

UNIVERSIDADE FEDERAL DE SÃO CARLOS

CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

**CLASSIFICAÇÃO DE SINAIS FISIOLÓGICOS
PARA INFERÊNCIA DO ESTADO EMOCIONAL DE
USUÁRIOS**

ISAQUE ELCIO DE SOUZA

ORIENTADORA: PROF^a. DR^a. VÂNIA PAULA DE ALMEIDA NERIS

São Carlos - SP
Fevereiro /2019

UNIVERSIDADE FEDERAL DE SÃO CARLOS

CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

**CLASSIFICAÇÃO DE SINAIS FISIOLÓGICOS PARA
INFERÊNCIA DO ESTADO EMOCIONAL DE
USUÁRIOS**

ISAQUE ELCIO DE SOUZA

Exame de Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação, área de concentração: Interação Humano Computador.
Orientadora: Dr^a. Vânia Paula de Almeida Neris

São Carlos - SP
Fevereiro/2019



UNIVERSIDADE FEDERAL DE SÃO CARLOS

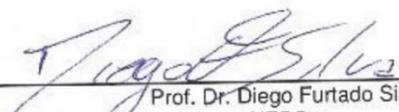
Centro de Ciências Exatas e de Tecnologia
Programa de Pós-Graduação em Ciência da Computação

Folha de Aprovação

Assinaturas dos membros da comissão examinadora que avaliou e aprovou a Defesa de Dissertação de Mestrado do candidato Isaque Elcio de Souza, realizada em 25/02/2019:



Profa. Dra. Vânia Paula de Almeida Neris
UFSCar



Prof. Dr. Diego Furtado Silva
UFSCar

Prof. Dr. Rodrigo Bonacin
FACAMP

Certifico que a defesa realizou-se com a participação à distância do(s) membro(s) Rodrigo Bonacin e, depois das arguições e deliberações realizadas, o(s) participante(s) à distância está(ão) de acordo com o conteúdo do parecer da banca examinadora redigido neste relatório de defesa.



Profa. Dra. Vânia Paula de Almeida Neris

AGRADECIMENTO

Agradeço primeiramente a Deus por permitir a finalização de uma mais uma etapa em minha vida.

À minha orientadora, Prof^a. Dr^a. Vânia Paula de Almeida Neris, pela oportunidade de realizar este trabalho. Agradeço por todos os ensinamentos compartilhados. Muito obrigado por tudo!

Ao Prof^o. Dr. Diego Furtado Silva, Prof^a. Dr. Rodrigo Bonacin, Prof^o. Dr. Murillo Rodrigo Petrucelli Homem e Prof^o. Dr. Luciano Neris, por contribuírem de forma significativa com sugestões de melhoria neste trabalho.

Aos meus pais, Sylvania e Aparecido, pelo apoio e palavras de conforto.

Aos meus irmãos, Heloisa e Zaqueu, pelo apoio incondicional.

À minha namorada, pelo apoio em momentos difíceis, pela força e compreensão.

Aos alunos de graduação que participaram deste trabalho, Bruno Fernandes, Jonas Karasek, Lucas Françoso e Mariana Cavichioli.

Aos meus amigos, Warteruzannan, Roger Levy, Ricardo Vilela, Marillia, Tatiana de Alencar, Guilherme Leal e todos aqueles que contribuíram de forma direta ou indireta para a realização deste trabalho.

Aos meus colegas de laboratório, com os quais compartilhei vários momentos no período do mestrado.

“Coisas simples devem ser simples,
e coisas complexas devem ser possíveis.”

Alan Kay

RESUMO

O estado emocional tem papel fundamental para explicar o comportamento humano no cotidiano, influenciando em decisões e até mesmo na forma de se comunicar. Portanto, entender tais características e como identificá-las é de extrema importância para conhecer melhor o comportamento humano. As emoções podem ser classificadas em dois modelos de taxonomia: Modelo Discreto, o qual inclui emoções básicas (felicidade, tristeza, medo, repugnância, raiva, surpresa) e o Modelo Dimensional, o qual expressa duas ou mais emoções em um espaço com domínios emocionais, como Valência (nojo, prazer) e Excitação (calma, excitação). A literatura apresenta as maneiras de avaliação de indícios emocionais, com inferência em tempo real, pela coleta de sinais fisiológicos por meio de sensores e classificados por algoritmos nos domínios emocionais de Valência e Excitação. Neste contexto, há uma complexidade em coletar esses dados com sensores de baixo custo, assim como em classificar emoções em mais domínios emocionais, aumentando a quantidade de classes e, conseqüentemente, a precisão da classificação no espaço. Desse modo, esta dissertação tem por objetivo classificar sinais fisiológicos coletados com sensores comerciais de baixo custo, inferindo emoções dimensionais em quatro domínios: Valência, Excitação, Sentimento de controle e Facilidade de conclusão do objetivo. Assim, este trabalho apresenta um *dataset* com dados de três sensores: de atividade cardíaca (ECG), atividade cerebral (EEG) e resposta galvânica (GSR). Para compor o *dataset*, os sinais fisiológicos foram coletados de 33 participantes em três sessões. Com o intuito de levar o indivíduo a um estado emocional desejado, utilizou-se 16 trechos de filmes e vídeos pré-rotulados. Após a coleta e gravação dos sinais, realizou-se uma etapa de pré-processamento para eliminar ruídos e dados inconsistentes e extração de características. Na sequência, para a classificação, foram utilizados algoritmos K-vizinhos mais próximos, *Naive Bayes*, *Decision Tree*, *Random Forest*, *XGBoost*, *Support Vector Machine* e Redes Neurais Artificiais. Por fim, foi realizada uma avaliação estatística do desempenho dos algoritmos em dados de cada sensor. Os algoritmos de classificação que melhor se adaptaram com as características dos dados foram *Naive Bayes* para ECG e GSR com 96% e 77% acurácia e *Support Vector Machine* para EEG com 99% de acurácia. Os resultados sugerem que os dados coletados permitem a classificação nos quatro domínios estudados.

Palavras-chave: Emoção, sensores, interação humano-computador, aprendizado de máquina, sinal fisiológico, *dataset*.

ABSTRACT

Emotional state plays a fundamental role in explaining human behavior in everyday life, influencing decisions and even how to communicate. Therefore, understanding these characteristics and how to identify them is of the utmost importance for a better understanding of human behavior. Emotions can be classified into two models of taxonomy: Discrete Model that include basic emotions (happiness, sadness, fear, disgust, anger, surprise) and Dimensional Model that expresses two or more emotions in a space, with emotional domains such as Valencia (disgust, pleasure) and Excitement (calm, excitement). The literature presents ways of evaluating emotional cues, with inference in real time, by collecting physiological signals through sensors and classified by algorithms in the emotional domains of Valencia and Excitation. In this context, there is a complexity in collecting this data with low-cost sensors, as well as classifying emotions into more emotional domains, increasing the number of classes and consequently the accuracy of the classification in space. This dissertation aimed to classify physiological signals collected with low cost commercial sensors, inferring dimensional emotions in four domains: Valencia, Excitation, Feeling of control and Ease of conclusion of the objective. Thus, this work presents a dataset, with data from three sensors: cardiac activity (ECG), brain activity (EEG) and galvanic response (GSR). To compose the dataset, the physiological signals were collected from 33 participants in three sessions. In order to bring the individual to a desired emotional state, 16 pre-labeled movie clips and video clips were used. After the collection and recording of the signals, a preprocessing step was performed to eliminate noise and inconsistent data and extraction of characteristics. In order to classify, we used the closest K-neighbors algorithms, Naive Bayes, Decision Tree, Random Forest, XGBoost, Support Vector Machine and Artificial Neural Networks. Finally, a statistical evaluation of the performance of the algorithms in each sensor data was performed. The classification algorithms that best fit the characteristics of the data were Naive Bayes for ECG and GSR with 96% and 77% accuracy and Support Vector Machine for EEG with 99% accuracy. The results suggest that the data collected allow classification in the four domains studied.

Keywords: Emotion, sensors, human-computer interaction, machine learning, physiological signal, dataset.

