variar.

Nesse sentido, dado que o modelo proposto por Kahneman apresenta seus conceitos de forma mais concisa e clara, o escolhemos para basear o tipo de processo cognitivo que desejamos estudar neste trabalho.

## 2.2 Sistema nervoso autônomo

É essencial adquirirmos uma compreensão básica do SNA, uma vez que esse sistema está intimamente ligado aos processos examinados neste estudo, como o controle da frequência cardíaca e a regulação das emoções experimentadas pelo indivíduo.

O SNA é uma parte integrante do Sistema Nervoso Periférico, que juntamente com o Sistema Nervoso Central (SNC), forma o sistema nervoso de um ser humano. Segundo [WAXENBAUM \*et al.\*, 2024](#), a função do SNA é controlar processos fisiológicos involuntários, como frequência cardíaca, respiração, digestão e excitação sexual. O SNA é composto por três divisões anatomicamente distintas: o sistema simpático, o sistema parassimpático

e o sistema entérico.

O Sistema Nervoso Simpático (SNS) e o Sistema Nervoso Parassimpático (SNP) possuem fibras aferentes e eferentes que transmitem informações sensoriais para o SNC e controlam a saída motora para os tecidos ativos, respectivamente (WAXENBAUM *et al.*, 2024). As vias motoras desses sistemas são compostas por dois neurônios: um pré-ganglionar, conectado ao SNC, e um pós-ganglionar, conectado aos órgãos e tecidos alvo.

Ambos, SNS e SNP, são tonicamente ativos. Em outras palavras, eles fornecem algum grau de estímulo nervoso a um determinado tecido o tempo todo (McCORRY, 2007). Para regular as atividades dos tecidos-alvo, esses sistemas podem aumentar ou diminuir a frequência de descarga de seus neurônios, o que resulta em aumento ou inibição da atividade tecidual. Cada sistema está conectado a diferentes tecidos no corpo humano e suas funções são frequentemente opostas em relação a esses tecidos. Portanto, para um controle preciso das funções fisiológicas, um sistema aumenta sua atividade enquanto o outro diminui simultaneamente, garantindo um controle rápido e preciso da função dos tecidos.

O SNS está conectado a quase todos os tecidos ativos no corpo humano (WAXENBAUM *et al.*, 2024). Sua ativação induz um estado geral de atividade e alerta, conhecido como a resposta de “lutar ou fugir”. Esse processo é caracterizado pelo aumento da pressão arterial e da frequência cardíaca, pela ocorrência de glicogenólise (degradação do glicogênio para fornecer energia às células musculares e hepáticas) e pela interrupção do peristaltismo gastrointestinal (movimentos que promovem a digestão), entre outros.

Em contrapartida, o SNP inerva principalmente a cabeça, as vísceras e a genitália externa, sendo notavelmente ausente na maior parte do sistema musculoesquelético e da pele, o que o torna consideravelmente menor que o SNS (WAXENBAUM *et al.*, 2024). O SNP é responsável por promover o estado de “descansar e digerir”, caracterizado pela diminuição da frequência cardíaca e da pressão arterial, o estímulo do peristaltismo gastrointestinal, entre outros efeitos.

O Sistema Nervoso Entérico (SNE) é uma rede extensa que opera de forma independente do restante do sistema nervoso, sendo responsável principalmente pela regulação dos processos digestivos (WAXENBAUM *et al.*, 2024). Suas funções incluem controlar a contração e o relaxamento muscular, a absorção e a secreção, bem como o fluxo sanguíneo através de seus circuitos reflexos.

O SNE está exclusivamente relacionado aos processos digestivos, que não são abordados neste trabalho. Portanto, não entraremos em detalhes sobre essa divisão e nos concentraremos em apresentar informações sobre o funcionamento do SNS e do SNP no controle da frequência cardíaca e das emoções.

Ambos, SNS e o SNP estão conectados ao coração. Suas funções são opostas, sendo o SNS responsável por aumentar a frequência cardíaca, a força de contração e a taxa de condução, enquanto o SNP é responsável por diminuir a frequência cardíaca e a taxa de condução.

A ativação do SNS provoca uma série de respostas em todo o corpo. Essas mudanças têm como objetivo principal aumentar o fornecimento de sangue bem oxigenado e rico em nutrientes aos músculos esqueléticos em atividade (WAXENBAUM *et al.*, 2024, McCORRY,

2007). O SNS envia sinais ao coração para aumentar tanto a frequência cardíaca quanto a contratilidade miocárdica, visando bombear mais sangue por todo o corpo. Conseqüentemente, ocorre vasoconstrição nos órgãos do sistema gastrointestinal, genitália externa e rins, reduzindo o fluxo sanguíneo nesses tecidos metabolicamente inativos e direcionando o sangue para os músculos em contração. Além disso, ocorre a broncodilatação nos pulmões, maximizando a entrada de oxigênio e a saída de dióxido de carbono. Outras respostas incluem o aumento na taxa de glicogenólise, fornecendo energia para a contração muscular, e o aumento da taxa de glicose no sangue.

A ativação do SNP, em contraste com o SNS, busca reduzir o gasto energético e restabelecer os processos digestivos. O SNP influencia diretamente o coração por meio da conexão do nervo vago com células “marca-passo” específicas (DULLECK *et al.*, 2011). Sua ativação também resulta no aumento da secreção salivar, no aumento do movimento coordenado dos músculos e secreções estomacais, bem como na promoção da secreção exócrina e endócrina do pâncreas. O pâncreas é responsável pela produção do suco pancreático e pela manutenção dos níveis de açúcar no sangue, respectivamente.

A relação entre a frequência cardíaca de um indivíduo e os processos fisiológicos controlados pelo SNA, juntamente com os estímulos ambientais que influenciam a reação biológica, é claramente evidente. Isso ressalta a importância da resposta fisiológica do indivíduo diante de diferentes estímulos, como, por exemplo, durante a tomada de decisões.

O SNA desempenha um papel significativo na percepção das emoções, conforme indicado por um estudo conduzido por KREIBIG, 2010. A pesquisa mostra que há uma considerável especificidade na resposta do SNA às emoções, especialmente ao considerar diferentes subtipos de emoções, em indivíduos saudáveis.

Os processos mentais, incluindo emoções, influenciam as respostas fisiológicas realizadas pelo SNA de três maneiras distintas: diretamente e automaticamente através dos nervos autonômicos; indiretamente através de mudanças na respiração, atividade motora esquelética ou postura controladas voluntariamente de forma total ou parcial; ou como conseqüências intencionais ou incidentais das escolhas comportamentais (CRITCHLEY *et al.*, 2013).

Na revisão conduzida por KREIBIG, 2010, são apresentados exemplos de emoções e suas respostas fisiológicas. A emoção da raiva é caracterizada por uma ativação simpática recíproca, resultando no aumento da atividade respiratória, especialmente respiração mais rápida. A análise da emoção da tristeza revela um padrão heterogêneo de coativação do SNS e SNP. O padrão de resposta autonômica da felicidade é caracterizado pelo aumento da atividade cardíaca devido à retirada vagal, vasodilatação, aumento da atividade eletrodérmica e aumento da atividade respiratória, processos causados pela ativação do SNS.

Conforme será mencionado na seção 2.5, as emoções desempenham um papel fundamental na tomada de decisão, e aqui mostramos como o SNA gera respostas fisiológicas distintas para cada emoção. Portanto, é possível presumir que as informações contidas nas respostas fisiológicas são úteis e podem nos fornecer pistas para prever uma decisão ao analisar essas informações.

## 2.3 Interocepção

A partir do que foi discutido na seção 2.2, é evidente que as variações na frequência cardíaca estão fortemente relacionadas com mudanças no estado fisiológico do indivíduo. Outro conceito que reforça essa afirmação é conhecido como interocepção. A interocepção é definida como nossa capacidade de perceber e interpretar mudanças em nosso sistema nervoso autônomo (CRAIG, 2003). A interocepção não se restringe às sensações corporais provenientes do componente aferente do SNA, mas também desempenha um papel no processamento de resultados emocionais, motivacionais e comportamentais (EDWARDS e PINNA, 2020).

Uma interpretação imprecisa das mudanças autonômicas pode prejudicar nossa habilidade de entender e regular nossas reações emocionais (LISCHKE *et al.*, 2020). Além disso, déficits na interocepção desempenham um papel significativo na origem e no desenvolvimento dos transtornos mentais, pois esses déficits comprometem a capacidade de compreensão e regulação das emoções (LISCHKE *et al.*, 2020).

Nesse sentido, a interocepção pode ser vista como uma representação do estado fisiológico do indivíduo. Ao medir a interocepção, podemos obter informações cruciais para o desenvolvimento de nossa hipótese.

A interocepção pode ser avaliada por meio do coração (EDWARDS e PINNA, 2020). Essa afirmação é justificada com o fato de que o coração é duplamente inervado pelo sistema nervoso simpático e parassimpático. Enquanto o SNS encurta o intervalo entre batimentos cardíacos, o SNP o prolonga. Além disso, o coração está sujeito a um controle inibitório tônico predominante do nervo vago, que faz parte do SNA responsável por transmitir informações entre o cérebro e outras partes do corpo, controlando funções corporais involuntárias.

Mais precisamente, para medirmos a interocepção, é necessário analisar o HRV, pois as mudanças no HRV refletem a ativação do SNS e SNP. Um HRV elevado indica um aumento na atividade do SNP, enquanto um HRV baixo indica uma redução na atividade parassimpática e um aumento na ativação do SNS.

Devido à capacidade do HRV de refletir o estado fisiológico do indivíduo, várias análises em diferentes áreas podem ser realizadas usando essa medida. Um exemplo é o fato de um baixo HRV estar associada a distúrbios psicológicos importantes, como depressão e transtorno de ansiedade (EDWARDS e PINNA, 2020). Além disso, um baixo HRV é preditiva de um evento cardiovascular pela primeira vez. Por outro lado, um HRV elevado indica uma melhor função cognitivo-comportamental, incluindo maior função executiva, melhor gestão do estresse, habilidades de enfrentamento e maior envolvimento social (EDWARDS e PINNA, 2020).


Em resumo, a interocepção fornece informações sobre o estado fisiológico do indivíduo, e para avaliar essas variações no SNA, podemos analisar o HRV. Portanto, podemos afirmar que através do HRV, obtemos informações corporais que podem nos auxiliar na predição de uma decisão baseada exclusivamente em informações fisiológicas.

Algo que também é bastante discutido na literatura é que a interocepção desempenha um papel significativo na representação das emoções. Como foi dito na seção 2.2, diferentes

emoções geram diferentes respostas fisiológicas, nesse sentido, a percepção da interocepção está intrinsecamente relacionada às respostas emocionais do indivíduo. Isso sugere que as emoções podem conter informações cruciais sobre o estado fisiológico da pessoa.

## 2.4 ECG e HRV

É crucial obter uma compreensão fundamental do ECG e da HRV para começarmos a estruturar o experimento deste trabalho. Conforme foi discutido na seção 2.2 e também é indicado por [ROBINSON \*et al.\*, 1966](#), o sistema nervoso autônomo exerce controle sobre a frequência cardíaca ao modular o fluxo de impulsos nas fibras nervosas simpáticas e parassimpáticas que convergem no nó sinoatrial. Essa modulação pode ser desencadeada por diversos fatores, como atividade física, alterações na postura, estimulação dos barorreceptores e mudanças psicofisiológicas. O ECG, uma técnica indolor e não invasiva, utiliza sensores para identificar as sutis variações elétricas decorrentes da despolarização e repolarização do músculo cardíaco em cada ciclo cardíaco.




**Figura 2.1:** Exemplo de gráfico ECG gerado a partir de dados coletados.

A partir da captação e registro meticuloso de tais sinais, é viável a elaboração de um gráfico que delinea a atividade elétrica intrínseca ao coração, conforme ilustrado na Figura 2.1. Nesse contexto gráfico, o eixo  $x$  representa a dimensão temporal em segundos da atividade cardíaca, enquanto o eixo  $y$  encapsula a magnitude dos impulsos elétricos captados pelo sensor.

Um batimento é caracterizado pelo segmento composto pelas ondas PQRST ([MADONA \*et al.\*, 2021](#)). A Figura 2.2 apresenta a divisão. A primeira onda encontrada é a onda P que representa a despolarização dos átrios. Durante essa fase, os átrios se contraem, impulsinando o sangue para os ventrículos. Em seguida inicia-se o complexo QRS, que representa a fase da contração ventricular do coração. A onda Q indica a despolarização inicial do septo interventricular, enquanto a onda R reflete a despolarização das porções mais massivas dos ventrículos. A onda S, por sua vez, representa a fase final da despolarização ventricular.

Por fim, a onda T representa a repolarização dos ventrículos, indicando o momento em que eles se preparam para o próximo ciclo de batimento cardíaco



**Figura 2.2:** Divisão do seguimento PQRST.

A separação entre dois destes picos R é conhecida como intervalo RR, e é a partir dessa medida temporal que se torna possível calcular o valor da frequência cardíaca, expressa em batimentos por minuto (BPM). A flutuação nesse valor é referida como HRV, e conforme indicado por [VANDERLEI \*et al.\*, 2009](#), é factível derivar métricas específicas, denominadas índices de HRV, mediante a análise aprofundada dos intervalos RR.

### 2.4.1 Pré-processamento de sinal cardíaco

Embora o posicionamento do coração garanta um sinal limpo, o ECG não está isento de ruídos e artefatos. Uma causa natural de ruídos são os batimentos ectópicos, causados pela condutividade elétrica originada nas fibras fora do nó sinoatrial. O nó sinoatrial é a região do músculo cardíaco responsável pelos impulsos elétricos.

Dois tipos principais incluem contrações atriais prematuras (APC) e contrações ventriculares prematuras (PVC) ([NABIL e BEREKSI REGUIG, 2015](#)). As APCs surgem nos átrios, enquanto as PVCs se originam nos ventrículos. Ambos envolvem sinais elétricos prematuros que perturbam o ritmo normal do coração. Em um ECG, as APCs se manifestam como ondas P irregulares e as PVCs como complexos QRS aberrantes. Embora batimentos ectópicos ocasionais sejam comuns e muitas vezes benignos, ocorrências frequentes ou persistentes podem indicar problemas de saúde subjacentes. Alguns fatores que podem contribuir para o acontecimento dessas contrações irregulares são, estresse, uso excessivo de cafeína, desequilíbrios eletrolíticos, condições cardíacas subjacentes, como doença arterial coronariana ou cardiomiopatia e alguns tipos de medicamentos.