LISTA DE FIGURAS

Figura 1. Estrutura do Espaço Emocional Semântico	27
Figura 2. Exemplo de classificação KNN	31
Figura 3. Uma árvore de decisão e o mapeamento das regiões de decisão	32
Figura 4. Exemplo classificação com XGBoost	33
Figura 5. Exemplo de classificação por meio SVM linear	34
Figura 6. Exemplo neurônio artificial	35
Figura 7. Exemplo RNA multicamada	36
Figura 8. Validação cruzada	38
Figura 9. Exemplo de matriz de confusão	39
Figura 10. Processos da Revisão Sistemática.	42
Figura 11. Análise de palavras-chave	43
Figura 12. Artigos encontrados por máquina de busca	44
Figura 13. Diagrama de seleção dos estudos	44
Figura 14. Quantidade de sensor utilizado por artigo	51
Figura 15. Arduino Leonardo, <i>wifi shield</i> e Sensor GSR	68
Figura 16. Arduino com sensor ECG, GSR e módulos de comunicação	68
Figura 17 . Locais do corpo onde foram posicionados eletrodos ECG	69
Figura 18. Sensor EEG <i>MindWave Headset</i>	69
Figura 19. Sensores para coleta de sinais fisiológico no participante	70
Figura 20. Câmera frontal para coleta expressões faciais	71
Figura 21. Participante assiste vídeo com estímulo de assustador/medo	72
Figura 22. Emoções participantes mapeado espaço semântico	72
Figura 23. Sinais ECG com estímulo assustador/medo	73
Figura 24. Sinais EEG com estímulo assustador/medo	73
Figura 25. Sinais GSR com estímulo assustador/medo	73
Figura 26. Porcentagem de dados consistentes e eliminados	76
Figura 27. Distribuição dos dados em função das classes GSR	78
Figura 28. Distribuição das classes GSR	79
Figura 29. Teste de Nemeyi modelos com dados GSR	81

Figura 30. Distribuição dos dados em função das classes ECG	82
Figura 31. Distribuição das classes ECG	82
Figura 32. Teste de Nemenyi modelos com dados ECG	84
Figura 33. Distribuição dos dados em função das classes EEG	85
Figura 34 . Distribuição das classes sinal Delta EEG	86
Figura 35. Teste de Nemenyi modelos com dados EEG	88

LISTA DE TABELAS

Tabela 1 - Artigos aceitos	45
Tabela 2 - Tipos de sensores	49
Tabela 3 - Algoritmos de classificação	51
Tabela 4 - Sensores que utiliza SVM como classificador	52
Tabela 5 - Sensores que utiliza RF com classificador	53
Tabela 6 - Sensores que utiliza NB como classificador	53
Tabela 7 - Sensores que utiliza RNA como classificador	54
Tabela 8 - Trabalhos relacionados	56
Tabela 9 - Classificação domínios emocionais NB e SVM	57
Tabela 10 - Classificação domínios emocionais com algoritmo NB	58
Tabela 11 - Resultado classificação SVM <i>dataset</i> DECAF	59
Tabela 12 - Resultado classificação SVM <i>dataset</i> DREAMER	60
Tabela 13 - Resultado classificação SVM <i>dataset</i> MAHNOB-HCI	61
Tabela 14 - Base de vídeos e emoções.	64
Tabela 15 - Resultados dos modelos de classificação com sinais GSR	79
Tabela 16 - Matriz de confusão modelo NB com sinais GSR	80
Tabela 17 - Matriz de confusão modelo RNA com sinais GSR	80
Tabela 18 - Resultados dos modelos de classificação com sinais ECG	83
Tabela 19 - Matriz de confusão modelo NB com sinais ECG	83
Tabela 20 - Matriz de confusão modelo RNA com sinais ECG	84
Tabela 21 - Resultados dos modelos de classificação com sinais EEG	86
Tabela 22 - Matriz de confusão modelo KNN com sinais EEG	87
Tabela 23 - Matriz de confusão modelo SVM com sinais EEG	88

LISTA DE ABREVIATURAS E SIGLAS

ACM - *Association for Computing Machinery*

DT - *Decision tree*

AG - *Algoritmo Genético*

BVP - *Blood Volume Pulse*

ECG - *Electrocardiogram*

EDA - *Electrodermal activity*

EDR - *Electrodermal response*

EEG - *Electroencephalography*

EKG - *Electrocardiogram*

EMG - *Electromyography*

FACS - *Facial Action Coding*

fNIRS - *Espectroscopia de infravermelho*

GSR - *Galvanic skin response*

ICG - *Cardiograma de impedância*

IEEE - *Institute of Electrical and Eletronics Engineers*

IHC - *Interação Humano-Computador*

J48 - *J48 (Melhoria do ID3)*

kNN - *k-vizinho mais próximo*

LB - *LogitBoost*

LDA - *Linear Discriminant Analysis*

LF - *Um Sistema de Inferência Fuzzy*

LIFeS - *Laboratório de Interação Flexível e Sustentável*

NB - *Naive Bayes*

NF - *Neuro-Fuzzy*

PD - *Padrão de digitação*

PPG - *Photoplethysmography*

PV - *Processamento Voz*

RBF - *Radial Basis Function*

R-R - *Round-robin*

RESP - *Respiratory monitoring*

RTF - *Rotation Forest*

RF - *Random Forest*

RNA - Redes Neurais Artificial

RP - Respostas Pupilares

RSL - Revisão sistemática da Literatura

SC - *Skin Conductance*

SFFS - *Sequential Floating Forward Selection*

SHAKE - Sensor de movimento

SKT - *Skin temperature*

SNA - Sistema Nervoso Autônomo

SNC - Sistema Nervoso Central

SNE - Sistema Neuroendócrino

SNS - Sistema Nervoso Somático

SS - Sistema Sensorial

StArt - *State of the Art through Systematic Review*

SVM - Máquina de vetores de suporte

USB - *Universal Serial Bus*

SUMÁRIO

CAPÍTULO 1 - INTRODUÇÃO	13
1.1 Contexto, motivação e problemática	13
1.2 Objetivos	16
1.3 Hipóteses	16
1.4 Metodologia de Desenvolvimento do Trabalho	17
1.5 Organização do Trabalho	19
CAPÍTULO 2 - CONCEITOS FUNDAMENTAIS	20
2.1 Emoções	20
2.1.1 Espaço Semântico de Scherer	26
2.2 Sinais Fisiológicos e Sensores	27
2.2.1 Resposta Galvânica	28
2.2.2 Atividade Cardíaca	28
2.2.3 Atividade Cerebral	28
2.3 Método para Redução de Dimensionalidade	29
2.4 Algoritmos de Classificação	30
2.4.1 KNN	30
2.4.2 <i>Naive Bayes</i>	31
2.4.3 <i>Árvore de decisão</i>	32
2.4.4 <i>Random Forest</i>	32
2.4.5 XGBoost	33
2.4.6 Máquina de vetores de suporte	34
2.4.7 Redes neurais artificiais	34
2.5 Avaliação de algoritmos de classificação	36
2.5.1 Acurácia	36
2.5.2 Validação cruzada K-fold	37
2.5.3 Matriz de confusão	37
2.6 Considerações Finais	38
CAPÍTULO 3 - SENSORES E EMOÇÃO: REVISÃO SISTEMÁTICA	40
3.1 Introdução	40

3.1.1 Método	41
3.1.2 Planejamento	42
3.1.3 Processo de Seleção	43
3.2 Resultados	45
3.2.1 Extração de dados	48
3.3 Considerações Finais	54
CAPÍTULO 4 - TRABALHOS RELACIONADOS	55
4.1 Considerações iniciais	55
4.2 <i>Dataset</i> de sinais fisiológicos	55
4.2.1 ASCERTAIN	57
4.2.2 DEAP	58
4.2.3 DECAF	59
4.2.4 DREAMER	60
4.2.5 MAHNOB-HCI	61
4.2.6 <i>Toward Machine Emotional Intelligence: Analysis of Affective Physiological State</i>	62
4.3 Considerações finais	62
CAPÍTULO 5 - COLETA DE DADOS DOS SENSORES FISIOLÓGICOS	64
5.1 Considerações iniciais	64
5.2 Seleção de filmes	64
5.3 Procedimentos do experimento	66
5.4 Coleta de sinais fisiológicos	68
5.5 Considerações Finais	75
CAPÍTULO 6 - DATASET	76
6.1 Definição da base de dados	76
6.2 Pré-processamento	77
6.3 Protocolo dos testes	78
6.4 Análise de dados do sensor GSR	79
6.5 Análise de dados do sensor ECG	82
6.6 Análise de dados do sensor EEG	86
6.7 Considerações finais	89
CAPÍTULO 7 - CONCLUSÃO E TRABALHOS FUTUROS	91

7.1 Considerações iniciais	91
7.2 Síntese das Contribuições	92
7.3 Limitações do trabalho	93
7.4 Trabalhos Futuros	93
7.5 Considerações finais	94
REFERÊNCIAS	95
APÊNDICE A QUESTIONÁRIO PRÉ - SESSÃO	103
APÊNDICE B QUESTIONÁRIO PÓS SESSÃO	105
APÊNDICE C PROTOCOLO DO EXPERIMENTO	106
APÊNDICE D TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO	109
APÊNDICE E AUTORIZAÇÃO DE CAPTAÇÃO E EXIBIÇÃO DE IMAGEM	112
ANEXO A SAM	114
ANEXO B PARECER CONSUBSTANCIADO DO CEP	115

Capítulo 1

INTRODUÇÃO

1.1 Contexto, motivação e problemática

A área de Interação Humano-Computador (IHC) surgiu no início da década de 1980, como um ramo da computação especializada em ciência cognitiva e engenharia de fatores humanos (BARBOSA; SILVA, 2010). A IHC surgiu com o intuito de melhorar a interação e a comunicação dos computadores da época, uma vez que o uso, assim como o surgimento de novos dispositivos, tais como celulares, tablets e notebooks, estava cada vez mais popular.

A IHC é um campo interdisciplinar que relaciona a ciência da computação, artes, design, ergonomia, psicologia, sociologia, semiótica, linguística e áreas afins. Os aspectos emocionais, por sua vez, vêm sendo estudados há mais tempo pela área de psicologia (LICHTENSTEIN ET AL., 2008).

No entanto, nos últimos anos, houve um aumento significativo de pesquisas sobre o tema de emoções no âmbito de IHC, visto que a emoção pode auxiliar na tomada de decisões das pessoas (SCHERER, 2005; XAVIER; NÉRIS, 2012). O reconhecimento das emoções do usuário permite aperfeiçoar a interação, compreender as necessidades de alterações no design e novas maneiras de interação (EWING; FAIRCLOUGH; GILLEADE, 2016; SOURINA; LIU, 2014; POLLMANN; VUKELIĆ; PEISSNER, 2015). Com a evolução tecnológica, sistemas de software têm a capacidade de inferir a emoção, responder a este estado emocional do usuário e tomar decisões considerando esta informação, tais como aplicações médicas, jogos e monitoramento de situações cotidianas.

Algumas aplicações médicas, por exemplo, monitoram os sinais fisiológicos e inferem o estado emocional do paciente para auxiliar no diagnóstico. Ko et al. (2015), por exemplo, coletam informações de atividades cardíacas e respiração utilizando sensores vestíveis em ambiente distribuído para acesso às informações biomédicas. Os sinais fisiológicos também podem fornecer uma métrica de estresse do indivíduo em situações do dia a dia, como no trânsito. Tais informações podem ser utilizadas para melhorar a segurança e gerenciar sistemas de informação em veículos (HEALEY et al., 2005).

Aplicadas às atividades de entretenimento, as emoções auxiliam a definir o nível de dificuldade do jogo, se adaptando de acordo com a pontuação e a emoção do jogador (SOURINA; LIU, 2014). Assim, é possível avaliar a satisfação do praticante em tempo real e alterar o nível de dificuldade da atividade com base nas informações do jogador.

Estudos em psicologia considera que as emoções estão ligadas à reação de vários componentes, que podem ser sintetizados em: avaliações cognitivas, sentimentos subjetivos, tendências comportamentais, reações fisiológicas e expressões motoras (MAHLKE; MINGE, 2008; SCHERER, 2005). Essas impressões podem se manifestar por meio de uma série complexa de respostas motoras, Sistema Nervoso Autônomo (SNA) e respostas glandulares, sendo difícil identificar determinadas emoções apenas pela observação, como expressão facial, postura corporal e respostas fisiológicas (BRAGHIROLI et al., 2001).

O modelo *Facial Action Coding System* (FACS) associa as respostas motoras com emoções em um determinado padrão de expressão (EKMAN; FRIESEN; HAGER, 2002). Analisando mais de quarenta e quatro músculos faciais, em conjunto ou isolados, avaliados por profissionais treinados, o estado emocional é classificado em seis emoções básicas, como medo, estresse, alegria, nojo, surpresa e tristeza, a partir da movimentação dos músculos por análise de fotos e vídeos. O modelo FACS, portanto, é implementado em sistemas de aprendizado de máquina para inferir o estado emocional.

Algoritmos de aprendizado máquina têm sido empregados para análise dos sinais para inferir o estado emocional e sua influência nas reações fisiológicas, uma vez que sinais possuem variações e características subjetivas de cada indivíduo. Este componente apresenta diversidade de sensores fisiológicos e algoritmos de

classificação de acordo com Greco et al. (2016). Mas apesar da quantidade de recursos disponíveis para coleta dos sinais e classificação do estado emocional em tempo real, estudos ressaltam a complexidade e os desafios para detectar o estado emocional (ALZOUBI et al., 2015; KUNCHEVA et al., 2011; PINTO, 2001).

Contudo, de acordo com Kuncheva et al. (2011), nenhuma técnica individual é perfeita para inferir estado emocional, considerando o uso de um sensor de atividade cerebral *Electroencephalography* (EEG) e um *Electro Dermal Activity* (EDA).

Os dados fisiológicos sofrem variações, dificultando a construção de um modelo de classificação eficiente (ALZOUBI et al., 2015), uma vez que as emoções são experiências subjetivas que envolvem a mente, corpo e o organismo em sua totalidade. Portanto, a variação dos sinais biológicos e alterações espontâneas de curta duração dificultam a inferência do estado emocional (RATHOD; GEORGE; SHINDE, 2016).

Para tratar variações, ruídos e dados inconsistentes, são definidas etapas para análise dos sinais (ATKINSON; CAMPOS, 2016; CALVO; D'MELLO, 2010). A primeira etapa após a coleta dos sinais é pré-processamento, cujo objetivo é o de eliminar ruídos. As próximas etapas são a realização de extração e seleção de características, de modo a eleger as melhores características dos sinais fisiológicos relacionados à cada emoção classificada. E, por fim, utilizando algoritmos de classificação, etapa esta, com objetivo de identificar as classes emocionais.

Para facilitar inferência, as emoções foram categorizadas como emoções básicas, conforme proposto por Ekman et al. (1987), sendo 6 emoções discretas: alegria, medo, surpresa, tristeza, nojo e raiva. Assim como a estrutura de Parrott (2001) que subdivide as emoções em três categorias básicas, secundárias e terciárias.

Ademais, foram propostas escalas dimensionais para emoções, como a Roda de Emoções, proposta por Plutchik (2001), o Modelo *Circumplex* de Russell (1980) com domínios emocionais de valência e excitação e distribuição de emoções neste espaço. Scherer (2005), baseado no modelo *Circumplex* de Russell, desenvolveu o Espaço Semântico com quatro domínios emocionais: valência, excitação, facilidade de conclusão de objetivo e sentimento de controle e acrescentou oitenta emoções ao *Circumplex*.

Apesar das dificuldades, há grande motivação para o uso de sinais fisiológicos para detectar estado emocional (KUSHKI et al., 2015; PICARD; VYZAS; HEALEY, 2001). Portanto, pesquisadores concentram-se em estudos de sinais fisiológicos relacionados às emoções com modelos dimensionais em dois domínios (dimensões) Valência e Excitação (KOELSTRA et al., 2012; SOLEYMANI et al., 2012; SUBRAMANIAN et al., 2016). Alguns acrescentam terceiro domínio de Dominância (KATSIGIANNIS; RAMZAN, 2017). Portanto, estudos apontam que são necessários mais de dois domínios para representação de emoção no círculo (Espaço Semântico) (FONTAINE et al., 2007) e sugerem a utilização de quatro domínios. Com a divisão do círculo em quatro dimensões, aumenta-se a representatividade característica de cada emoção. Um dos modelos que contempla as quatro dimensões emocionais é o Espaço Semântico de Scherer (2005).

1.2 Objetivos

Este trabalho tem como objetivo geral a formalização de um *dataset* de sinais fisiológicos com sensores (ECG, EEG e GSR) de baixo custo, com rótulos emocionais contemplando quatro domínios emocionais, na qual as classes representam áreas do Espaço Semântico de Scherer (2005) e, ao final, avaliar algoritmos de classificação que obteve melhor desempenho com os dados de cada sensor.

Para que o objetivo geral seja alcançado, foram definidos os seguintes objetivos específicos:

1. Seleção de estímulos emocionais para coleta de sinais fisiológicos;
2. Sistema para coleta sinais fisiológicos;
3. Comparação dos modelos de classificação, de modo a identificar aquele que mais se adequa às características dos dados de cada sensor;
4. Demonstrar o modelo de classificação com o melhor desempenho.

1.3 Hipóteses

Para realização dos objetivos citados anteriormente, as hipóteses nulas e alternativas definidas para este trabalho são:

- Hipótese nula (H0): Não há alteração nos sinais fisiológicos (indícios de emoção) coletados pelos sensores de baixo custo enquanto o usuário assiste aos trechos de vídeos que estimulam determinadas emoções, inviabilizando, portanto, a extração característica e posteriormente sua classificação em quatro domínios emocionais.
- Hipótese alternativa 1 (H1-1): Há alteração mensurável nos sinais fisiológicos (indícios de emoção) coletados pelos sensores de baixo custo enquanto o usuário assiste aos trechos de vídeos que estimulam determinadas emoções. Os sinais não são padronizáveis e não auxiliam na construção de uma base de dados e as características coletadas dos sinais não representam os quatro domínios emocionais, dificultando, assim, sua classificação.
- Hipótese alternativa 2 (H1-2): Há alteração mensurável nos sinais fisiológicos (indícios de emoção) coletados pelos sensores de baixo custo enquanto o usuário assiste aos trechos de vídeos que estimulam determinadas emoções. Os sinais são padronizáveis e podem ser utilizados na construção de uma base de dados. Com as características dos sinais fisiológicos é possível a classificação dos quatro domínios emocionais e representação no Espaço Semântico.