Outra fonte de irregularidade são os artefatos, que consistem em anormalidades ou interferências provenientes de fatores externos ao sistema elétrico cardíaco, como, a falta de contato do sensor com a pele, movimento muscular como tremores do paciente, atividade elétrica devido a contrações musculares duradouras, artefatos gerados pelo processamento de sinal em hardware como saturação de sinal, interferência eletromagnética, entre outros (CLIFFORD, 2006; PÉREZ-RIERA *et al.*, 2018).

A partir disso, obtivemos os intervalos normalizados (NN) pré-processando os dados usando a biblioteca `hrv-analysis` para Python do Aura Healthcare Project. O termo “normal” significa que batimentos anormais, como batimentos ectópicos, foram removidos. O NN é o tempo decorrido entre dois picos R sucessivos no complexo QRS da onda do eletrocardiograma. As etapas de pré-processamento para obtenção dos intervalos NN foram as seguintes:

1. Excluimos os *outliers*, ou seja, intervalos RR inferiores a 300 ms e superiores a 2.000 ms.
2. Filtramos os batimentos ectópicos nas frequências cardíacas de curto prazo usando a técnica de Malik (AÇAR *et al.*, 2000).

Além disso, seguindo as sugestões de DAHIYA *et al.*, 2004, aplicamos interpolação linear para completar os pontos faltantes.

### 2.4.2 Índices de HRV

Com os dados livres de qualquer ruído, podemos calcular algo chamado de índices de HRV, que são medidas quantitativas derivadas da análise das variações nos intervalos de tempo entre batimentos cardíacos sucessivos. Elas podem ser divididas em três categorias, tempo, frequência e não linear (SHAFFER e GINSBERG, 2017). Os índices no domínio do tempo utilizam métodos estatísticos para calcular medidas que explicitam flutuações na duração dos ciclos cardíacos. Os índices no domínio da frequência analisam o espectro da frequência dos intervalos NN usando a transformada de Fourier. Por fim, os índices não lineares são derivados de análises geométricas dos intervalos NN no domínio do tempo, possibilitando avaliar a complexidade e a irregularidade da série temporal da frequência cardíaca.

Neste trabalho iremos nos focar apenas em um índice não-linear chamado `sd_ratio`. O `sd_ratio` representa a relação entre o desvio padrão da variabilidade do intervalo NN de curto e longo prazo e pode fornecer informações úteis sobre a modulação vagal dinâmica do intervalo NN (TULPPO *et al.*, 1996). FORTE *et al.*, 2021 mostraram que indivíduos cujo tônus vagal é elevado poderiam tomar boas decisões em condições incertas. Indivíduos com baixo tônus vagal foram associados a um tipo de miopia para o futuro.

Para calcular o `sd_ratio`, primeiro obtivemos o gráfico de Poincaré (Figura 2.3). O gráfico de Poincaré exhibe os valores de  $NN_i$  no eixo  $x$  e o  $NN_{i+1}$  (intervalo NN sucessivo) no eixo  $y$ . Com base no gráfico de Poincaré calculamos SD1 e SD2. SD1 é o desvio padrão da projeção do gráfico de Poincaré na reta perpendicular à reta de identidade. SD2 é o desvio padrão da projeção do gráfico de Poincaré na reta identidade ( $y = x$ ). Por fim, obtivemos o `sd_ratio` calculando a razão  $SD2/SD1$ .

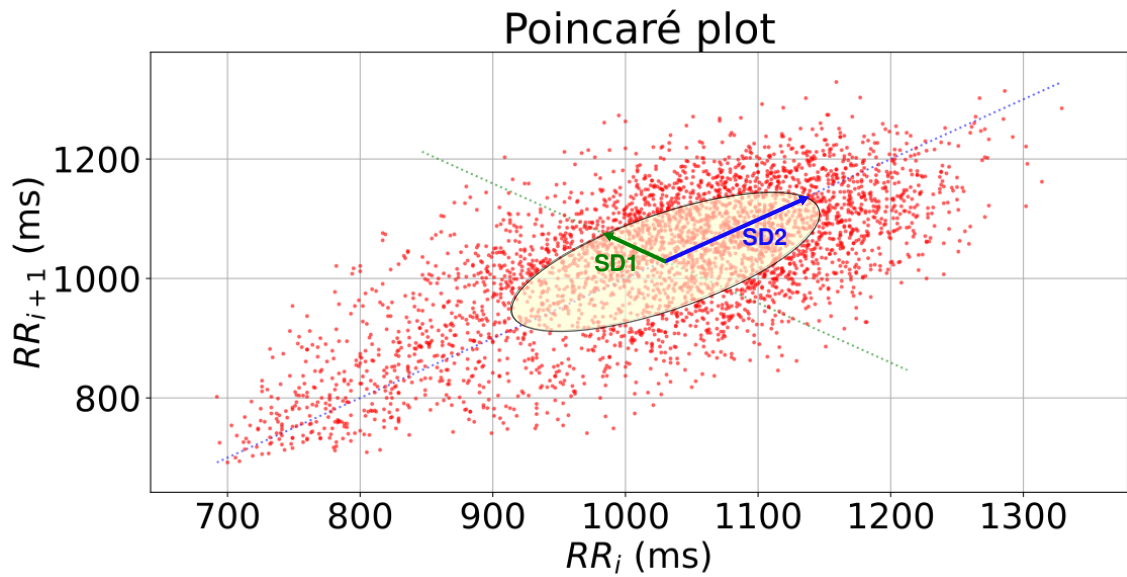


Figura 2.3: Gráfico de Poincaré usado para calcular os índices de HRV SD1 e SD2.

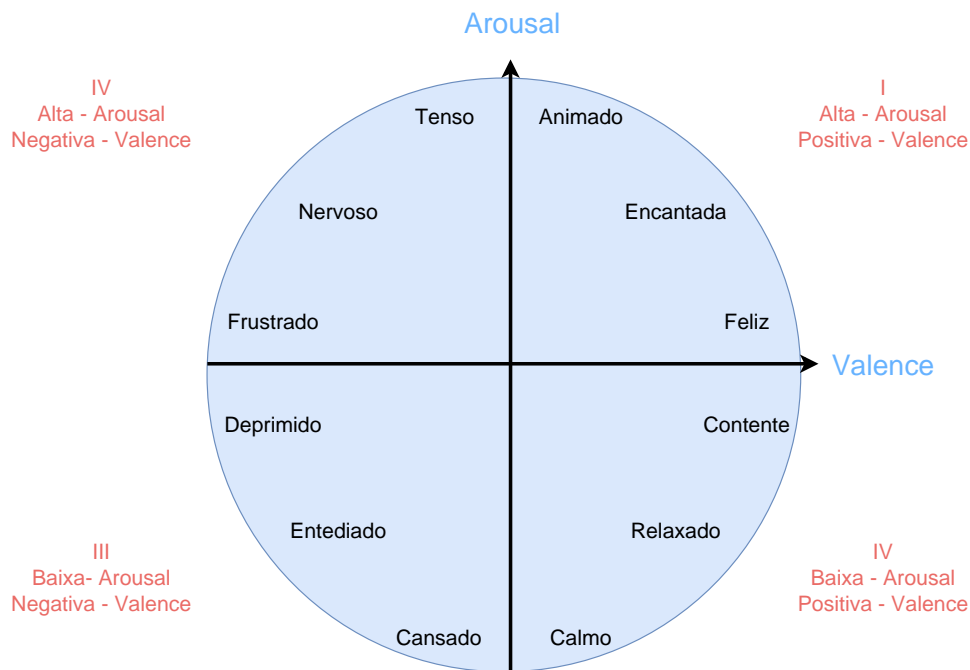
## 2.5 Sistema de representação de emoções

As emoções têm um papel fundamental na tomada de decisões de acordo com muitos relatos na literatura. Por exemplo, [ACHAR et al., 2016](#) mostraram o impacto da emoção nas decisões do consumidor, nas estratégias de marketing e nas vendas. [YANG et al., 2020](#) evidenciaram que em decisões de risco, elementos como raiva, medo e felicidade podem exercer influência sobre o resultado da decisão, mesmo que esses não sejam originados diretamente do processo de tomada de decisão. [BROSCH et al., 2013](#) indicaram que, no caso de decisões complexas, pessoas que apresentam reatividade emocional reduzida devido a lesões em regiões cerebrais específicas tendem a tomar decisões prejudiciais ao seu bem-estar em comparação com pessoas saudáveis.

Há diversas maneiras de categorizar as emoções, sendo a mais elementar a divisão dos estados mentais em seis categorias fundamentais: felicidade, tristeza, raiva, medo, repugnância e surpresa ([EKMAN et al., 1987](#)). De acordo com [MAFFEI e ANGRILLI, 2019](#), é possível incluir um sétimo estado, o neutro. Entretanto, essa abordagem enfrenta desafios consideráveis na precisão da classificação das emoções percebidas, uma vez que carece de um protocolo específico para a mensuração dessas sensações.

O modelo desenvolvido por [RUSSELL, 1980](#), denominado Valence-Arousal (VA), destaca-se como o mais amplamente utilizado na literatura para a categorização de emoções. Um exemplo de estudo que emprega esse modelo é o trabalho de [KASSEM et al., 2017](#), que propõe uma nova estratégia para quantificar valores emocionais usando o comportamento ocular de um indivíduo, validando seu método por meio do modelo VA. Outro estudo, conduzido por [KUPERMAN et al., 2014](#), busca avaliar a influência da emoção na tarefa de reconhecimento de palavras. Nessa pesquisa, o modelo VA é empregado para classificar o conjunto de palavras em positivas ou negativas e excitantes ou tranquilizadoras. Um dos resultados obtidos pelo autor é que palavras associadas a uma emoção negativa são reconhecidas mais lentamente do que palavras positivas, e palavras excitantes são





**Figura 2.4:** Representação do sistema VA exibido no plano cartesiano, em que o eixo x representa a Valence e o eixo y representa o Arousal.

reconhecidas mais lentamente do que palavras tranquilizadoras.

Este modelo compreende a divisão das emoções em dois eixos, Valence e Arousal. O eixo Valence determina se a emoção é positiva ou negativa, enquanto o eixo Arousal ilustra o nível de excitação ou calma associado à emoção. Dessa forma, o ponto central desses dois eixos representa uma emoção neutra. A Figura 2.4 apresenta a representação visual desse modelo. Note que esse modelo abrange o método de dividir as emoções em estados distintos, pois a partir dos valores de valência e excitação podemos determinar a emoção sentida.

## 2.6 Relação entre emoção e trailers

Utilizar filmes como estímulo para provocar uma resposta emocional nas pessoas é uma estratégia eficaz. Conforme discutido por Tan em seu livro *“Emotion and the Structure of Narrative Film: Film As An Emotion Machine”* (TAN, 2011), assistir a filmes não é apenas uma experiência passiva de observar sons e imagens, mas sim uma busca por elementos que despertam interesse, geralmente encontrados nos eventos mais impactantes do filme.

Além disso, existem diversos artigos na literatura que utilizam filmes com o intuito de identificar respostas emocionais distintas. Um exemplo disso é apresentado por BAVEYE *et al.*, 2015, o qual propõe uma grande base de dados, chamada de LIRIS-ACCEDE, composta de pequenos trechos de filmes anotados com seus respectivos valores de Valence e Arousal. Não utilizamos o conjunto de dados proposto por BAVEYE *et al.*, 2015 em nosso projeto, pois os trechos de filmes fornecidos pelo LIRIS-ACCEDE possuem uma duração entre 8 a 12 segundos, o que é considerado um período extremamente curto para verificar mudanças significativas no HRV do indivíduo, impossibilitando nossas análises.

A literatura também aborda o uso de *trailers* para elicitare respostas emocionais. No estudo conduzido por [MICHAEL B. DEVLIN e CALLISON, 2011](#), foi avaliado o efeito do humor induzido nos participantes ao assistirem um trailer de um filme sério ou cômico. O autor destacou a descoberta de uma interação entre humor, tipo de trailer e gênero, observando que os homens relataram maior intenção de assistir filmes sérios ou cômicos, independentemente de seu humor. No entanto, as mulheres mostraram um padrão de congruência: aquelas com humor negativo responderam positivamente aos *trailers* sérios e demonstraram antipatia pelos *trailers* cômicos. Por outro lado, as mulheres com humor positivo responderam positivamente aos *trailers* cômicos, mas não aos sérios.

Os *trailers* tendem a conter elementos destinados a destacar o gênero clássico que se busca promover, visando gerar uma resposta emocional específica e intensa ([JENSEN, 2014](#)). Nesse sentido, a utilização de *trailers* a fim de obter respostas emocionais diversas é uma estratégia eficiente.

O estudo apresentado por [REDFERN, 2020](#) aborda a construção dos *trailers* de filmes de terror em relação à sua trilha sonora. De acordo com o autor, uma característica crucial da sonorização de *trailers* de filmes de terror é a presença de uma série de eventos sonoros afetivos que capturam a atenção do público e criam momentos de medo. Simplificadamente, o evento sonoro pode ser dividido em três etapas. O primeiro estágio é o ataque, cujo objetivo é aumentar a energia até alcançar um nível desejado de intensidade. Em seguida, temos a sustentação, que consiste em manter esse efeito por um período de tempo. Por fim, há a liberação, a qual é a fase de diminuição gradual do efeito sonoro até que não seja mais percebido. A combinação dessas etapas gera respostas emocionais de medo com intensidades variadas.

Com base na análise desta seção, fica claro que os *trailers* são ferramentas confiáveis para induzir respostas emocionais distintas, uma vez que sua construção é planejada para alcançar determinadas respostas emocionais intensas. Portanto, em nosso experimento, iremos apresentar um conjunto de *trailers* aos participantes os quais deverão decidir se irão assistir ou não ao filme correspondente.

# Capítulo 3

## Metodologia

Nesta seção apresentaremos as atividades executadas para o desenvolvimento do projeto. Na seção 3.1 detalhamos quais são as características dos indivíduos que participam do nosso experimento. Na seção 3.2 apresentamos o experimento proposto para verificar nossa hipótese. Na seção 2.6, apresentamos justificativas para utilizarmos *trailers* de filmes para induzir respostas emocionais distintas. O *software* usado para capturar os sinais cardíacos será apresentado na seção 3.4. Na seção 3.5, explicaremos o método de aprendizado de máquina utilizado para realizar as predições. Na seção 3.6 mostraremos como foi feita a classificação dos dados coletados. Na seção 3.7, apresentamos as ferramentas estatísticas que usamos para analisar os dados.