1.4 Metodologia de Desenvolvimento do Trabalho

Este estudo se caracteriza como experimental, com base nos procedimentos técnicos utilizados, seguindo a classificação de Gerhardt et al. (2009). Com a identificação das características dos sinais fisiológicos relacionados com estado emocional do indivíduo a partir de um estímulo, gerando uma base de dados rotulada, realizou-se um experimento controlado visando avaliar sinais fisiológicos

dos sensores ECG, EEG e GSR coletados com estímulos emocionais. Os estímulos em formato de trechos de filmes e videoclipes foram utilizados para que o participante atinja determinadas emoções, possibilitando a criação de um *dataset* de sinais fisiológicos com rótulos emocionais. Este estudo relaciona as seguintes variáveis: trechos de filmes, sinais fisiológicos, algoritmos de classificação e emoções. Portanto, estado emocional é o fenômeno estudado a partir de análise dos sinais fisiológicos definindo peculiaridades das emoções neste contexto.

Este trabalho teve início com a elaboração de uma Revisão Sistemática da Literatura (RSL), com análise do uso de sensores fisiológicos para classificar o estado emocional. Por meio da RSL, buscou-se responder questões de pesquisa e estado da arte no contexto de sensores, além da classificação de sinais fisiológicos em tempo real. A partir da RSL, foi proposta uma base de dados de sinais fisiológicos; Já a atividade cerebral, cardíaca e resposta galvânica da pele foram utilizados para a classificação do estado emocional, coletados por sensores comerciais.

Na sequência, foi preparado o experimento para a coleta dos sinais fisiológicos, com a seleção de vídeos que estimulam determinadas emoções. Por se tratar de experimento com pessoas, foi submetido e aprovado pelo comitê de ética. Em seguida, foi desenvolvida uma ferramenta para coleta dos sinais fisiológicos, seguindo rigoroso protocolo de planejamento para coleta de dados.

Após essa etapa, foram realizados pré-processamentos para eliminar dados inconsistentes com filtros de passa baixa e passa alta, e para eliminação de ruídos o filtro *Wiener* (WIENER, 1964). Para extração de características e redução de dimensionalidade dos sinais fisiológicos, foi utilizado *Linear Discriminant Analysis* (LDA).

Por último, os dados foram submetidos aos seguintes algoritmos de classificação: *k-Nearest Neighbors* (KNN), *Naive Bayes* (NB), Árvore de Decisão ou *Decision Tree* (DT), Floresta Aleatória ou *Random Forest* (RF), XGBoost, Máquina de Vetores de Suporte ou *Support Vector Machine* (SVM) e Redes Neurais Artificiais (RNA). Os dados foram divididos em treinamento e teste utilizando validação cruzada e gerando a taxa de acerto com acurácia para avaliar modelos de classificação. Para a avaliação estatística entre os algoritmos de classificação, é analisado a acurácia com teste de Friedman e Nemenyi.

1.5 Organização do Trabalho

O restante deste trabalho está dividido da seguinte forma:

- No Capítulo 2, são apresentados os conceitos de emoções, o Espaço Semântico de Scherer, sinais fisiológicos, sensores, algoritmos de extração de característica e classificação.
- O Capítulo 3 aborda o processo de revisão sistemática da literatura, descrevendo, ainda, os principais sensores fisiológicos encontrados na literatura que apresentam indícios emocionais e métodos de classificação.
- No Capítulo 4, são relatados os trabalhos relacionados que criaram base de dados emocionais de sinais fisiológicos semelhantes a este trabalho.
- O Capítulo 5 explica o experimento para coleta de sinais fisiológicos e seleção de estímulos.
- No Capítulo 6, discute-se o pré-processamento dos sinais, extração de características e comparação do desempenho dos modelos de classificação.
- Por fim, no Capítulo 7, apresenta-se a conclusão com suas contribuições, além das limitações e perspectivas futuras.

Capítulo 2

CONCEITOS FUNDAMENTAIS

Neste capítulo, são apresentados os conceitos fundamentais abordados no desenvolvimento e avaliação deste trabalho, envolvendo emoções, sinais fisiológicos e aprendizado de máquina. Este capítulo está organizado da seguinte forma: a Seção 2.1 apresenta a teoria das emoções e outros aspectos emocionais. A Seção 2.2 a descrição de sinais e sensores fisiológicos. A Seção 2.3 algoritmos de extração de características, Seção 2.4 algoritmos de classificação. A Seção 2.5 métodos de avaliação dos algoritmos de classificação e por fim, a Seção 2.6 traz as considerações finais.

2.1 Emoções

Áreas como psicologia, filosofia e neurociência têm pesquisado sobre emoções e suas características, bem como a influência para corpo humano. Logo, com diferentes perspectivas, surgiram variações de definições para emoção e, com a falta de consenso na definição, Dixon (2012) e Russell (2012) sugerem que seja adotada a definição que se adeque com as peculiaridades do trabalho.

Pesquisas acerca dos aspectos emocionais tiveram seus primeiros passos com Darwin, em 1872, Sócrates, no século VI a.C., Platão, nos anos de 427 a 347 a.C e Tzu, nos anos de 470 a 399 a.C. Para Darwin (1872), pai da Teoria da Evolução, as expressões fisiológicas das emoções se manifestam com alterações na sudorese excessiva e os batimentos cardíacos, os quais podem representar uma resposta emocional à tensão, preparando para a ação que será tomada.

De acordo com Scherer (1984) e Pinto (2001), a emoção é uma experiência subjetiva que envolve o indivíduo como um todo, tanto a mente quanto o corpo. Uma reação, por sua vez, é considerada complexa quando desencadeada por um estímulo ou pensamento com envolvimento de reações orgânicas e sensações pessoais. Segundo Pinto (2001), é uma resposta que envolve diferentes componentes, tais como reação observável, excitação fisiológica, interpretação cognitiva e experiência subjetiva.

Damásio (2003), por sua vez, define emoções como uma variação psíquica e física desencadeada por um estímulo, além de consistir em um meio natural de avaliação o ambiente ao redor e de reação de maneira adaptativa.

Braghirolli (2001) considera que as emoções são complexos estados de excitação em que participa o organismo como um todo. Considera que há (três) indicadores para discernir o estado emocional: relatos verbais, observação do comportamento e indicadores fisiológicos. Já para Norman (2004), o afeto pode ser definido como um termo geral para o sistema de julgamento, consciente ou subconsciente, e considera a emoção como uma experiência consciente do afeto.

Scherer (2001) destaca que se tratando do modelo de processo de componente, a emoção é conceituada como um episódio de mudança inter-relacionada e sincronizada de todos ou da maioria dos subsistemas do organismo (componentes) em resposta à avaliação de um evento de estímulo externo ou interno, como relevante para os principais interesses do organismo.

O estímulo é considerado externo quando indivíduo percebe o evento ou objetos no ambiente pelo sistema sensorial e desencadeia um determinado estado emocional. O estímulo interno, por sua vez, está atribuído a um conjunto de pensamentos sobre o evento que já ocorreu, está ocorrendo ou vai ocorrer. A avaliação de estímulos tem por objetivo analisar objetos ou eventos com a finalidade de preparar no organismo uma reação apropriada (SCHERER, 2001).

O processo de análise dos estímulos é feito com base em critérios específicos, novidade, agradável (ou desagradado), previsibilidade, relevância de objetivo, ou seja, sua significância para os objetivos do indivíduo, potencial de enfrentamento, o qual consiste na capacidade do indivíduo de lidar com as consequências do evento, e significância normativa, constituída pela

compatibilidade com normas e valores pessoais ou sociais (COPPIN; SANDER, 2016).

Scherer (2001, p. 94) classifica em quatro categorias a importância da avaliação de determinado evento ou objeto:

(1) Relevância - Quão relevante é este evento para mim? Isso afeta diretamente a mim ou ao meu grupo de referência social?; (2) Implicações - Quais são as implicações ou consequências deste evento e como isso afeta meu bem-estar e meus objetivos imediatos ou de longo prazo?; (3) Potencial de enfrentamento - Quão bem posso lidar com essas consequências ou me ajustar a elas? e, (4) Significado normativo - Qual é o significado deste evento em relação ao meu autoconceito, normas e valores sociais?.

Diversos métodos, técnicas, modelos e instrumentos são encontrados na literatura para avaliar o estado emocional. Segundo Scherer (2005, p. 709) para uma avaliação ideal é preciso.

(1) as contínuas mudanças nos processos de avaliação em todos os níveis de processamento do sistema nervoso central; (2) os padrões de respostas geradas nos sistema nervoso neuroendócrino, autonômico e somático; (3) as mudanças motivacionais produzidas pelo resultado da avaliação de tendências de ação particulares; (4) os padrões de expressões facial e vocal, bem como os movimentos do corpo e, (5) a natureza do estado dos sentimentos subjetivos experimentados que refletem todas essas mudanças dos componentes.

De acordo com Scherer, os cinco subsistemas, ou componentes, da emoção, são: (1) avaliações cognitivas, (2) reações fisiológicas, (3) tendências comportamentais, (4) expressões motoras e (5) sentimentos subjetivos. No contexto de componente emocional, o organismo é avaliado como um todo, dividido nos sistemas do organismo: Sistema Nervoso Central (SNC), Sistema Neuroendócrino

(SNE), SNA, Sistema Sensorial (SS) e Sistema Nervoso Somático (SNS), estando os componentes da emoção relacionados aos sistemas do organismo. Para os psicólogos, as emoções estão ligadas às reações de vários componentes permitindo avaliação do estado emocional.