### 3.1 Participantes do experimento

Queremos testar a hipótese de que, utilizando o HRV, podemos prever a escolha de um indivíduo. Para testar essa hipótese, recrutamos 20 sujeitos. Montamos um experimento no qual os sujeitos assistiam a *trailers* de filmes e decidiam se queriam assistir ao filme. Coletamos a frequência cardíaca usando uma cinta com sensor de frequência cardíaca e construímos um modelo de predição de aprendizado de máquina.

Ao total foram vinte indivíduos (dez homens e dez mulheres) com idades entre 18 e 40 anos. Os indivíduos elegíveis eram saudáveis, com idade entre 18 e 40 anos, falantes nativos de português e visão e audição normais ou corrigidas para normais. Os critérios de exclusão foram doenças cardiorrespiratórias, distúrbios do sistema nervoso, doenças sistêmicas, doenças crônicas, uso de drogas/medicamentos, ingestão de cafeína ou álcool, exercícios exaustivos 24 horas antes da coleta de dados e não dormir bem pelo menos sete horas na noite anterior à coleta de dados. Não excluímos nenhum participante. Assim, nosso conjunto de dados final compreendeu 20 indivíduos (idade média  $\pm$  desvio padrão,  $23,8 \pm 5,04$  anos). Além da aquisição do sinal cardíaco (consulte a seção 2.3 para mais detalhes), também coletamos informações sobre preferências de gêneros de filme, altura e peso dos participantes.

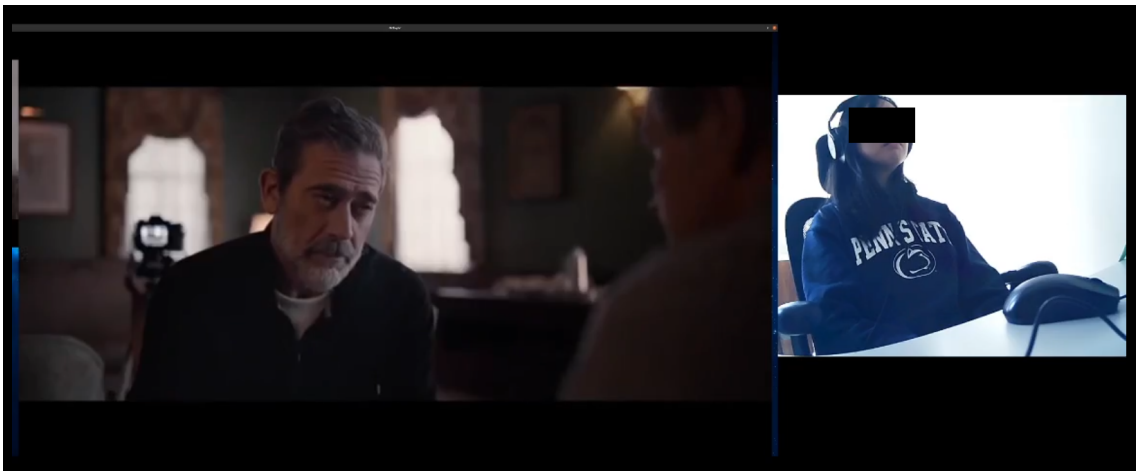
O Comitê de Ética em Pesquisa com Seres Humanos da Escola de Artes, Ciências e Humanidades (EACH) - Universidade de São Paulo (USP) aprovou o protocolo experimental

(número do protocolo: 32732320.4.0000.5390; data de aprovação: 9 de junho de 2020). Realizamos todos os experimentos seguindo as diretrizes e regulamentos do comitê de ética. Obtivemos consentimento informado de todos os participantes.

## 3.2 Experimento

Para testar a hipótese de que é possível prever a escolha de um sujeito usando o HRV, coletamos os sinais cardíacos dos participantes enquanto assistiam aos *trailers* dos filmes. Após assistir a cada trailer, o participante escolhia se assistiria ao filme associado ao trailer.

Conduzimos o experimento em uma sala fechada com clima controlado. Por meio de um questionário, coletamos as preferências de filmes dos participantes (a lista dos gêneros que eles mais gostam e não gostam). Coletamos sinais cardíacos usando um sensor cardíaco Polar H10, uma cinta de tecido macio com eletrodos que captam intervalos RR com baixa interferência. O Polar H10 usa Bluetooth para conectar e transmitir os sinais ao computador. Utilizamos fones de ouvido (Audio Technica ATH-M20x) com isolamento acústico para evitar som externo. Utilizamos um monitor de 31 polegadas (LG) para exibir os *trailers* aos participantes.

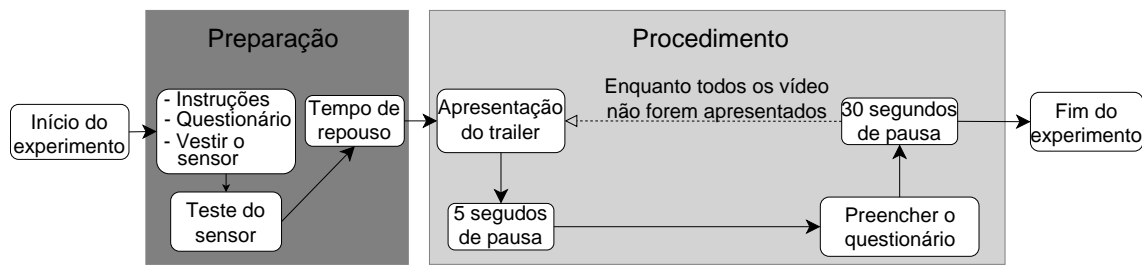


**Figura 3.1:** Exemplo de seção de coleta de dados.

A Figura 3.1, apresenta uma seção do experimento que realizamos. A janela grande a esquerda é a tela que o indivíduo está observando. Nela serão exibidos os *trailers* e os questionários. A direita é a imagem do indivíduo, capturada por uma webcam.

Realizamos o experimento descrito na Figura 3.2. As etapas são as seguintes.

- O participante responde ao questionário com informações básicas, como preferências de gênero de filme, altura, peso, sexo e se pertencem aos critérios de exclusão.
- O participante veste o sensor de frequência cardíaca e realizamos testes para verificar se captamos os sinais corretamente. Ao final dos testes, o participante descansa por três minutos sem nenhum estímulo externo.
- O experimento começa. Exibimos um trailer seguido de uma pausa de cinco segundos. Em seguida, o participante responde à probabilidade dele assistir ao filme associado



**Figura 3.2:** Desenho do experimento. Na fase de preparação, montamos o experimento e preparamos os participantes. Durante a etapa processual, apresentamos os trailers aos participantes.

ao trailer. Além disso, o participante registra os níveis de valência e excitação usando o método apresentado na seção 3.3. Antes de iniciar o trailer seguinte, o participante descansa por 30 segundos. Repetimos este procedimento até exibirmos todos os *trailers* dos filmes. Todo esse procedimento é realizado automaticamente por software para evitar interferência humana.

Selecionamos 21 *trailers* de filmes lançados principalmente entre 2021 e 2022 (Tabela 3.1). Classificamos os *trailers* em sete gêneros: ação, comédia, drama, histórico, terror, romance e ficção científica e seguimos as definições descritas pela Forbes.<sup>1</sup> Consideramos filmes de ação aqueles com muitos combates, armas e explosões. Agrupamos filmes de aventura como ação. Filmes de comédia são aqueles marcados pela ironia, diversão e finais felizes. Os filmes dramáticos seguem personagens reais e seus conflitos consigo mesmos, com o mundo ou com as pessoas ao seu redor. Filmes históricos mostram eventos passados ou um período histórico. Consideramos biografias e documentários como filmes históricos. Filmes de terror apresentam intenções de despertar o medo. Agrupamos *thriller*, mistério e suspense com filmes de terror. Romance se concentra nos relacionamentos românticos entre dois personagens e apresenta intimidade, paixão e emoções complexas. Incluímos histórias de amor como romance. Finalmente, a ficção científica trata de ciência e tecnologia e alterna realidade, novos mundos ou universos, viagens no tempo, tecnologia e cenários futuristas. Também classificamos a fantasia como ficção científica.

Selecionamos três filmes para cada um dos sete gêneros, totalizando 21 *trailers* com duração média de 2 minutos e 21 segundos (o trailer mais curto tem 2 minutos e 2 segundos. Em contrapartida, o trailer mais longo tem 2 minutos e 52 segundos). Utilizamos apenas *trailers* dublados em português porque todos os participantes eram falantes nativos de português.

É relevante ressaltar que o desenvolvimento do nosso conjunto de dados passou por uma avaliação prévia realizada por um grupo de cinco pessoas, que não fazem parte dos 20 participantes do experimento principal, para garantir a eficácia desse conjunto.

Cada um dos cinco avaliadores participou do experimento mencionado nesta seção, porém, além das etapas regulares, os avaliadores também foram solicitados a indicar se o trailer em questão evocava uma resposta emocional apropriada para o gênero do filme. De acordo com nossa pesquisa, os cinco avaliadores consideraram que 14 dos 21 trailers provocavam uma resposta emocional adequada. Dos sete *trailers* restantes, cinco foram


<sup>1</sup> <<https://tinyurl.com/4suns93>>

Título	Categorias	Duração (mm:ss)	Ano de lançamento
Doutor Estranho no Multiverso da Loucura	Ação	02:29	2022
Lightyear	Ação	02:16	2022
Me Tira da Mira	Ação	02:33	2022
Neymar: O Caos Perfeito	Histórico	02:25	2022
O Começo da Vida	Histórico	02:25	2016
Os Segredos de Saqara	Histórico	02:25	2020
DC Liga dos Super Pets	Comédia	02:05	2022
Gato de Botas 2: O Último Pedido	Comédia	02:22	2022
O Peso do Talento	Comédia	02:26	2022
Medida Provisória	Drama	02:14	2020
Predestinado	Drama	02:17	2022
Pureza	Drama	02:02	2019
Matrix Resurrections	Ficção Científica	02:29	2021
Moonfall	Ficção Científica	02:27	2022
Oxigênio	Ficção Científica	02:25	2021
A Última Carta de Amor	Romance	02:07	2021
Mesa Para Quatro	Romance	02:22	2022
O Último Paraíso	Romance	02:10	2021
A Médium	Terror	02:25	2021
Exorcismo Sagrado	Terror	02:11	2021
Rogai Por Nós	Terror	02:52	2021

**Tabela 3.1:** Lista de trailers de filmes selecionados para o experimento. Categorizamos 21 trailers em sete gêneros: ação, comédia, drama, história, terror, romance e ficção científica. A duração média dos trailers é de 2 minutos e 21 segundos.

considerados adequados por quatro avaliadores, enquanto um avaliador os considerou insuficientes. Por fim, os dois *trailers* restantes receberam respostas positivas de apenas três avaliadores. Como em todos os casos os *trailers* receberam *feedback* positivo da maioria, consideramos o conjunto de dados adequado para nosso experimento e prosseguimos com a coleta de dados.

### 3.3 Self-Assessment Manikin



**Figura 3.3:** Método SAM usado para medir às duas dimensões da emoção, Valence (painel superior) e Arousal (painel inferior)

Para quantizar os valores de valência e excitação empregaremos a técnica denominada *Self-Assessment Manikin* (SAM) (BRADLEY e LANG, 1994). SAM é um pequeno questionário de autorrelato para “quantificar” a valência e a excitação de um participante, usando imagens para transmitir a escala. Por ser não-verbal, o SAM é legível independentemente da idade, habilidade linguística ou fatores educacionais (BRADLEY e LANG, 1994).

A Figura 3.3 exibe as representações visuais empregadas no questionário. A escala para cada um dos eixos varia de 1 a 9. Na primeira linha, as imagens oscilam entre uma representação sorridente e feliz, atribuindo o valor 9, e uma figura carrancuda e descontente, associada ao valor 1. Esta pergunta visa avaliar a intensidade no eixo do prazer (Valence). Quanto à segunda linha, a imagem varia entre uma representação animada e de olhos arregalados, com valor 9, e uma figura relaxada e sonolenta, representando o valor 1. Aqui, busca-se avaliar a intensidade na dimensão da excitação (Arousal).

Para responder a este questionário, o participante deverá escolher um valor de 1 a 9 em cada uma das dimensões. Essa abordagem permitirá a identificação e quantificação da intensidade da emoção induzida por um estímulo específico.

### 3.4 Software para captura de sinais

Para a captura dos sinais cardíacos, construímos um *software* que conecta o computador com o sensor cardíaco Polar H10 via Bluetooth e armazena os dados. Desenvolvemos o programa utilizando a linguagem de programação Python.

A estrutura do programa é subdividida em dois módulos. O primeiro atua como coletor de dados, estabelecendo a comunicação com o dispositivo e recebendo os dados, além de organizá-los em um arquivo de saída. O segundo módulo é encarregado de interagir com o usuário.

A primeira função do coletor de dados é estabelecer uma conexão com o dispositivo por meio do Bluetooth, utilizando a biblioteca Bleak,<sup>2</sup> que oferece uma API assíncrona projetada para conectar-se a dispositivos BLE (Bluetooth Low Energy). Essa conexão é estabelecida através do endereço MAC exclusivo do dispositivo. Em termos simples, o computador envia um pacote endereçado ao dispositivo pelo seu endereço MAC, e o dispositivo responde a essa solicitação enviando um pacote para aceitar ou recusar a conexão com o computador.

Após a conexão ser estabelecida, iniciamos a captura dos sinais. O programa emite uma solicitação para que o dispositivo envie as leituras para o computador. O sensor cardíaco, em resposta, envia, a cada segundo ( $t$ ), as leituras de frequência cardíaca ( $HR$ ), os intervalos RR ( $RR$ ) e os valores do ECG ( $ECG$ ). No entanto, essas informações são recebidas no formato de um vetor de *bytes* e requerem conversão para valores inteiros.



**Figura 3.4:** Gráfico com valores de HR durante um minuto de leitura

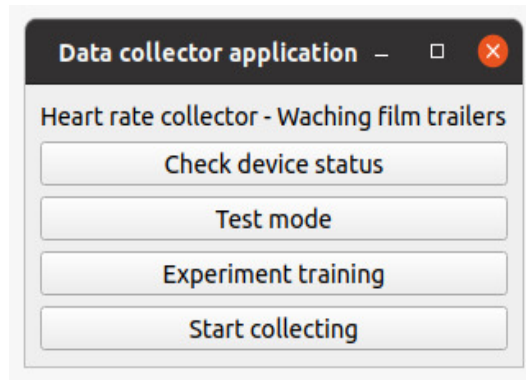
A Figura 3.4 ilustra um gráfico com os valores de frequência cardíaca obtidos durante uma execução. Nesse exemplo, a coleta de dados foi realizada por um minuto, embora seja possível controlar o tempo em que o dispositivo envia os sinais para o computador. Ao final da leitura, todas as triplas ( $t$ ,  $HR$ ,  $RR$ ) são armazenadas em um arquivo no formato csv, bem como os pares ( $t$ ,  $ECG$ ) em outro arquivo.

O segundo módulo, encarregado de interagir com o usuário, desenvolve uma interface gráfica que serve para fornecer instruções ao usuário e capturar as respostas dos questionários preenchidos pelos voluntários. A Figura 3.5 exibe a interface gráfica inicial, destinada ao controle por parte do aplicador do experimento. A primeira opção estabelece

<sup>2</sup> Disponível em: <<https://bleak.readthedocs.io/en/latest/>>. Acessado em: 27 nov. 2023.



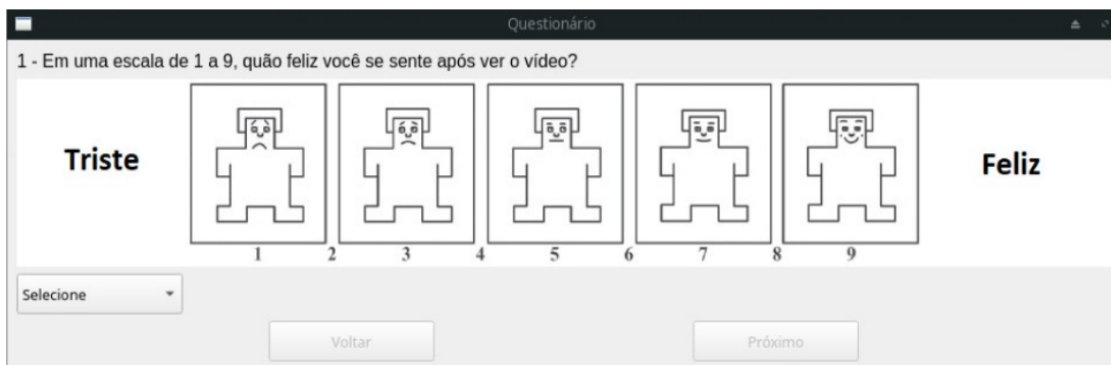
a conexão com o sensor e verifica o nível de carga de sua bateria. A segunda opção inicia a coleta de dados no modo teste, empregado para verificar a correta coleta de dados antes do início do experimento real. A terceira opção executa uma versão de treinamento do experimento, proporcionando familiaridade ao voluntário com o procedimento. Por fim, a última opção dá início à coleta de dados e ao experimento real.



**Figura 3.5:** Interface de seleção de funcionalidades

Por fim, implementamos a rotina que automatiza o experimento. Assim que o experimento é iniciado, a coleta de dados cardíacos é iniciada, e uma janela é exibida ao voluntário com o seguinte texto: “O experimento começará em 3 minutos. Tente relaxar.”. Quando faltam 30 segundos para o início do experimento, uma nova mensagem é apresentada: “O experimento começará em instantes. Aguarde 30 segundos.”. Após esse intervalo, a exibição dos *trailers* é iniciada.

Após a apresentação de um *trailer*, o voluntário encontra a janela ilustrada na Figura 3.6, que possibilita que ele responda ao questionário usando o mouse. O voluntário deve selecionar sua resposta por meio da caixa de seleção localizada na região inferior esquerda da janela. Após a seleção, o participante pode utilizar o botão “Próximo” para avançar para a próxima pergunta ou o botão “Voltar” para retornar à questão anterior. Uma vez que todas as perguntas são respondidas, a exibição dos *trailers* recomeça.



**Figura 3.6:** Interface do questionário

No decorrer do experimento, a tela do voluntário é gravada, assim como o rosto do participante é capturado por meio de uma webcam. Esses dados não foram utilizados nas

análises, mas sim para fins de controle. Caso ocorram anomalias nos dados capturados, essa gravação possibilitará a reprodução do experimento para investigar possíveis causas de erros. Além disso, o programa também salva um arquivo de *log*, que registra todos os cliques no mouse realizados pelo voluntário, juntamente com o respectivo horário de cada clique.

Ao fim de uma execução do experimento, o programa cria cinco arquivos, sendo eles:

- `raw_ecg.csv` - guarda os valores de ECG capturados durante a seção;
- `raw_rr.csv` - guarda os valores de frequência cardíaca e dos intervalos RR capturados durante a seção;
- `survey.csv` - guarda as respostas do voluntário aos questionários;
- `log.csv` - guarda o tempo e o local em que o clique foi realizado;
- `video.mp4` - vídeo com a gravação do experimento.

O código-fonte desse software pode ser encontrado gratuitamente no Github ([github.com/mmuramatsu/Heart-rate-collector](https://github.com/mmuramatsu/Heart-rate-collector)).

### 3.5 Aprendizado de máquina

Para a classificação dos dados, empregamos um algoritmo preditivo denominado Máquina de Vetores de Suporte, mais conhecido como SVM (*Support Vector Machine*). Antes de entrarmos nos detalhes desse método, é necessário compreender o processo pelo qual uma máquina aprende a distinguir dados e a fazer previsões com base neles, conhecido como aprendizado de máquina.

O processo de aprendizado de máquina guarda semelhanças com a maneira como os seres humanos fazem previsões com base nas experiências passadas. Zhi-Hua Zhou, em seu livro “Machine Learning” (ZHOU, 2020), oferece o seguinte exemplo: ao escolher uma melancia em uma barraca de frutas, optamos por uma melancia verde com raiz crespa e som abafado, pois aprendemos ao longo do tempo que tais características geralmente indicam que a melancia está madura. Da mesma forma, podemos esperar bons resultados acadêmicos após um semestre de estudos intensivos, pois nossa experiência nos ensinou que o esforço dedicado geralmente resulta em boas notas. Em resumo, nossa confiança em previsões é fundamentada na aprendizagem pela experiência e na tomada de decisões embasadas nessa aprendizagem.

Da mesma forma, as máquinas aprendem. O aprendizado de máquina é a técnica que aprimora o desempenho de um sistema com base na experiência por meio de métodos computacionais. Nos sistemas computacionais, a experiência se manifesta na forma de dados, e a principal missão do aprendizado de máquina é desenvolver algoritmos que construam modelos a partir desses dados. Ao alimentar o algoritmo de aprendizado com dados de experiência, conseguimos obter um modelo capaz de fazer previsões.

O processo de treinamento ocorre quando o algoritmo é exposto a um conjunto de dados, e a partir das características observadas, começa a identificar padrões ou relações. Assim, quanto mais diversos e representativos forem os dados de treinamento, melhor o algoritmo poderá generalizar para dados novos que ainda não foram apresentados a ele.

Segundo [ZHOU, 2020](#), duas ferramentas essenciais no aprendizado são a indução e a dedução. A indução é o processo da especialização à generalização, ou seja, resumir observações específicas a regras generalizadas. Por outro lado, a dedução é o processo da generalização à especialização, derivando casos específicos de princípios básicos. Podemos conceber o aprendizado de máquina como uma busca no espaço de hipóteses por uma hipótese que seja consistente com o conjunto de treinamento, em nosso exemplo, desejamos aquela que consiga classificar corretamente todas as melancias do conjunto de treinamento.

Definimos classes como categorias que designam a qual grupo uma instância observada pertence no conjunto de dados. Tomando o exemplo das melancias, as duas classes existentes seriam “madura” e “não madura”. Dessa forma, a classe corresponderia ao rótulo atribuído a uma dada instância pelo algoritmo de classificação.

No campo do aprendizado de máquina, é prática comum dividir o conjunto de dados em duas partes disjuntas: treino e teste. Os dados de treino são utilizados para treinar o modelo, conforme explicado anteriormente. Já os dados de teste, que não foram previamente vistos pelo modelo, são empregados para avaliar a eficácia da hipótese desenvolvida pelo modelo na separação dos dados. É comum em aprendizado de máquina alocar 80% dos dados para treino e 20% para teste ([BAUDER e KHOSHGOFTAAR, 2017](#)) ou separar os dados em 70% treino e 30% teste ([SHEN et al., 2021](#)).

### 3.5.1 Máquina de vetores de suporte


Usamos o algoritmo de aprendizado de máquina conhecido como SVM, que é um algoritmo de aprendizado supervisionado. Esse tipo de algoritmo utiliza um conjunto de dados rotulado, onde as classes de cada instância observada são conhecidas, para o treinamento. A concepção do SVM foi apresentada por [VAPNIK, 1995](#). De modo bem simples, a ideia do algoritmo é encontrar um hiperplano que consiga separar os dados em diferentes grupos.

Existes infinitos hiperplanos capazes de dividir os dados, no entanto, o objetivo do SVM é encontrar aquele que maximiza a distância entre o hiperplano e os pontos mais próximos de cada classe. Tal distância é chamada de margem e os pontos de vetores de suporte. Então, a ideia do algoritmo é encontrar os vetores de suporte que maximizem a margem, dessa forma os dados estarão divididos em diferentes classes.

A Figura 3.7 ilustra um conjunto de dados que possui instâncias de duas classes, representadas pelos símbolos + e -. Nesta figura, também está representado o hiperplano, H, que melhor separa os dados, representado pela linha contínua. Ao redor do hiperplano, representada pela distância entre as linhas pontilhadas, está a margem, M, a qual passa pelos vetores de suporte de cada uma das classes, sendo tais pontos representados pelas cores vermelho, para a classe + e azul para a classe -.

No caso deste exemplo, se quisermos separar tais dados, uma reta será suficiente para tal. Dessa forma, usando a equação da reta, temos que

$$X_2 = aX_1 + b \rightarrow aX_1 - X_2 + b = 0.$$



**Figura 3.7:** Ilustração de um conjunto de dados com duas classes, representados pelos símbolos + e -. Os pontos ilustrados nas cores azul e vermelho representam os vetores de suporte de cada uma das classes. A reta contínua ilustra o hiperplano  $H$  ideal para separar os dados e as retas pontilhadas a margem  $M$ .

Se definirmos  $x = (X_1, X_2)$  e  $w = (a, -1)$ , então, a equação da reta será,

$$w \cdot x + b = 0.$$

É importante destacar que esta equação é derivada de vetores bidimensionais. Mas, na verdade, também funciona para qualquer número de dimensões. Esta é a equação do hiperplano. Para encontrarmos os valores de  $w$  e  $b$  que satisfaçam o problema ilustrado na Figura 3.7, precisamos adicionar algumas restrições ao nosso problema, primeiro, vamos definir uma regra de decisão, sendo  $x_+$  um elemento da classe representada pelo símbolo + e  $x_-$  um elemento da classe -, nossa restrição será:


$$\begin{cases} w \cdot x_+ + b \geq 1 \\ w \cdot x_- + b \leq -1 \end{cases} \quad (3.1)$$

Para tornar as contas mais convenientes, introduziremos uma nova variável,  $y_i$  tal que  $y_i = 1$  para elementos da classe + e  $y_i = -1$  para elementos da classe -. Multiplicando  $y_i$  em (3.1) obtemos duas inequações iguais, sendo ela:

$$y_i(w \cdot x_i + b) - 1 \geq 0. \quad (3.2)$$

Nesse caso, a segunda restrição que iremos definir é que para todo ponto que estiver na margem o resultado de (3.2) será igual a zero, ou seja:

$$y_i(w \cdot x_i + b) - 1 = 0. \quad (3.3)$$



**Figura 3.8:** Representação dos vetores de suporte  $x_+$  e  $x_-$ , representantes das classes  $+$  e  $-$ , respectivamente. Em rosa, é apresentado o vetor resultante da subtração dos vetores de suporte.

Como o objetivo do SVM é encontrar a configuração que separe as duas classes na maior distância possível, precisamos definir a largura da margem. A Figura 3.8, apresenta os vetores de suporte  $x_+$  e  $x_-$ . A subtração desses dois vetores, representado em rosa, multiplicado pelo vetor normal unitário nos dá a largura da margem. Sabemos que, por definição,  $w$  é o vetor normal do hiperplano, então basta dividir  $w$  pela sua norma para torná-lo unitário. Então, podemos definir a largura,  $\gamma$ , como:

$$\gamma = (x_+ - x_-) \cdot \frac{w}{\|w\|}. \quad (3.4)$$

Utilizando a equação (3.3), a qual é restrita aos pontos pertencentes à margem, sendo o caso dos valores em (3.4), podemos reescrever (3.4) da seguinte forma:

$$\gamma = \frac{2}{\|w\|}. \quad (3.5)$$

Como estamos interessando na maior distância possível, nosso objetivo é maximizar  $\gamma$ .

$$\max \frac{2}{\|w\|}. \quad (3.6)$$

Para tornar (3.6) mais conveniente, podemos realizar algumas modificações nessa expressão. Primeiro, removeremos a constante da operação de maximização, em seguida, podemos dizer que maximizar  $\gamma$  é o mesmo que minimizar a norma de  $w$ . Por fim, dividiremos a norma de  $w$  por 2 e o elevaremos ao quadrado. Este último passo será importante nos próximos passos.

$$\max \frac{1}{\|w\|} \rightarrow \min \|w\| \rightarrow \min \frac{1}{2} \|w\|^2. \quad (3.7)$$

Nesta etapa, nosso objetivo é encontrar o extremo de uma função com restrições, nesse caso, a melhor forma de resolver esse problema, é usando multiplicadores de Lagrange, o qual irá gerar uma nova expressão que podemos minimizar sem se preocupar com as restrições.

Vamos chamar de  $L$ , o que queremos minimizar e usando Lagrange, iremos adicionar as restrições na equação as quais estarão associadas a um multiplicador de Lagrange  $\alpha_i$ . A restrição que iremos adicionar é a apresentada pela equação (3.3), que define que todo ponto pertencente a margem será igual a zero em nossa regra de decisão. Então,  $L$  é:

$$L = \frac{1}{2} \|w\|^2 - \sum_i \alpha_i [y_i(w \cdot x_i + b) - 1]. \quad (3.8)$$

A partir disso, é possível chegar a uma expressão em que conseguimos calcular  $w$ , sendo necessário calcular o diferencial de  $L$  em relação a  $w$  e igualá-lo a zero. Sendo assim:

$$\frac{\delta L}{\delta w} = w - \sum_i \alpha_i y_i x_i = 0 \rightarrow w = \sum_i \alpha_i y_i x_i. \quad (3.9)$$

É importante notar que o resultado obtido em (3.9) mostra que  $w$  é igual a uma soma linear de alguns vetores  $x_i$ , pois em alguns casos  $\alpha_i$  será zero.