As Avaliações Cognitivas consistem no processamento e interpretação de informações detectadas pelo SS acerca de determinada situação, realizado pelo SNS. Sendo assim, as emoções consistem em respostas emitidas pelo SNC à integração dos dados sensoriais que a ele chegam. O indivíduo está em constante avaliação do ambiente, procurando perceber afetos de eventos e objetos (FONTAINE et al., 2002). Para Coppin (2016), os organismos exploram constantemente seu ambiente e reagem a estímulos relevantes.

Com a identificação de um estímulo, as funções de adaptação das emoções são ativadas preparando a tendência comportamental, adequado aos incidentes de resultados relevantes, considerando que uma mesma situação pode induzir diferentes emoções a partir da interpretação do indivíduo (MAHLKE; MINGE, 2008; SCHERER, 2005). Para avaliação deste componente, por exemplo, o método “*Think aloud*” (em português, “pensamento em voz alta”) de Van Someren (1994), baseia-se no autorrelato, no qual o indivíduo retrata o que está sentindo diante de um evento ou objeto que despertou determinado sentimento. A emoção é também uma interpretação cognitiva associada ao estado fisiológico e à situação que desencadeou a reação.

O componente emocional de Reações Fisiológicas é conhecido também como: Alterações Psicofisiológicas (FONTAINE et al., 2007), Neurofisiológicas (HAYASHI; BARANAUSKAS, 2011), Ativação fisiológica (LAURANS; DESMET; HEKKERT, 2009), Reação Corporal (COPPIN; SANDER, 2016) e Excitação Fisiológica (PINTO, 2001) e permitem avaliar respostas emocionais do indivíduo de forma espontânea e inconsciente.

Segundo Pinto (2001), as reações fisiológicas estão no nível do SNA, manifestando-se com aumento do ritmo cardíaco e pressão sanguínea, a respiração torna-se ofegante, o sangue flui para os músculos voluntários, aumenta-se a transpiração, as glândulas suprarrenais produzem epinefrina (adrenalina), as pupilas se dilatam para melhorar a visão, entre outras reações. Consequentemente, está fortemente ligado aos SNC, SNE e SNA. O SNC recebe informações dos cinco

sentidos, as interpreta e gera uma resposta, executada pelo sistema motor. O SNE, por sua vez, é responsável pela regularização e manutenção das condições internas do organismo, enquanto o SNA controla as funções vitais do corpo, respiração, digestão, frequência dos batimentos cardíacos, controle de temperatura, dentre outros (MAHLKE; MINGE, 2008; SCHERER, 2001; STEMMLER, 2003).

Diversas teorias consideram as reações corporais (fisiológicas) um aspecto da emoção. De acordo com as teorias de avaliação, as reações fisiológicas apoiam respostas adaptadas para a expressão da emoção e produção de tendências de ação (COPPIN; SANDER, 2016).

Ainda, de acordo com Coppin (2016), algumas alterações emocionais possuem influência direta nas porções simpática e parassimpática do SNA, sendo as respostas eletrotérmicas e cardiovasculares os indicadores mais utilizados para avaliar as mudanças no estado emocional do indivíduo.

A Atividade Eletrodérmica (EDA), também é conhecida como *Galvanic Skin Response* (GSR), está relacionada à mudança de calor e condutividade de eletricidade da pele que são capturados através de sensores colocados nos dedos. A resposta galvânica da pele pode estar relacionada ao nível de excitação e situações de estresse ou frustração (LICHTENSTEIN et al., 2008; MAHLKE; MINGE, 2008).

O Eletrocardiograma (ECG) captura a variabilidade da frequência cardíaca (VFC) e anormalidades nos batimentos cardíacos. Além disso, está relacionado com domínio da valência (LICHTENSTEIN et al., 2008; MAHLKE; MINGE, 2008).

A Eletroencefalografia (EEG), por sua vez, reconhece a atividade elétrica do cérebro e registra os padrões elétricos das ondas cerebrais. A captura das ondas por meio de sensores é utilizada para inferir excitação e valência (KATSIKIANNIS; RAMZAN, 2017; KOELSTRA et al., 2012).

Outro tipo de medida bastante utilizada é a Eletromiografia (EMG), capaz de medir, através de sensores, os potenciais elétricos gerados pelos músculos durante sua ativação e descanso. Além disso, possui relação com domínio da valência. Esse parâmetro é utilizado para monitorar contrações musculares específicas, como a atividade muscular do rosto (LICHTENSTEIN et al., 2008; MAHLKE; MINGE, 2008).

A pupilometria estuda a dilatação da pupila medindo variações no diâmetro de abertura da pupila. Mahlke (2008) afirma que existe uma relação entre a dilatação da pupila e o prazer de um estímulo.

O componente de Tendências Comportamentais analisa a preparação e o direcionamento do indivíduo em uma determinada atividade, avaliando indicadores de desempenho. Como exemplo, o tempo necessário para realizar uma tarefa, precisão de se alcançar determinado objetivo, assim como o número de erros, de pedidos de ajuda e de ideias criativas durante a interação com a atividade (MAHLKE; MINGE, 2008).

Como mencionado anteriormente, a EMG pode medir a atividade em músculos nos quais as contrações não são visíveis, antes mesmo que as ações sejam iniciadas. A sensibilidade deste indicador permite a detecção de pequenas contrações ao longo do tempo e, possivelmente, tendências de ações simultâneas, embora antagônicas (COPPIN; SANDER, 2016).

Segundo Scherer (2001), as tendências comportamentais estão relacionadas com SNC e são consideradas como preparação e direção de ação. O componente cognitivo é a porção do SNC responsável por processar todas as informações, enquanto os sistemas SNS, SNE e SNA oferecem suporte de referência aos sistemas periféricos responsáveis pela execução das reações fisiológicas. A porção emocional de tendências comportamentais está relacionada com SNC, o componente de expressão motora com o SNS, com reações do comportamento e o sentimento subjetivo, por sua vez, está associado com CNS (SCHERER, 2001).

Os subsistemas apresentados, assim como componentes emocionais, são interligados, caso haja alteração em um dos componentes, os demais componentes também podem sofrer alterações.

O componente de Expressões Motoras analisa expressões faciais, gestos e características do discurso da fala como a velocidade, a intensidade, a melodia, o som e o tom de voz. As medidas de expressões motoras estão relacionadas à expressão facial e corporal, gestos e características da fala. A relação entre emoções e expressões faciais tem sido estudada extensivamente (MAHLKE; MINGE, 2008).

O sistema FACS, uma abordagem que avalia a expressão facial, baseia-se na análise de 44 músculos faciais ativados individualmente ou em combinação por

um indivíduo. Uma pessoa treinada pode categorizar utilizando sistema FACS observado as atividades em relação as seis emoções básicas, independentes da cultura, como o medo, a raiva, a alegria, o desgosto, a tristeza e a surpresa (EKMAN, 1992), assim como um sistema automatizado utiliza esta abordagem para inferir estado emocional.

Para Scherer (2001), o componente de expressões motoras está relacionado com SNS, que comunica as reações e intenção comportamental. O SNS é constituído de fibras nervosas periféricas que enviam informações para o SNC, além de fibras motoras que inervam os músculos esqueléticos, o quais têm movimento voluntário.

A Eletromiografia (EMG) mede a atividade muscular espontânea e é outra forma de estudar a expressão facial. Os sensores são colocados sobre as regiões musculares e detectam sensivelmente a tensão mínima causada pela atividade (MAHLKE; MINGE, 2008).

No componente de Sentimentos Subjetivos, o próprio indivíduo informa o estado emocional. Esse componente apenas permite avaliar um episódio emocional, tornando impossível uma avaliação objetiva do estado emocional (durante a interação, por exemplo, sem interromper o usuário). Para Scherer (2005), o componente de sentimento subjetivo está relacionado ao SNC, monitorando o estado interno e a interação entre organismo e o ambiente.

A avaliação é realizada por meio de questionários de auto-observação (auto avaliação) sobre o que o indivíduo sente ou vivenciou (PINTO, 2001). Uma variedade de escalas estão disponíveis para a autoavaliação, como a escalas SAM (*Self-Assessment-Manikin*), introduzida por Lang (1980). Com figuras de manequins (pictogramas) para cada uma das dimensões de valência, excitação e dominância que representam as respostas emocionais.