Podemos também, diferenciar  $L$  em relação a  $b$  para chegarmos a um resultado importante que irá auxiliar a simplificar nosso problema de otimização.

$$\frac{\delta L}{\delta b} = \sum_i \alpha_i y_i = 0 \rightarrow \sum_i \alpha_i y_i = 0. \quad (3.10)$$

Com os resultados de (3.9) e (3.10), iremos substituir em (3.8) a fim de encontrar quais são as dependências da expressão para se calcular  $L$ . Fazendo tal substituição, temos que:

$$\begin{aligned} L &= \frac{1}{2} \left( \sum_i \alpha_i y_i x_i \right) \cdot \left( \sum_j \alpha_j y_j x_j \right) - \left( \sum_i \alpha_i y_i x_i \right) \cdot \left( \sum_j \alpha_j y_j x_j \right) - \sum_i \alpha_i y_i b + \sum_i \alpha_i \\ &= \sum_i \alpha_i - \frac{1}{2} \sum_i \sum_j \alpha_i \alpha_j y_i y_j x_i \cdot x_j. \end{aligned} \quad (3.11)$$

A partir de (3.11), podemos dizer que nosso problema de otimização depende apenas do produto escalar de pares de amostras.

Para calcularmos o valor de  $b$ , podemos retomar a equação (3.3) e fazer algumas manipulações para chegar a um resultado melhor. Multiplicando ambos os lados por  $y_i$  e sabendo que  $y_i^2 = 1$ , nos temos:

$$b = y_i - w \cdot x_i.$$

Sendo  $S$  o número de vetores de suporte, então  $b$  será:

$$b = \frac{1}{S} \sum_i^S (y_i - w \cdot x_i) \quad (3.12)$$

Novamente, vemos que  $b$  também depende apenas das amostras para ser calculado.

Neste ponto, temos como calcular o hiperplano ótimo a partir dos dados que forem fornecidos, dessa forma, podemos definir nossa hipótese para realizar previsões, que se baseia na nossa regra de decisão, descrita em (3.1). Então, nossa hipótese  $h$  será definida como:

$$h(x) = \begin{cases} 1 & \text{se } w \cdot x + b \geq 1 \\ -1 & \text{se } w \cdot x + b \leq -1 \end{cases} \quad (3.13)$$

Resumidamente, calculamos  $w$  e  $b$  utilizando os dados de treino, assim, encontrando o hiperplano ótimo que separa nossos dados, e usaremos a nossa hipótese  $h$  para realizar as previsões nos dados de teste.

O cenário ideal seria conseguir separar os dados perfeitamente utilizando essa estratégia. No entanto, dados reais podem apresentar pontos fora da curva, conhecidos como *outliers* e ruídos que dificultam a separação. Para isso, o SVM adiciona uma função de custo associada a classificação incorreta de pontos. Então o algoritmo deverá lidar com dois problemas de otimização, minimizar o erro de classificação e maximizar a margem.

Até o momento, discutimos apenas o SVM linear, no entanto, a partir da equação (3.11) surge a ideia de tornar o SVM um classificador não linear aplicando um truque de Kernel (BOSER *et al.*, 1992). Sabendo que para otimizar  $L$ , essencialmente dependemos apenas do produto escalar de  $x_i$  e  $x_j$ , então, podemos reescrever tal produto como uma função de Kernel não linear, ficando:

$$L = \sum_i \alpha_i - \frac{1}{2} \sum_i \sum_j \alpha_i \alpha_j y_i y_j K(x_i, x_j). \quad (3.14)$$

Esse método é usado quando os dados não são linearmente separáveis no espaço de entrada original. Ao aplicarmos a função de Kernel, alteramos o espaço original dos dados e tentamos encontrar um hiperplano capaz de separá-los nesse novo espaço de dimensão maior. O objetivo é tornar um problema não separável em um problema separável. Para classificar nossos dados usamos o Kernel Gaussiano, também conhecido como RBF dado pela seguinte equação:

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right)$$

em que  $\sigma > 0$  é a largura do Kernel Gaussiano.


### 3.5.2 Validação cruzada

O algoritmo SVM utilizado é fornecido pela biblioteca Scikit-learn.<sup>3</sup> Essa biblioteca oferece diversas opções de modificação nos parâmetros do algoritmo, permitindo otimizá-lo para tarefas específicas. Alterações específicas nos parâmetros podem influenciar ligeiramente os resultados da classificação.

Visando identificar os melhores parâmetros para a nossa classificação, adotaremos a técnica conhecida como validação cruzada, em particular, o método *K-fold*, também denominado *K-fold cross-validation*. A validação cruzada representa um dos métodos de amostragem de dados mais amplamente empregados para estimar o verdadeiro erro de previsão dos modelos e ajustar seus parâmetros (BERRAR, 2018).

O procedimento compreende a divisão do conjunto de dados em  $k$  conjuntos disjuntos ou *folds*, cada um com o mesmo tamanho. O modelo é então treinado e testado  $k$  vezes, em que a cada iteração, um *fold* diferente atua como o conjunto de teste, também referido nesta etapa como conjunto de validação, enquanto os  $k - 1$  *folds* remanescentes constituem o conjunto de treinamento.

A Figura 3.9 ilustra o processo de separação dos dados em cada etapa. Esse método assegura que o modelo seja exposto a diversas instâncias de dados para treinamento e teste, promovendo uma avaliação abrangente de seu desempenho.



**Figura 3.9:** Processo de separação dos conjuntos no método de validação cruzada *k-fold*.

Uma das principais vantagens da validação cruzada *k-fold* é a mitigação de problemas associados à variabilidade e aleatoriedade do conjunto de dados. Ao realizar divisões repetidas, a avaliação torna-se menos dependente de uma divisão aleatória específica, resultando em uma estimativa mais confiável da capacidade de generalização do modelo. Além disso, essa abordagem auxilia na identificação de problemas potenciais, como sobreajuste ou subajuste, ao avaliar o desempenho do modelo em diferentes subconjuntos de dados.

Para avaliar o modelo, empregamos a métrica conhecida como acurácia. A acurácia é calculada como a razão entre o número de previsões corretas e o total de previsões realizadas na fase de teste do modelo. Em cada execução, obtém-se um valor de acurácia, e o resultado final da validação cruzada é a média dessas previsões nos conjuntos de validação.

<sup>3</sup> Disponível em: <<https://scikit-learn.org/stable/index.html>>

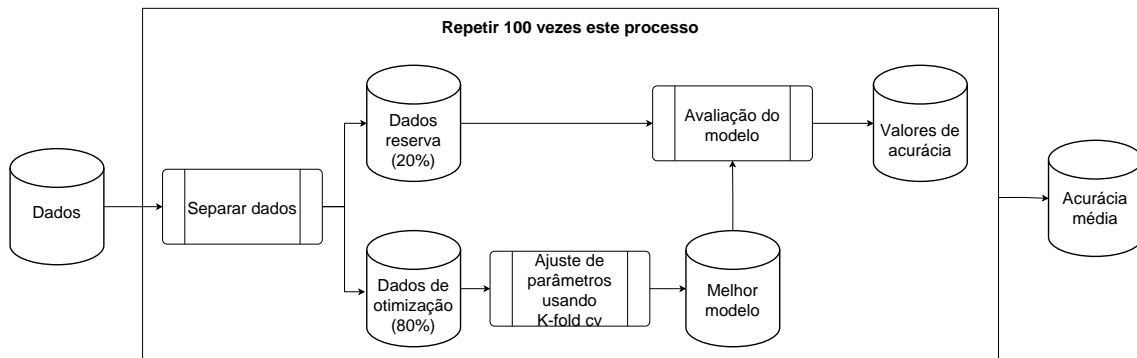


Utilizamos essa abordagem para ajustar os parâmetros do SVM e identificar a combinação mais eficaz que resultasse no melhor modelo preditivo para nossos dados. A fim de determinar tal modelo, usamos uma técnica chamada de *hold-out* a qual consiste em separar um subconjunto de dados especialmente para validação, ou seja, tais dados não serão vistos pelo modelo na etapa de treino e serão usados para testar o modelo. Dessa forma conseguiremos comparar os modelos otimizados a partir da validação cruzada, a fim de encontrar aquele que melhor classifica nossos dados.

É importante destacar que existem outras formas de realizar a seleção do melhor modelo, porém, de acordo com [YADAV e SHUKLA, 2016](#), tais abordagens exigem um conjunto de dados grande para se tornarem mais eficientes. Segundo o autor, em conjuntos de dados pequenos, como o nosso, o ideal é utilizar uma abordagem usando validação cruzada k-fold.

### 3.6 Classificação de dados

Usamos o SVM com kernel Gaussiano como é sugerido por [D. PARK et al., 2018](#) para classificação de ECG. Dicotomizamos a probabilidade de um participante assistir ao filme em “assistir” e “não assistir” usando o limite de 50%. Ou seja, consideramos que o participante assistirá ao filme se a probabilidade anotada pelo participante for superior a 50%.



**Figura 3.10:** Procedimento de classificação. Começamos separando os dados em dois grupos (80% e 20% do total). Ajustamos os hiperparâmetros usando K-fold cross-validation e testamos no conjunto que removemos inicialmente. Repetimos este procedimento 100 vezes e calculamos a precisão média do nosso classificador.

Nosso procedimento começa removendo aleatoriamente 20% dos dados e mantendo-os como um conjunto de dados de retenção (Figura 3.10). Iremos usá-lo mais tarde para avaliação estatística. Em seguida, realizamos uma validação cruzada de 10 subconjuntos (*fold*) no conjunto de dados restante para ajustar os hiperparâmetros do SVM. Por fim, avaliamos o SVM com os hiperparâmetros ajustados no conjunto de dados de 20% que removemos inicialmente. Observe que essa abordagem evita *overfitting*. Repetimos esse procedimento 100 vezes e calculamos a precisão média do nosso classificador.

## 3.7 Análise estatística

Utilizamos o teste  $t$  pareado para comparar as precisões obtidas pelo SVM e utilizando diferentes preditores: questionário, Emoção, HRV e a combinação de Emoção e HRV. Assumimos um ponto de corte do valor  $p$  de 0.05 para significância estatística.

Utilizamos a correlação de Pearson para calcular a associação entre HRV e Emoção (valência e excitação). Combinamos os valores de  $p$  (meta-análise) utilizando o método de Fisher.

### 3.7.1 Método de Fisher

O método de Fisher (FISHER, 1925; BROWN, 1975; WHITLOCK, 2005) é uma técnica estatística usada para mesclar os resultados de vários testes estatísticos independentes em uma estatística de teste geral. O objetivo é avaliar se a evidência combinada destes testes fornece suporte significativo para uma hipótese específica.

No método de Fisher, os valores de  $p$  individuais/independentes ( $p_1, p_2, \dots, p_k$ ) são combinados usando o teste estatístico de chi-quadrados usando a fórmula:

$$\chi_F^2 = -2 \sum_{i=1}^k \ln p_i$$

se todas as hipóteses nulas dos testes  $k$  forem verdadeiras, então  $\chi_F^2$  terá uma distribuição  $\chi^2$  com  $2k$  graus de liberdade.

Se o valor combinado for menor que o nível de significância escolhido, que em nosso caso foi 0.05, sugere que a evidência combinada dos valores  $p$  individuais fornece suporte significativo para rejeitar a hipótese nula.

O principal objetivo desse método é tornar um teste composto em um teste da significância do agregado de uma série de testes independentes. O método de Fisher é amplamente utilizado em metanálises e oferece uma abordagem para integrar valores- $p$  de diferentes estudos ou testes em uma avaliação abrangente de significância estatística.


## Capítulo 4

# Resultados e discussões

Queremos testar a hipótese de que a HRV é um bom preditor para escolhas do Sistema 1. Para testar essa hipótese, elaboramos um experimento em que cada participante assistia ao trailer de um filme e deveria decidir se assistiria ao filme. Utilizamos dois outros preditores naturais para comparação: as preferências de gênero dos participantes e a Emoção (valência e excitação). A preferência de gênero é um recurso bastante utilizado para sugerir filmes. O estudo da Emoção na tomada de decisões aumentou desde o início do século XXI (LERNER *et al.*, 2014) e foram citados alguns exemplos na seção 2.5.

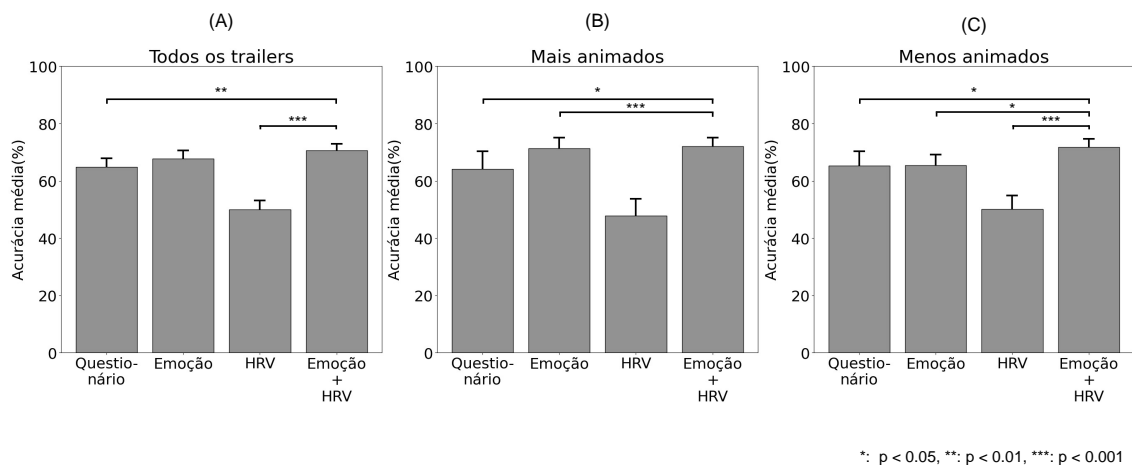
Primeiro, aplicamos o SVM, considerando todo o conjunto de dados. Em outras palavras, embaralhamos os dados e usamos 80% para treinamento e 20% como reserva (Figura 3.10). Usamos o questionário, o HRV, a Emoção e a combinação de Emoção e HRV como preditores. Os classificadores baseados no questionário, na Emoção, no HRV e na combinação de Emoção e HRV obtiveram precisões médias de 63, 71, 54 e 73%, respectivamente (Figura 4.1A). Além disso, analisamos uma condição que imita o mundo real. Treinamos o SVM usando um conjunto de pessoas (80% dos participantes) e testamos se outro conjunto (20% dos participantes - *hold-out*) assistiria ao filme. Os resultados foram muito semelhantes aos anteriores. Para a classificação usando a pesquisa, a emoção, o HRV e a combinação de emoção e HRV como preditores, obtivemos precisões médias de 64, 67, 49 e 70%, respectivamente (Figura 4.2A). Portanto, mesmo que treinássemos o classificador usando um grupo de pessoas e testássemos em outro grupo, poderíamos classificar aproximadamente 70% dos trailers com base na combinação de Emoção e HRV. Em outras palavras, nosso classificador apresentou boa precisão mesmo em um cenário mais realista no qual não usamos as informações de um indivíduo para treinar o modelo.

A precisão do questionário em ambos os experimentos foi significativamente superior a 50% (precisão de 63 e 64%). Esperávamos esse resultado porque é uma das abordagens mais utilizadas para prever que tipo de filme se deseja assistir. O classificador baseado em Emoção também apresentou bom desempenho (precisão de 71 e 67%). Como mencionado acima, a Emoção influencia fortemente a tomada de decisões (KAHNEMAN, 2003). O HRV isoladamente apresentou desempenho ruim (54 e 49%) e foi semelhante a uma classificação aleatória, ou seja, 50% de acerto. FOOKEN e SCHAFFNER, 2016 relataram resultado semelhante na tomada de decisão sob risco e dilema. Eles não encontraram evidências de que o



**Figura 4.1:** (A) As precisões médias obtidas pelo SVM considerando todo o conjunto de dados. (B) A precisão média obtida pelo SVM considerando os trailers mais animados. (C) A precisão média obtida pelo SVM considerando os trailers menos animados. As barras de erro indicam os intervalos de confiança de 95%.


HRV por si só esteja relacionado à tomada de decisões. No entanto, as Figuras 4.1A e 4.2A mostram que a combinação de Emoção e HRV é útil para a previsão da tomada de decisões. Observe que a precisão da classificação baseada em Emoção e HRV é significativamente maior (precisão de 73 e 70%) do que quando usamos apenas Emoção (precisão de 71 e 67%). Estes resultados sugerem que os efeitos do HRV não são aditivos, mas interativos. Ou seja, o HRV só está associado à tomada de decisão quando interage com a Emoção. Também avaliamos a possibilidade de efeito de gênero nesses resultados. Não encontramos efeitos de gênero na previsão da tomada de decisões em nossa configuração experimental (as precisões de classificação foram as mesmas quando analisamos apenas homens ou mulheres).



**Figura 4.2:** (A) As precisões médias obtidas pelo SVM considerando 80% dos participantes como treinamento e 20% como reserva. (B) A precisão média obtida pelo SVM considerando os trailers mais animados. (C) A precisão média obtida pelo SVM considerando os trailers menos animados.

Em seguida, analisamos a associação entre Emoção e HRV. A Figura 4.3 apresenta

as relações entre HRV com valência e excitação para cada um dos 20 indivíduos. Os coeficientes médios de correlação de Pearson entre HRV e valência e HRV e excitação são 0.0008 (valor  $p$  combinado usando o método de Fisher = 0.107) e  $-0.0486$  (valor  $p$  combinado usando o método de Fisher = 0.559), respectivamente. Em outras palavras, particularmente no nosso caso, não existe uma correlação significativa entre HRV e Emoção. Esta falta de correlação apoia a ideia de que o HRV transporta informação ortogonal à Emoção, aumentando a classificação quando interage com a Emoção.



**Figura 4.3:** (A) Correlação entre o HRV e a Valência ( $\rho = 0.0008$ ,  $p$ -valor = 0.107). (B) Correlação entre HRV e excitação ( $\rho = -0.0486$ ,  $p$ -valor = 0.559). As linhas cinzas representam a correlação para cada indivíduo. A linha preta representa a correlação média.

Curiosamente, existem alguns relatos que indicam a associação entre Emoção e HRV. [QUINTANA et al., 2012](#) mostraram que o HRV se correlaciona positivamente com o desempenho em uma tarefa de reconhecimento de emoções. [CHOI et al., 2017](#) mostraram que o HRV reflete a emoção humana apenas quando a estimulação é intensa. Finalmente, [MATHER e THAYER, 2018](#) mencionaram que indivíduos com alto HRV apresentam melhor bem-estar emocional do que aqueles com baixo HRV. Particularmente para a nossa configuração experimental, encontramos esta relação.

Para entender melhor em quais casos nosso classificador baseado em Emoção e HRV é melhor que os demais, dividimos os dados em vídeos mais e menos animados. Para realizar essa separação, nos baseamos no artigo publicado na Forbes,<sup>1</sup> que utilizamos para selecionar os gêneros dos trailers. De acordo com esse artigo, classificamos como mais animados aqueles trailers cuja descrição evidenciava a presença de cenas com alta intensidade de ação e energia, caracterizados principalmente por sequências rápidas e elementos visuais vibrantes, com o objetivo de manter o público constantemente engajado e em um estado de alta excitação. Consideramos como mais animados os trailers de filmes de Ação, Comédia, Terror e Ficção Científica. Por outro lado, os trailers menos animados possuem um ritmo mais lento, com uma abordagem mais contemplativa e introspectiva, focando no desenvolvimento de personagens e em narrativas profundas e emocionais. Consideramos como menos animados os trailers de filmes de Drama, Histórico e Romance.

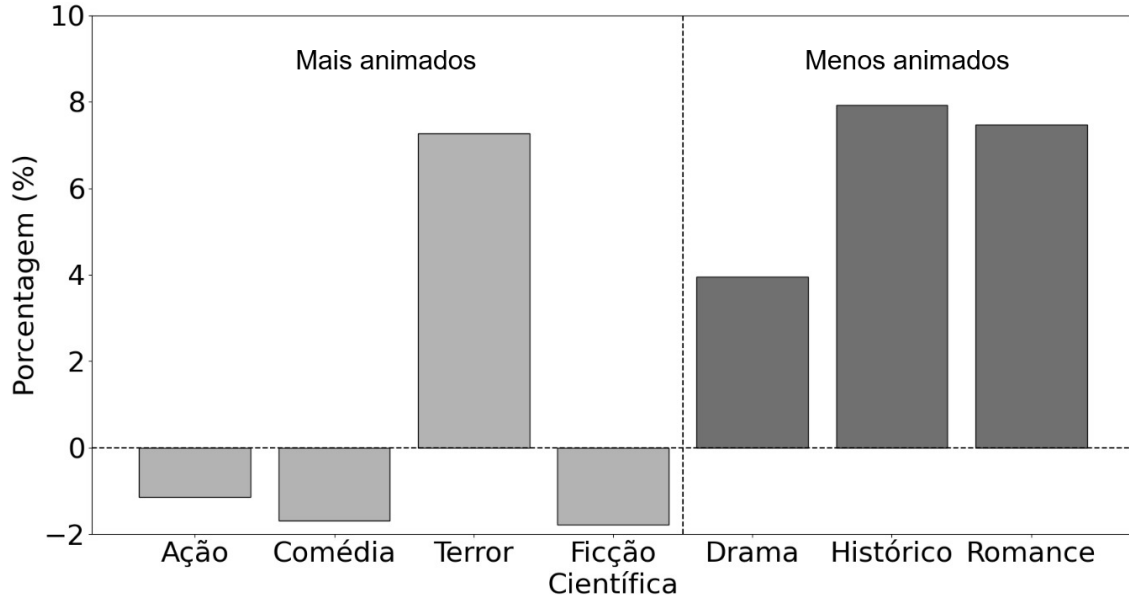
Considerando os *trailers* mais animados, o classificador baseado em Emoção (precisão de 73 e 71%) e a combinação de Emoção e HRV (precisão de 73 e 72%) obteve maiores precisões do que os classificadores baseados no questionário (precisão de 62 e 64%) ou apenas na HRV (precisão de 51 e 47%) (Figuras 4.1B e 4.2B). Não houve diferença estatística

<sup>1</sup> <https://tinyurl.com/4suns93>

entre usar apenas Emoção ou a combinação de Emoção e HRV. Em contrapartida, considerando os *trailers* menos animados, o classificador baseado na combinação de Emoção e HRV (precisão de 73 e 71%) obteve a maior precisão (Figuras 4.1C e 4.2C). Este resultado significa que o HRV ajuda a classificar *trailers* menos animados.

Além disso, esse resultado corrobora nossa ideia de que a emoção não está associada ao HRV (pelo menos em nosso experimento). Suponhamos que a emoção e o HRV estejam associados uma à outra. Nesse caso, o HRV não deveria aumentar a precisão de vídeos menos animados que podem apresentar menor excitação.

Em seguida, queríamos entender melhor quais tipos de filmes o HRV poderia acrescentar informações para melhorar a precisão da classificação. Para isso, calculamos a porcentagem de previsões corretas por gênero obtidas usando a combinação de Emoção e HRV, e subtraímos da porcentagem de previsões corretas obtidas usando apenas Emoção (Figura 4.4). Observe que, para os *trailers* menos animados, o classificador baseado em Emoção e HRV foi aproximadamente 7,47% melhor, em média, do que o classificador baseado somente em Emoção. Para os *trailers* mais animados, o classificador baseado em Emoção e HRV foi aproximadamente 1,69% pior, em média, do que o classificador baseado em Emoção para *trailers* de ação (1,15%), comédia (1,69%) e ficção científica (1,78%). Entretanto, o classificador baseado em Emoção e HRV foi 7,27% melhor do que o classificador baseado em Emoção para *trailers* de terror. Assim, embora os *trailers* mais animados pareçam estar mais associados a emoções mais intensas, nossos resultados mostram que o HRV é útil apenas para filmes de terror.



**Figura 4.4:** Porcentagem de previsões corretas por gênero obtidas usando a combinação de Emotion e HRV subtraídas da porcentagem de previsões corretas obtidas usando apenas Emotion.

Considerando esses resultados, sugerimos que as informações fisiológicas do corpo são úteis para a previsão da tomada de decisões, assim como foi mostrado no capítulo 1, em que apresentamos trabalhos que ilustram esse fato. De acordo com nossos resultados, mostramos uma situação em que sinais fisiológicos como HRV e emoção estão associadas à tomada de decisão.

Todo o conjunto de dados usado neste estudo está disponível gratuitamente no GitHub ([github.com/mmuramatsu/ChoicePrediction\\_data](https://github.com/mmuramatsu/ChoicePrediction_data)).





## Capítulo 5

### Limitações do estudo

Nesse capítulo, iremos listar algumas limitações do estudo que podem possivelmente ter influência nos resultados obtidos.

Em nosso experimento, nosso objetivo era avaliar a tomada de decisão dos participantes. No caso, eles deviam decidir se iriam ou não assistir ao filme após assistirem ao seu trailer de lançamento. No entanto, o participante não necessariamente assistirá ao filme mesmo que tenha indicado “sim” durante o experimento. Isso pode influenciar as respostas dos indivíduos, uma vez que o processo de tomada de decisão considera diversos fatores, como a avaliação entre resultado e consequência (Li *et al.*, 2020). Em nosso caso, isso se refere ao equilíbrio entre a quantidade de entretenimento proporcionada pelo filme e o tempo gasto para assisti-lo. Como os participantes não eram obrigados a assistir ao filme, esse tipo de análise pode não ter sido considerada, influenciando assim o resultado.

Outro fator que influencia diretamente as respostas dos participantes é a condição emocional inicial do indivíduo. Dependendo do humor do participante, ele poderá preferir um tipo de filme a outro, ou até mesmo optar por nenhum. Durante as seções de experimentos, não avaliamos o estado emocional inicial dos indivíduos. No entanto, se essa variável fosse considerada, adicionaríamos uma camada extra de complexidade aos resultados, podendo correlacionar gêneros de filmes, humor e HRV.

Existe também uma limitação inerente à regulação emocional no contexto de um experimento. Em outras palavras, a realização do experimento em um ambiente controlado e com isolamento de ruídos pode gerar um estado emocional diferente daquele que ocorreria, por exemplo, em uma sala de cinema, onde o indivíduo está com o objetivo de assistir a um filme. Para aplicarmos as ideias deste projeto em situações reais, seria interessante avaliarmos contextos mais “caóticos”, como em salas de cinema, para compreender melhor quais tipos de resultados seriam obtidos em condições reais.

Por fim, existem limitações inerentes ao método SAM. Sendo um método baseado no autorrelato dos participantes, há preocupações quanto à confiabilidade e validade dos valores obtidos, já que pode haver divergências na forma como cada participante avalia sua situação emocional ou até mesmo omissões por parte dos participantes. Uma alternativa seria utilizar algum método não invasivo capaz de quantificar as emoções do indivíduo,

como, por exemplo, a classificação de emoções através do HRV (CHOI *et al.*, 2017) ou baseada na expressão facial (GRIMM *et al.*, 2006; ARUMUGAM, 2011).

## Capítulo 6

### Conclusão

Neste estudo, exploramos a possibilidade de prever decisões usando o HRV. Embora a hipótese inicial não tenha sido completamente validada, já que a classificação exclusiva com os sinais cardíacos não produziu resultados expressivos, a análise revelou sua validade quando o HRV foi combinado com a emoção. Essa abordagem demonstrou resultados superiores aos obtidos a partir dos gostos pessoais do indivíduo, indicando uma influência das variações no HRV na tomada de decisão.

Outro resultado intrigante derivado de nossa análise diz respeito à interação entre o HRV e as emoções no contexto da tomada de decisões. Embora inicialmente não apresentem correlação direta, conforme evidenciado em nossa análise, a combinação desses elementos revela resultados significativos, especialmente em relação a filmes de terror e aqueles menos animados. Uma hipótese para esse fenômeno é a presença de um fator convergente entre as duas variáveis, orientando o classificador para uma resposta precisa. Em outras palavras, certos estímulos provocam respostas únicas no HRV e nas emoções, tornando-as distintas quando classificadas separadamente. No entanto, ao combiná-las, tornam-se indiscerníveis para o classificador. Embora a causa exata desse fenômeno não seja clara, planejamos explorar esse resultado em futuros trabalhos de pesquisa.