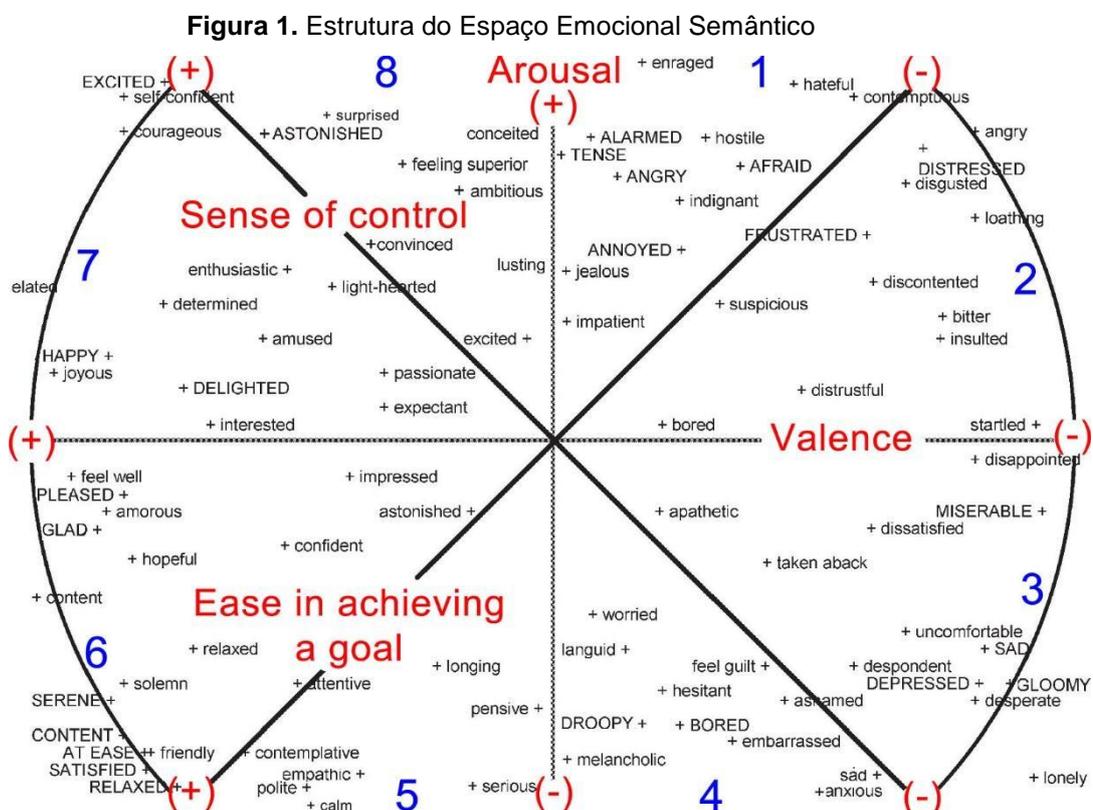
2.1.1 Espaço Semântico de Scherer

Uma das formas de classificação da emoção desenvolvida por Scherer (2005) consiste na extensão do modelo de Russell (1980), composto pelos domínios de valência e excitação. Scherer adicionou dois domínios importantes para diferenciação da emoção: a) *goal conduciveness*, a qual avalia a facilidade de atingir um ou vários objetivos/necessidades e b) *coping potential*, o qual avalia o

sentimento de controle. Ele também fez a inclusão de oitenta termos emocionais na estrutura do espaço emocional semântico (Figura 1) e divisão dos quatro domínios:

- Excitação (*Active/Aroused e Passive/Calm*): domínio fortemente relacionado ao impacto de excitação e à motivação do indivíduo;
- Sentimento de controle (*High Power/Control e Low Power/Control*): reflete o sentimento de controle do indivíduo sobre a interação/dispositivo;
- Valência (*Positive e Negative*): representa o grau de satisfação, prazer e desprazer;
- Facilidade de conclusão do objetivo (*Conducive/Obstructive*): reflete a destreza de alcançar determinado objetivo.

O Espaço Semântico é divisão em oito partes denominados “oitantes”, ademais, essa divisão representa quatro domínios emocionais. Cada domínio possui polos positivos e negativos, com Espaço Semântico (quadridimensional) e a distribuição das emoções discretas no espaço, permitindo representação gráfica e orientação no espaço. Com o mapeamento do estado emocional em determinado oitante do Espaço Semântico, é possível associar um domínio, por exemplo, à baixa valência. A baixa valência contempla os oitantes 1,2,3 e 4. No oitante (1) é possível mapear emoções como raiva, medo, assustado, hostil neste espaço.



Fonte: (GONÇALVES, 2016).

Dessa maneira, nesta dissertação assume-se que a experiência emocional de um indivíduo pode ser avaliada a partir da relação entre as respostas emocionais identificadas pelos sinais fisiológicos e aos oitantes domínios no Espaço Semântico.

2.2 Sinais Fisiológicos e Sensores

As reações fisiológicas permitem a avaliação do estado emocional, considerando que a emoção é motivada por evento ou objeto (estímulo) percebido e processado pelo SS e compartilhada com os demais sistemas do organismo. Entender a relação entre respostas emocionais e atividade fisiológica é de fundamental importância para entender o comportamento humano. Nas últimas décadas, os pesquisadores tentaram identificar os padrões específicos da atividade do SNA associados às diferentes emoções (PECCHINENDA, 2001).

Segundo Brandão (2005), indicadores de emoções podem ser pela resposta galvânica da pele, secreção da boca, atividade cardíaca, atividade respiratória e atividade cerebral. Para coletar sinais fisiológicos os sensores mais populares são: ECG, EEG, RESP e GSR.

2.2.1 Resposta Galvânica

A resposta Galvânica mede a atividade elétrica das glândulas que produzem suor nas palmas das mãos e nos dedos, sendo útil na identificação de situações de estresse e ansiedade. O sinal desta resposta indica as mudanças elétricas na superfície da pele, considerada uma das características mais fortes para detectar a excitação emocional (GUO et al., 2013). Esse reflexo pode ser mensurado pelos seguintes sensores: GSR, EDA, *Skin Conductance* (SC) e *Electrodermal Response* (EDR).

2.2.2 Atividade Cardíaca

A atividade ou frequência cardíaca indica a quantidade de vezes que o coração bate por minuto. A variação dos batimentos é causada por situações do dia

a dia, como a raiva, a alegria, entre outros. O tipo de sensor utilizado para capturar a atividade cardíaca geralmente é colocado no pulso do indivíduo. De acordo com Huynh (2015), a frequência cardíaca consiste em um bom indicador emocional. É medida pelos seguintes sensores: *Blood Volume Pulse (BVP)*, *Electrocardiogram (ECG ou EKG)*, *Cardiografia de impedância (ICG)* e *Photoplethysmography (PPG)*.

2.2.3 Atividade Cerebral

A atividade cerebral está intimamente relacionada às emoções. O monitoramento do funcionamento elétrico do cérebro permite dizer, com até 90% de precisão, qual região está ativada em determinado estado emocional (Chang et al., 2015), sendo medida por EEG e Espectroscopia de Infravermelho (fNIRS). Estudos sobre sinais EEG do cérebro humano mostraram que existe uma conexão entre atividades cerebrais e as emoções (MATIKO et al., 2015).

2.3 Método para Redução de Dimensionalidade

Para a classificação do estado emocional a partir dos sinais fisiológicos é necessário o auxílio dos algoritmos de aprendizado de máquina, dada a complexidade dos dados, assim como filtros para eliminar ruídos e dados inconsistentes dos sinais fisiológicos. Algoritmos de extração de características e redução de dimensionalidade são utilizados para gerar uma base de dados menor com apenas as características de cada amostra, com objetivo de evitar a maldição da dimensionalidade e otimizar a classificação dos dados posteriormente (JAIN; DUIN; MAO, 2000).

O método estatístico desenvolvido por Fisher (1936) maximiza a separação entre classes e minimiza o espalhamento dentro das classes, esta técnica ficou conhecida como *Linear Discriminant Analysis (LDA)* e tem apresentado resultados satisfatórios para sinais fisiológicos e emoções. Dada a quantidade de dados coletados por sensores fisiológicos com grande dimensão de dados, há necessidade de reduzir a quantidade de informações e agrupá-las em classes. A extração de característica transforma um conjunto de sinais fisiológicos em um novo

conjunto de elementos, mas com menor dimensão, com objetivo de evitar a maldição da dimensionalidade e otimizar a classificação dos dados posteriormente (JAIN; DUIN; MAO, 2000).

Para Manly (2008), a análise discriminante trata de avaliar o quanto é possível separar dois ou mais grupos de indivíduos, sendo conferidas medidas para estes indivíduos em várias variáveis. A redução de dimensionalidade e extração de características com LDA é realizada baseada no número de classes, sendo o número de classe menos um ($nClasses - 1$), a dimensão reduzida (TREVOR; ROBERT; JH, 2009).

2.4 Algoritmos de Classificação

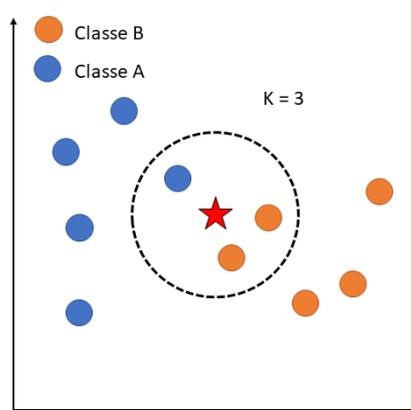
Sinais fisiológicos apresentam variações e complexidade para inferir características (PINTO, 2001). Para classificá-los, Picard (2001) propõe a utilização de algoritmos de aprendizado de máquina, baseados em distância, probabilidade estatística e otimização. Neste trabalho, são abordados algoritmos supervisionados, os quais necessitam de treinamento com base de dados já rotulada. Após o treinamento, o modelo de classificação gerado está apto a receber novas amostras sem rótulos e realizar previsões. Os algoritmos de classificação mais utilizados no contexto de inferência emocional e sinais fisiológicos são apresentados nas próximas subseções.