Um resultado indireto do nosso estudo é a potencial aplicabilidade em sistemas ou ambientes já existentes, como cinemas ou canais de streaming. Podemos monitorar facilmente o HRV usando um dispositivo vestível que mede ECG, o qual é não invasivo, de baixo custo e de configuração simples. Com a popularidade dos smartwatches e os avanços tecnológicos no ECG associados a eles, uma previsão de tomada de decisão semelhante à que fizemos aqui poderia servir para verificar a popularidade de um filme antes de seu lançamento, baseado nos resultados da análise do HRV durante a exibição de tais *trailers* em serviços de streaming de vídeo ou cinemas antes do filme principal. O gargalo para colocá-lo em prática é medir com precisão a emoção (excitação e valência). No nosso caso, foi autodeclarado.



## Referências

- [AÇAR *et al.* 2000] Burak AÇAR, Irina V. SAVELIEVA, Harry HEMINGWAY e Marek MALIK. “Automatic ectopic beat elimination in short-term heart rate variability measurement”. *Computer methods and programs in biomedicine* 63 2 (2000), pp. 123–31. URL: <https://api.semanticscholar.org/CorpusID:11949453> (citado na pg. 13).
- [ACHAR *et al.* 2016] Chethana ACHAR, Jane So, Nidhi AGRAWAL e Adam DUHACHEK. “What we feel and why we buy: the influence of emotions on consumer decision-making”. *Current Opinion in Psychology* 10 (fev. de 2016). DOI: [10.1016/j.copsyc.2016.01.009](https://doi.org/10.1016/j.copsyc.2016.01.009) (citado na pg. 14).
- [ARUMUGAM 2011] Devi ARUMUGAM. “Emotion classification using facial expression”. *International Journal of Advanced Computer Science and Applications* 2.7 (2011) (citado na pg. 40).
- [BAUDER e KHOSHGOFTAAR 2017] Richard A. BAUDER e Taghi M. KHOSHGOFTAAR. “Medicare fraud detection using machine learning methods”. In: *2017 16th IEEE International Conference on Machine Learning and Applications (ICMLA)*. 2017, pp. 858–865. DOI: [10.1109/ICMLA.2017.00-48](https://doi.org/10.1109/ICMLA.2017.00-48) (citado na pg. 25).
- [BAVEYE *et al.* 2015] Yoann BAVEYE, Emmanuel DELLANDRÉA, Christel CHAMARET e Liming CHEN. “Liris-accede: a video database for affective content analysis”. *IEEE Transactions on Affective Computing* 6.1 (2015), pp. 43–55. DOI: [10.1109/TAFFC.2015.2396531](https://doi.org/10.1109/TAFFC.2015.2396531) (citado na pg. 15).
- [BERRAR 2018] Daniel BERRAR. “Cross-validation”. In: jan. de 2018. ISBN: 9780128096338. DOI: [10.1016/B978-0-12-809633-8.20349-X](https://doi.org/10.1016/B978-0-12-809633-8.20349-X) (citado na pg. 30).
- [BOSER *et al.* 1992] Bernhard E. BOSER, Isabelle M. GUYON e Vladimir N. VAPNIK. “A training algorithm for optimal margin classifiers”. In: *Proceedings of the 5th Annual ACM Workshop on Computational Learning Theory*. 1992 (citado na pg. 29).
- [BRADLEY e LANG 1994] Margaret M. BRADLEY e Peter J. LANG. “Measuring emotion: the self-assessment manikin and the semantic differential”. *Journal of Behavior Therapy and Experimental Psychiatry* 25.1 (1994), pp. 49–59. ISSN: 0005-7916. DOI: [https://doi.org/10.1016/0005-7916\(94\)90063-9](https://doi.org/10.1016/0005-7916(94)90063-9). URL: <https://www.sciencedirect.com/science/article/pii/0005791694900639> (citado na pg. 21).

- [BROSCH *et al.* 2013] Tobias BROSCH, Klaus SCHERER, Didier GRANDJEAN e David SANDER. “The impact of emotion on perception, attention, memory, and decision-making”. *Swiss Medical Weekly* 143.1920 (mai. de 2013), w13786. DOI: [10.4414/smw.2013.13786](https://doi.org/10.4414/smw.2013.13786). URL: <https://smw.ch/index.php/smw/article/view/1687> (citado na pg. 14).
- [BROWN 1975] Morton B. BROWN. “400: a method for combining non-independent, one-sided tests of significance”. *Biometrics* 31.4 (1975). Accessed 5 Feb. 2024, pp. 987–992. DOI: [10.2307/2529826](https://doi.org/10.2307/2529826). URL: <https://doi.org/10.2307/2529826> (citado na pg. 32).
- [CHAIKEN 1980] Shelly CHAIKEN. “Heuristic versus systematic information processing and the use of source versus message cues in persuasion”. *Journal of Personality and Social Psychology* 39 (nov. de 1980), pp. 752–766. DOI: [10.1037/0022-3514.39.5.752](https://doi.org/10.1037/0022-3514.39.5.752) (citado na pg. 5).
- [CHEN e CHAIKEN 1999] Shelly CHEN e Shelly CHAIKEN. “The heuristic-systematic model in its broader context”. In: *Dual-process theories in social psychology*. Ed. por Shelly CHAIKEN e Yaacov TROPE. The Guilford Press, 1999, pp. 73–96 (citado na pg. 5).
- [CHOI *et al.* 2017] Kwang-Ho CHOI *et al.* “Is heart rate variability (hrv) an adequate tool for evaluating human emotions? - a focus on the use of the international affective picture system (iaps)”. *Psychiatry Research* 251 (2017), pp. 192–196. ISSN: 0165-1781. DOI: <https://doi.org/10.1016/j.psychres.2017.02.025>. URL: <https://www.sciencedirect.com/science/article/pii/S0165178116312550> (citado nas pgs. 35, 40).
- [CLIFFORD 2006] Gari D. CLIFFORD. “Ecg statistics, noise, artifacts, and missing data”. In: *Advanced Methods and Tools for ECG Data Analysis*. 2006 (citado na pg. 13).
- [CRAIG 2003] A. D. CRAIG. “Interoception: the sense of the physiological condition of the body”. *Current Opinion in Neurobiology* 13.4 (2003), pp. 500–505. ISSN: 0959-4388. DOI: [https://doi.org/10.1016/S0959-4388\(03\)00090-4](https://doi.org/10.1016/S0959-4388(03)00090-4). URL: <https://www.sciencedirect.com/science/article/pii/S0959438803000904> (citado nas pgs. 2, 10).
- [CRITCHLEY *et al.* 2013] Hugo D. CRITCHLEY, Jessica ECCLES e Sarah N. GARFINKEL. “Chapter 6 - interaction between cognition, emotion, and the autonomic nervous system”. In: *Autonomic Nervous System*. Ed. por Ruud M. BUIJS e Dick F. SWAAB. Vol. 117. Handbook of Clinical Neurology. Elsevier, 2013, pp. 59–77. DOI: <https://doi.org/10.1016/B978-0-444-53491-0.00006-7>. URL: <https://www.sciencedirect.com/science/article/pii/B9780444534910000067> (citado na pg. 9).
- [DAHIYA *et al.* 2004] Dilbag DAHIYA, Vinod KUMAR e S SAXENA. “Sampling frequency of the rr interval time series for spectral analysis of heart rate variability”. *Journal of medical engineering and technology* 28 (nov. de 2004), pp. 263–72. DOI: [10.1080/03091900410001662350](https://doi.org/10.1080/03091900410001662350) (citado na pg. 13).

- [DULLECK *et al.* 2011] Uwe DULLECK, Andrea RISTL, Markus SCHAFFNER e Benno TORGLER. “Heart rate variability, the autonomic nervous system, and neuroeconomic experiments”. *Journal of Neuroscience, Psychology, and Economics* 4.2 (2011), pp. 117–124. DOI: [10.1037/a0022245](https://doi.org/10.1037/a0022245). URL: <https://doi.org/10.1037/a0022245> (citado na pg. 9).
- [EDWARDS e PINNA 2020] Darren J. EDWARDS e Thomas PINNA. “A systematic review of associations between interoception, vagal tone, and emotional regulation: potential applications for mental health, wellbeing, psychological flexibility, and chronic conditions”. *Frontiers in Psychology* 11 (2020). ISSN: 1664-1078. DOI: [10.3389/fpsyg.2020.01792](https://doi.org/10.3389/fpsyg.2020.01792). URL: <https://www.frontiersin.org/journals/psychology/articles/10.3389/fpsyg.2020.01792> (citado na pg. 10).
- [EKMAN *et al.* 1987] Paul EKMAN *et al.* “Universals and cultural differences in the judgments of facial expressions of emotion”. *Journal of personality and social psychology* 53 (nov. de 1987), pp. 712–7. DOI: [10.1037/0022-3514.53.4.712](https://doi.org/10.1037/0022-3514.53.4.712) (citado na pg. 14).
- [FERNANDEZ 2017] Cledwyn FERNANDEZ. “The paradox of choice: why more is less”. *Vikalpa* 42.4 (2017), pp. 265–267. DOI: [10.1177/0256090917732442](https://doi.org/10.1177/0256090917732442). eprint: <https://doi.org/10.1177/0256090917732442>. URL: <https://doi.org/10.1177/0256090917732442> (citado na pg. 2).
- [FISHER 1925] Ronald A. FISHER. *Statistical Methods for Research Workers*. Edinburgh: Oliver e Boyd, 1925. ISBN: 0-05-002170-2 (citado na pg. 32).
- [FOOKEN e SCHAFFNER 2016] Jonas FOOKEN e Markus SCHAFFNER. “The role of psychological and physiological factors in decision making under risk and in a dilemma”. *Frontiers in Behavioral Neuroscience* 10 (2016). ISSN: 1662-5153. DOI: [10.3389/fnbeh.2016.00002](https://doi.org/10.3389/fnbeh.2016.00002). URL: <https://www.frontiersin.org/articles/10.3389/fnbeh.2016.00002> (citado na pg. 33).
- [FORTE *et al.* 2021] Giuseppe FORTE, Matteo MORELLI e Maria CASAGRANDE. “Heart rate variability and decision-making: autonomic responses in making decisions”. *Brain Sciences* 11 (fev. de 2021), p. 243. DOI: [10.3390/brainsci11020243](https://doi.org/10.3390/brainsci11020243) (citado na pg. 13).
- [GAMBLE *et al.* 2018] Katherine R. GAMBLE *et al.* “Different profiles of decision making and physiology under varying levels of stress in trained military personnel”. *International Journal of Psychophysiology* 131 (2018). *The Psychophysiology of Stress and Adaptation: Models, Pathways, and Implications*, pp. 73–80. ISSN: 0167-8760. DOI: <https://doi.org/10.1016/j.ijpsycho.2018.03.017>. URL: <https://www.sciencedirect.com/science/article/pii/S0167876018300023> (citado na pg. 3).

- [GIBBONS 2019] Christopher H. GIBBONS. “Chapter 27 - basics of autonomic nervous system function”. In: *Clinical Neurophysiology: Basis and Technical Aspects*. Ed. por Kerry H. LEVIN e Patrick CHAUVEL. Vol. 160. Handbook of Clinical Neurology. Elsevier, 2019, pp. 407–418. DOI: <https://doi.org/10.1016/B978-0-444-64032-1.00027-8>. URL: <https://www.sciencedirect.com/science/article/pii/B9780444640321000278> (citado na pg. 2).
- [GRIMM *et al.* 2006] Michael GRIMM, D. DASTIDAR e Kristian KROSCHEL. “Recognizing emotions in spontaneous facial expressions”. In: *Proceedings of the International Conference on Intelligent Systems and Computing (ISYC)*. 2006 (citado na pg. 40).
- [HEILMAN *et al.* 2016] Renata M. HEILMAN, Andrei C. MIU e Daniel HOUSER. “Emotion regulation and economic decision-making”. In: *Neuroeconomics*. Ed. por Martin REUTER e Christian MONTAG. Berlin, Heidelberg: Springer Berlin Heidelberg, 2016, pp. 113–131. ISBN: 978-3-642-35923-1. DOI: [10.1007/978-3-642-35923-1\\_7](https://doi.org/10.1007/978-3-642-35923-1_7). URL: [https://doi.org/10.1007/978-3-642-35923-1\\_7](https://doi.org/10.1007/978-3-642-35923-1_7) (citado na pg. 7).
- [HINSON *et al.* 2003] John HINSON, Tina JAMESON e Paul WHITNEY. “Impulsive decision making and working memory”. *Journal of experimental psychology. Learning, memory, and cognition* 29 (abr. de 2003), pp. 298–306. DOI: [10.1037/0278-7393.29.2.298](https://doi.org/10.1037/0278-7393.29.2.298) (citado na pg. 1).
- [JENSEN 2014] Charlotte Sun JENSEN. “Reduced narration, intensified emotion: the film trailer”. *Projections: The Journal for Movies and Mind* (jun. de 2014). DOI: [10.3167/proj.2014.080107](https://doi.org/10.3167/proj.2014.080107) (citado na pg. 16).
- [JUNGERMANN 2004] Helmut JUNGERMANN. “Encyclopedia of applied psychology”. In: ed. por Charles SPIELBERGER. Vol. 1. Elsevier Ltd, jan. de 2004. Cap. Decision Making, pp. 569–574 (citado na pg. 1).
- [KAHNEMAN 2003] Daniel KAHNEMAN. “A perspective on judgment and choice: mapping bounded rationality”. *The American psychologist* 58 (out. de 2003), pp. 697–720. DOI: [10.1037/0003-066X.58.9.697](https://doi.org/10.1037/0003-066X.58.9.697) (citado nas pgs. 1, 7, 33).
- [KAHNEMAN 2011] Daniel KAHNEMAN. *Thinking, Fast and Slow*. Farrar, Straus e Giroux, 2011 (citado nas pgs. 1, 6).
- [KAHNEMAN e TVERSKY 1979] Daniel KAHNEMAN e Amos TVERSKY. “Prospect theory: an analysis of decision under risk”. *Econometrica* 47.2 (1979), pp. 263–291 (citado na pg. 7).
- [KASSEM *et al.* 2017] Khaled KASSEM *et al.* “Diva: exploring the usage of pupil diameter to elicit valence and arousal”. In: *Proceedings of the 16th International Conference on Mobile and Ubiquitous Multimedia. MUM '17*. Stuttgart, Germany: Association for Computing Machinery, 2017, pp. 273–278. ISBN: 9781450353786. DOI: [10.1145/3152832.3152836](https://doi.org/10.1145/3152832.3152836). URL: <https://doi.org/10.1145/3152832.3152836> (citado na pg. 14).