2.4.1 KNN

O algoritmo KNN é um dos algoritmos mais simples de aprendizado de máquina e é baseado em distância aprimorada, formalizado em 1975 por Fukunaga (1975). Neste algoritmo, o conjunto de dados é formado por vetores n-dimensionais e cada amostra do conjunto de dados representa um ponto no espaço n-dimensional. Assim, é possível calcular as distâncias entre dois pontos. O KNN, após o treinamento, não gera um modelo, apenas armazena os dados; a partir do acréscimo de nova amostra para teste é calculada a distância deste elemento para as demais amostras armazenadas.

O parâmetro K pode ser alterado e indica quantos vizinhos serão analisados e à qual classe pertence. A Figura 2 representa um exemplo de classificação $K = 3$ com duas classes de treinamento, A (azul) e B (laranja), e a nova amostra representada por uma estrela. A variável k representa a quantidade de vizinho mais próximo da nova amostra a ser analisado e a qual classe pertence. Neste caso, das 3 amostras analisadas, duas são da classe B e uma da classe A. Sendo assim, a nova amostra tem mais vizinhos da classe B, sendo, portanto, considerada como classe B.

Figura 2. Exemplo de classificação KNN



Fonte: Elaborada pelo autor

Para calcular a distância no KNN, pode ser utilizado: distância *Euclidiana*, *Manhattan* e *Minkowski*. Segundo Carvalho (2011), a distância *Euclidiana* é mais usual, representada na equação (2.4.1) abaixo:

$$d(X_i, X_j) = \sqrt{\sum_{l=1}^d (x_i^l - x_j^l)^2} \quad (2.4.1)$$

2.4.2 Naive Bayes

O algoritmo de classificação NB está baseado no teorema de *Bayes*, nos métodos probabilísticos bayesianos. O modelo gerado pelo algoritmo de classificação gera uma tabela de probabilidade de acordo com os dados de treinamento apresentados. A principal característica deste algoritmo é desconsiderar a correlação entre os atributos (CARVALHO et al., 2011). A função para os cálculos probabilísticos é apresentada na equação (2.4.2).

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \tag{2.4.2}$$

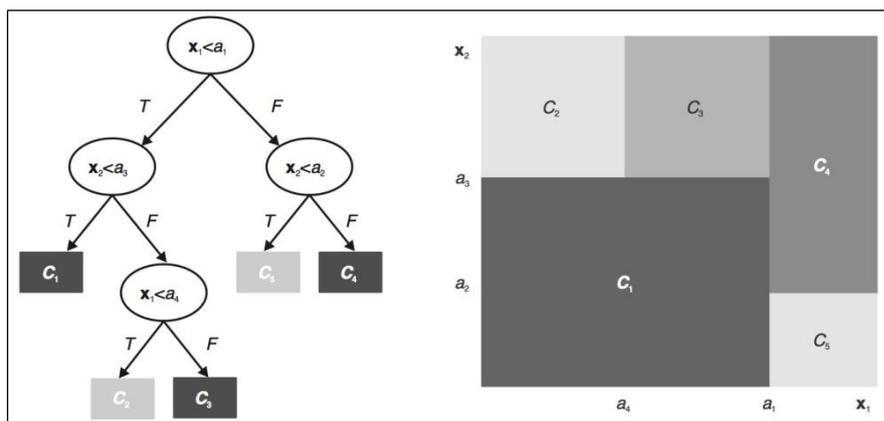
Para realizar a classificação, o algoritmo NB cria uma tabela de frequência dos atributos e posteriormente uma tabela de probabilidade. Quando há uma nova amostra para classificar, o modelo calcula a probabilidade de cada classe. A amostra é inserida na classe que apresentar maior probabilidade.

2.4.3 Árvore de decisão

Uma DT utiliza a estratégia de dividir os espaços de acordo com os dados em regiões separadas para construir um limite de decisão. As regiões são escolhidas de acordo com a otimização heurística, assim, a cada passo o algoritmo seleciona a variável que provê a melhor separação de classes.

Na Figura 3 é apresentada uma DT e mapeamento dos espaços de decisão correspondentes a árvore. Onde X_1 e X_2 representa os atributos, e C_1, C_2, C_3, C_4 e C_5 representando as classes na DT nos nós folhas e no espaço é apresentada as divisões de decisões.

Figura 3. Uma árvore de decisão e o mapeamento das regiões de decisão



Fonte: (CARVALHO et al., 2011)

De acordo com Carvalho (2011), uma DT é um grafo acíclico direcionado, em que cada nó ou é um nó de divisão com dois ou mais sucessores, ou um nó folha. A DT tem a seguinte estrutura: nó raiz sendo início, nós internos correspondendo aos atributos testados e nós folhas determinando as classes e arcos os valores dos atributos.

2.4.4 Random Forest

O algoritmo RF é a combinação de um conjunto de árvores de decisão para obter uma predição com maior acurácia, no qual cada estrutura gerada depende de um subconjunto de dados amostrados de forma independente e que apresentam a mesma distribuição para todas as árvores que formam a floresta.

A ideia do método Florestas de Decisão Aleatória teve início com Ho (1995), com uma abordagem de criar várias árvores em subespaços selecionados aleatoriamente do âmbito de recurso. Já Breiman (2001), aprimorou o método adicionando a seleção aleatória das variáveis preditoras para a árvore de decisão.

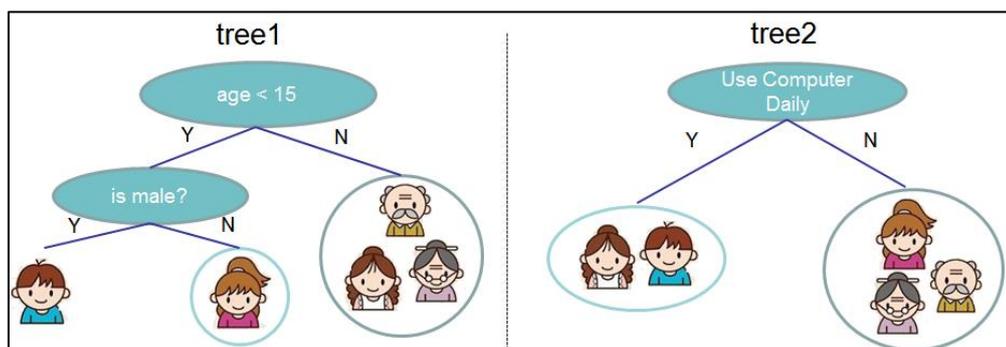
Neste algoritmo, depois que um determinado número de árvores geradas, cada uma lança um voto para uma classe do problema, considerando dados de entrada. Então, a classe mais votada é escolhida e será predição do classificador.

2.4.5 XGBoost

O *XGBoost* (*eXtreme Gradient Boosting*) é um algoritmo otimizado baseado em *Gradient Boosting Decision Tree*. A principal característica é impulsionar as árvores de decisão integradas, buscando melhor desempenho.

Nessa técnica, à cada amostra classificada é atribuída um peso; caso seja categorizada corretamente, o peso diminui; a classificação errada da amostra, por sua vez, aumenta seu peso. Assim é construído um novo marcador que realiza nova iteração e atualização dos pesos. Por fim, a avaliação é obtida pela combinação das DT em diferentes iterações. A Figura 4 apresenta um exemplo de iteração e otimização da árvore de decisão.

Figura 4. Exemplo classificação com XGBoost



Fonte: (CHEN; GUESTRIN, 2016)

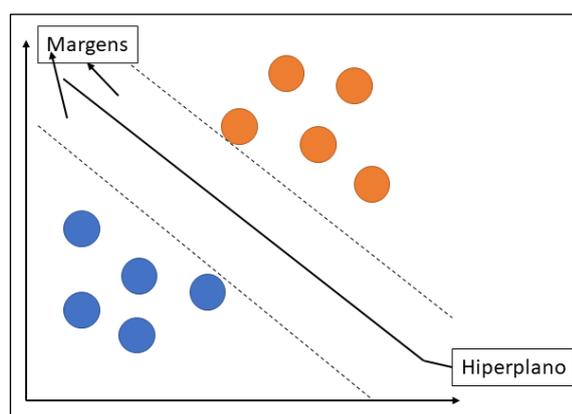
Segundo Zhang (2018), o algoritmo *XGBoost* tem apresentado bom desempenho no *Kaggle*¹ (site de competição de aprendizado de máquina) com premiação em 29 soluções nas competições.

2.4.6 Máquina de vetores de suporte

A SVM é um algoritmo de otimização matemática que implementa um limite derivado da teoria de aprendizagem estatística. Esta técnica tem apresentado bom desempenho em diversos contextos de aprendizado de máquina, além das tarefas de reconhecimento de padrões em bioinformática, processamento de texto entre outros. Os resultados deste algoritmo são comparáveis e, muitas vezes, superiores aos obtidos por outros populares de aprendizado de máquina (CARVALHO et al., 2011).