- [KREIBIG 2010] Sylvia D. KREIBIG. “Autonomic nervous system activity in emotion: a review”. *Biological Psychology* 84.3 (2010). The biopsychology of emotion: Current theoretical and empirical perspectives, pp. 394–421. ISSN: 0301-0511. DOI: <https://doi.org/10.1016/j.biopsycho.2010.03.010>. URL: <https://www.sciencedirect.com/science/article/pii/S0301051110000827> (citado na pg. 9).
- [KUPERMAN *et al.* 2014] Victor KUPERMAN, Zachary ESTES, Marc BRYLSBAERT e Amy Beth WARRINER. “Emotion and language: valence and arousal affect word recognition”. *Journal of Experimental Psychology: General* 143.3 (2014), pp. 1065–1081. DOI: [10.1037/a0035669](https://doi.org/10.1037/a0035669) (citado na pg. 14).
- [LERNER *et al.* 2014] Jennifer LERNER, Ye LI, Piercarlo VALDESOLO e Karim KASSAM. “Emotion and decision making”. *Annual review of psychology* 66 (set. de 2014). DOI: [10.1146/annurev-psych-010213-115043](https://doi.org/10.1146/annurev-psych-010213-115043) (citado na pg. 33).
- [LI *et al.* 2020] Ning LI, Jincan HUANG, Yanghe FENG, Kuihua HUANG e Guangquan CHENG. “A review of naturalistic decision-making and its applications to the future military”. *IEEE Access* PP (fev. de 2020), pp. 1–1. DOI: [10.1109/ACCESS.2020.2974317](https://doi.org/10.1109/ACCESS.2020.2974317) (citado nas pgs. 1, 39).
- [LISCHKE *et al.* 2020] Alexander LISCHKE, Rike PAHNKE, Anett MAU-MOELLER e Matthias WEIPPERT. “Heart rate variability modulates interoceptive accuracy”. *Frontiers in Neuroscience* 14 (jan. de 2020). DOI: [10.3389/fnins.2020.612445](https://doi.org/10.3389/fnins.2020.612445). URL: <https://doi.org/10.3389/fnins.2020.612445> (citado na pg. 10).
- [MADONA *et al.* 2021] Putri MADONA, Rahmat Ilias BASTI e Muhammad Mahrus ZAIN. “Pqrst wave detection on ecg signals”. *Gaceta Sanitaria* 35 (2021). The 3rd International Nursing and Health Sciences Students and Health Care Professionals Conference (INHSP), S364–S369. ISSN: 0213-9111. DOI: <https://doi.org/10.1016/j.gaceta.2021.10.052>. URL: <https://www.sciencedirect.com/science/article/pii/S0213911121002466> (citado na pg. 11).
- [MAFFEI e ANGRILLI 2019] Antonio MAFFEI e Alessandro ANGRILLI. “E-MOVIE - Experimental MOVies for Induction of Emotions in neuroscience: An innovative film database with normative data and sex differences”. *PLoS One* 14.10 (2019) (citado na pg. 14).
- [MATHER e THAYER 2018] Mara MATHER e Julian F THAYER. “How heart rate variability affects emotion regulation brain networks”. *Current Opinion in Behavioral Sciences* 19 (2018). Emotion-cognition interactions, pp. 98–104. ISSN: 2352-1546. DOI: <https://doi.org/10.1016/j.cobeha.2017.12.017>. URL: <https://www.sciencedirect.com/science/article/pii/S2352154617300621> (citado na pg. 35).
- [McCORRY 2007] Laurie K. McCORRY. “Physiology of the autonomic nervous system”. *American Journal of Pharmaceutical Education* 71.4 (ago. de 2007), p. 78. DOI: [10.5688/aj710478](https://doi.org/10.5688/aj710478) (citado na pg. 8).

- [MICHAEL B. DEVLIN e CALLISON 2011] L. Todd Chambers MICHAEL B. DEVLIN e Coy CALLISON. “Targeting mood: using comedy or serious movie trailers”. *Journal of Broadcasting & Electronic Media* 55.4 (2011), pp. 581–595. DOI: [10.1080/08838151.2011.620668](https://doi.org/10.1080/08838151.2011.620668). eprint: <https://doi.org/10.1080/08838151.2011.620668>. URL: <https://doi.org/10.1080/08838151.2011.620668> (citado na pg. 16).
- [MOELLER *et al.* 2001] F. MOELLER, Ernest BARRATT, Donald DOUGHERTY, Joy SCHMITZ e Alan SWANN. “Psychiatric aspects of impulsivity”. *The American journal of psychiatry* 158 (dez. de 2001), pp. 1783–93. DOI: [10.1176/appi.ajp.158.11.1783](https://doi.org/10.1176/appi.ajp.158.11.1783) (citado na pg. 1).
- [NABIL e BEREKSI REGUIG 2015] Dib NABIL e F. BEREKSI REGUIG. “Ectopic beats detection and correction methods: a review”. *Biomedical Signal Processing and Control* 18 (2015), pp. 228–244. ISSN: 1746-8094. DOI: <https://doi.org/10.1016/j.bspc.2015.01.008>. URL: <https://www.sciencedirect.com/science/article/pii/S1746809415000105> (citado na pg. 12).
- [NOVAK e MRÁZOVÁ 2015] Andrej NOVAK e Mária MRÁZOVÁ. “The effect of physiological stressors on pilot’s decision making during unfavourable simulated conditions: an explorative study”. *INCAS BULLETIN* 7 (jun. de 2015), pp. 153–162. DOI: [10.13111/2066-8201.2015.7.2.16](https://doi.org/10.13111/2066-8201.2015.7.2.16) (citado na pg. 3).
- [NOWACKI *et al.* 2018] Jan NOWACKI *et al.* “Decision making in response to physiological and combined physiological and psychosocial stress”. *Behavioral Neuroscience* 133 (dez. de 2018). DOI: [10.1037/bne0000288](https://doi.org/10.1037/bne0000288) (citado na pg. 3).
- [D. PARK *et al.* 2018] Dajeong PARK, Miran LEE, Sunghee E. PARK, Joon-Kyung SEONG e Inchan YOUN. “Determination of optimal heart rate variability features based on svm-recursive feature elimination for cumulative stress monitoring using ecg sensor”. *Sensors* 18.7 (2018). ISSN: 1424-8220. DOI: [10.3390/s18072387](https://doi.org/10.3390/s18072387). URL: <https://www.mdpi.com/1424-8220/18/7/2387> (citado na pg. 31).
- [H. PARK *et al.* 2016] Hyeongdong PARK *et al.* “Transient modulations of neural responses to heartbeats covary with bodily self-consciousness”. *Journal of Neuroscience* 36 (ago. de 2016), pp. 8453–8460. DOI: [10.1523/JNEUROSCI.0311-16.2016](https://doi.org/10.1523/JNEUROSCI.0311-16.2016) (citado na pg. 2).
- [PÉREZ-RIERA *et al.* 2018] Andrés Ricardo PÉREZ-RIERA, Raimundo BARBOSA-BARROS, Rodrigo DAMINELLO-RAIMUNDO e Luiz Carlos de ABREU. “Main artifacts in electrocardiography”. *Annals of Noninvasive Electrocardiology* 23 (2018), e12494. DOI: [10.1111/anec.12494](https://doi.org/10.1111/anec.12494) (citado na pg. 13).

- [QUINTANA *et al.* 2012] Daniel S. QUINTANA, Adam J. GUASTELLA, Tim OUTHRED, Ian B. HICKIE e Andrew H. KEMP. “Heart rate variability is associated with emotion recognition: direct evidence for a relationship between the autonomic nervous system and social cognition”. *International Journal of Psychophysiology* 86.2 (2012), pp. 168–172. ISSN: 0167-8760. DOI: <https://doi.org/10.1016/j.ijpsycho.2012.08.012>. URL: <https://www.sciencedirect.com/science/article/pii/S0167876012005843> (citado na pg. 35).
- [REDFERN 2020] Neil REDFERN. “Sound in horror film trailers”. *Music, Sound, and the Moving Image* 14.1 (2020), pp. 47–71. DOI: [10.3828/msmi.2020.4](https://doi.org/10.3828/msmi.2020.4) (citado na pg. 16).
- [ROBINSON *et al.* 1966] Brian F. ROBINSON, Stephen E. EPSTEIN, G. David BEISER e Eugene BRAUNWALD. “Control of heart rate by the autonomic nervous system”. *Circulation Research* 19 (1966), pp. 400–411. DOI: [10.1161/01.RES.19.2.400](https://doi.org/10.1161/01.RES.19.2.400) (citado na pg. 11).
- [RUSSELL 1980] James RUSSELL. “A circumplex model of affect”. *Journal of Personality and Social Psychology* 39 (dez. de 1980), pp. 1161–1178. DOI: [10.1037/h0077714](https://doi.org/10.1037/h0077714) (citado na pg. 14).
- [SHAFFER e GINSBERG 2017] Fred SHAFFER e J. P. GINSBERG. “An overview of heart rate variability metrics and norms”. *Frontiers in Public Health* 5 (2017), p. 258. DOI: [10.3389/fpubh.2017.00258](https://doi.org/10.3389/fpubh.2017.00258) (citado na pg. 13).
- [SHEN *et al.* 2021] Yu-Sheng SHEN *et al.* “Influence of data splitting on performance of machine learning models in prediction of shear strength of soil”. *Mathematical Problems in Engineering* 2021 (fev. de 2021), p. 4832864. ISSN: 1024-123X. DOI: [10.1155/2021/4832864](https://doi.org/10.1155/2021/4832864). URL: <https://doi.org/10.1155/2021/4832864> (citado na pg. 25).
- [SHIV e FEDORIKHIN 1999] Baba SHIV e Alexander FEDORIKHIN. “Heart and mind in conflict: the interplay of affect and cognition in consumer decision making”. *Journal of Consumer Research* 26.3 (1999), pp. 278–292 (citado na pg. 7).
- [STANOVICH e WEST 2000] Keith E. STANOVICH e Richard F. WEST. “Individual differences in reasoning: implications for the rationality debate?” *Behavioral and Brain Sciences* 23.5 (2000), pp. 645–665. DOI: [10.1017/S0140525X00003435](https://doi.org/10.1017/S0140525X00003435) (citado nas pgs. 1, 6).
- [STRACK e DEUTSCH 2004] Fritz STRACK e Roland DEUTSCH. “Reflective and impulsive determinants of social behavior”. *Personality and social psychology review : an official journal of the Society for Personality and Social Psychology, Inc* 8 (fev. de 2004), pp. 220–47. DOI: [10.1207/s15327957pspr0803\\_1](https://doi.org/10.1207/s15327957pspr0803_1) (citado na pg. 1).
- [TAN 2011] Ed S. TAN. *Emotion and the Structure of Narrative Film: Film As An Emotion Machine*. 1st. Routledge, dez. de 2011. ISBN: 0415515602 (citado na pg. 15).

- [TULPPO *et al.* 1996] Mikko P TULPPO, Timo MÄKIKALLIO, Timo E. S. TAKALA, Tapio SEPPÄNEN e Heikki Veli HUIKURI. “Quantitative beat-to-beat analysis of heart rate dynamics during exercise.” *The American journal of physiology* 271 1 Pt 2 (1996), H244–52. URL: <https://api.semanticscholar.org/CorpusID:21978498> (citado na pg. 13).
- [VANDERLEI *et al.* 2009] Luiz Carlos Marques VANDERLEI, Carlos Marcelo PASTRE, Tatiana Dias HOSHI Rosângela Akemi de Carvalho e Moacir FERNANDES DE GODOY. *Basic notions of heart rate variability and its clinical applicability*. 2009. DOI: [10.1590/S0102-76382009000200018](https://doi.org/10.1590/S0102-76382009000200018). URL: <http://www.bjcv.org/article/372/en-us/basic-notions-of-heart-rate-variability-and-its-clinical-applicability> (citado na pg. 12).
- [VAPNIK 1995] Vladimir VAPNIK. *The Nature of Statistical Learning Theory*. New York: Springer, 1995 (citado na pg. 25).
- [WAXENBAUM *et al.* 2024] J. A. WAXENBAUM, V. REDDY e M. VARACALLO. “Anatomy, autonomic nervous system” (2024). Updated 2023 Jul 24. In: StatPearls [Internet]. Treasure Island (FL): StatPearls Publishing; 2024 Jan-. Available from: <https://www.ncbi.nlm.nih.gov/books/NBK539845/>. URL: <https://www.ncbi.nlm.nih.gov/books/NBK539845/> (citado nas pgs. 7, 8).
- [WHITLOCK 2005] Michael C. WHITLOCK. “Combining probability from independent tests: the weighted z-method is superior to fisher’s approach”. *Journal of Evolutionary Biology* 18.5 (set. de 2005), pp. 1368–1373. DOI: [10.1111/j.1420-9101.2005.00917.x](https://doi.org/10.1111/j.1420-9101.2005.00917.x). URL: <https://doi.org/10.1111/j.1420-9101.2005.00917.x> (citado na pg. 32).
- [YADAV e SHUKLA 2016] Sanjay YADAV e Sanyam SHUKLA. “Analysis of k-fold cross-validation over hold-out validation on colossal datasets for quality classification”. In: *2016 IEEE 6th International Conference on Advanced Computing (IACC)*. 2016, pp. 78–83. DOI: [10.1109/IACC.2016.25](https://doi.org/10.1109/IACC.2016.25) (citado na pg. 31).
- [YANG *et al.* 2020] Qiwei YANG, Shiqin ZHOU, Ruolei GU e Yan WU. “How do different kinds of incidental emotions influence risk decision making?” *Biological Psychology* 154 (2020), p. 107920. ISSN: 0301-0511. DOI: <https://doi.org/10.1016/j.biopsycho.2020.107920>. URL: <https://www.sciencedirect.com/science/article/pii/S0301051120300806> (citado na pg. 14).
- [ZHOU 2020] Zhi-Hua ZHOU. *Machine Learning*. 1ª ed. Springer, 2020. DOI: [http://doi.org/10.1007/978-15-1967-3](https://doi.org/10.1007/978-15-1967-3) (citado nas pgs. 24, 25).