O SVM tem como objetivo determinar uma linha separando as classes e minimizando erro. Desta forma, a margem de um classificador é definida como a menor distância entre os exemplos do conjunto de treinamento e o hiperplano utilizado na separação desses dados em classes. Na Figura 5, tem-se a separação entre as classes por meio do hiperplano, orientado para maximizar a margem pelo ponto mais próximo da classe.

Figura 5. Exemplo de classificação por meio SVM linear



Fonte: Elaborada pelo autor

¹ <https://www.kaggle.com>

O SVM possui 3 funções de Kernel mais comuns, sendo elas: Polinomial, *Radial Basis Function* (RBF) e *Sigmoidal*. Cada *kernel* tem parâmetros para serem definidos de acordo com as características dos dados.

2.4.7 Redes neurais artificiais

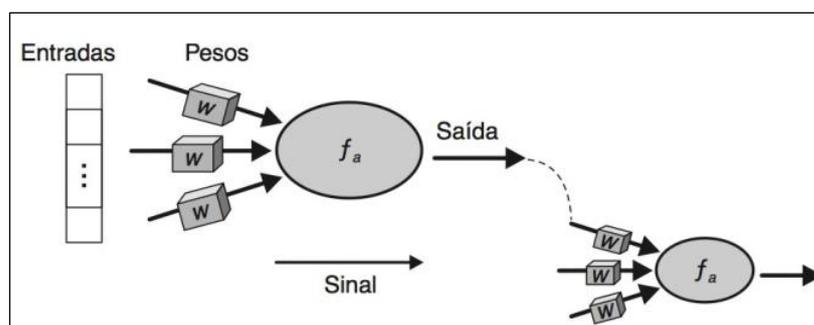
As RNA são modelos computacionais inspirados na estrutura e no funcionamento do sistema nervoso. Trabalhos simulando a capacidade de aprendizado do cérebro humano tiveram início na década de 1940, com McCulloch e Pitts (1943), que desenvolveram um modelo de redes neurais simulando máquinas, com neurônios artificiais que executavam funções lógicas simples.

Uma RNA básica é composta de unidades de processamento simples interconectados conhecidos como neurônios artificiais, que calculam as funções matemáticas. As conexões que simulam as sinapses biológicas possuem pesos, sendo estes positivos ou negativos. Estas conexões simulam o comportamento dos neurônios a partir das entradas recebidas pelas conexões e realiza as operações.

Uma das propriedades mais importantes de uma RNA é a capacidade de aprender por intermédio de exemplos e fazer inferências sobre o que aprendeu. Dessa forma, as RNA são aplicadas em problemas complexos de reconhecimento de padrões.

A Figura 6 demonstra um exemplo de unidade de processamento (neurônio) de uma RNA. Os sinais de entrada que recebem um valor simulam os dendritos. Cada sinal recebido é ponderado e combinado pela função matemática, indicando a sua influência na saída da unidade. A partir da combinação das entradas, produz uma determinada saída.

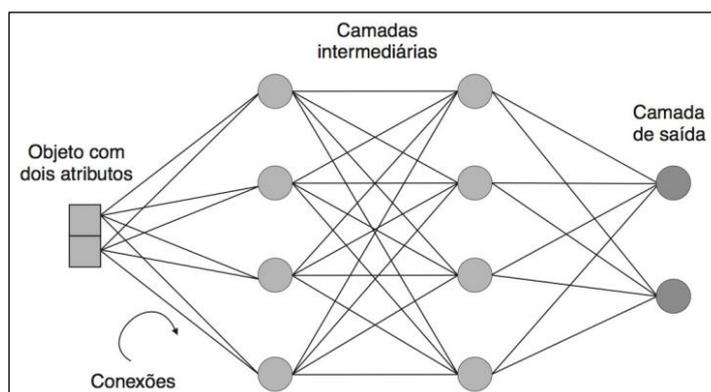
Figura 6. Exemplo neurônio artificial



Fonte: (CARVALHO et al., 2011)

Uma RNA com mais de uma camada de neurônio recebe o nome de multicamada (Figura 7). As camadas são classificadas em camada de entrada onde os dados são apresentados à rede, camadas intermediárias ou escondidas onde grande parte do processamento, através das conexões, é realizado e, por fim, a camada de saída onde resultado final é apresentado.

Figura 7. Exemplo RNA multicamada



Fonte: (CARVALHO et al., 2011)

Para obter melhor desempenho de uma RNA, existem alguns parâmetros para serem ajustados, como: valores dos pesos associados às conexões, função de ativação entre outros.

2.5 Avaliação de algoritmos de classificação

Para avaliação de desempenho dos algoritmos de classificação, a validação cruzada é utilizada para embaralhar os dados, já a acurácia é empregada para analisar a quantidade de erro e acertos de cada avaliação e a matriz de confusão aplicada para análise do desempenho dos algoritmos em cada classe.

2.5.1 Acurácia

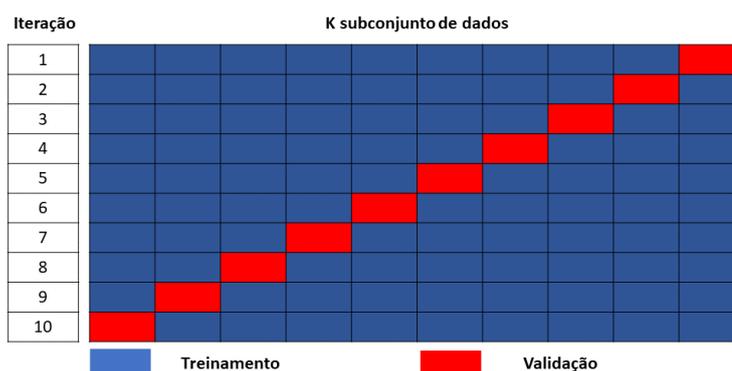
A acurácia é uma métrica de avaliação de desempenho do classificador que considera a quantidade de amostras dos dados pelo número de amostras classificadas corretamente. Por exemplo, para cada base de dados com 300

amostras, são classificados, corretamente, 250 amostras, obtendo-se, assim, uma acurácia de $83\% = 250/300$.

2.5.2 Validação cruzada K-fold

Para comprovação dos testes, usamos a validação cruzada (*K-fold*), dividindo conjunto de dados. Um exemplo é a divisão dos dados em 10 partes (*fold*); destas, 9 treinam o algoritmo de aprendizado, enquanto a outra valida o modelo gerado, repetido 10 vezes, mudando subconjunto de validação, como apresentado na Figura 8. No exemplo abaixo foram utilizadas 10 partes (*fold*), sendo apenas um parâmetro e não regra.

Figura 8. Validação cruzada



Fonte: Elaborada pelo autor

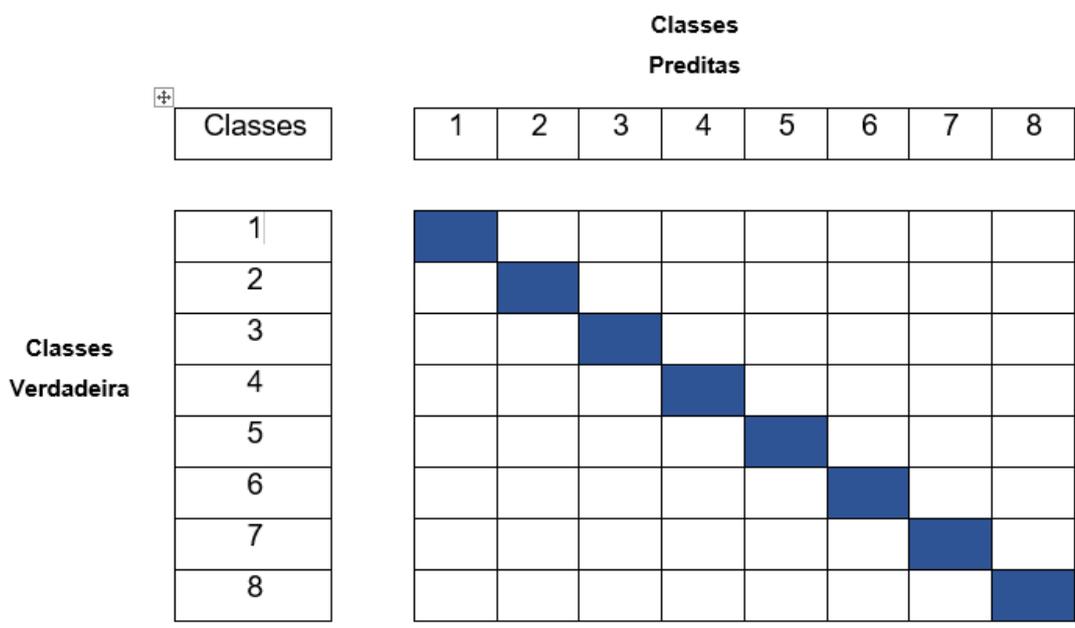
A avaliação de desempenho dos algoritmos de classificação, de acordo com exemplo de 10 partes (*fold*), gera 10 modelos. A cada modelo gerado é testado avaliando a acurácia. Este método é realizado para garantir que os dados sejam embaralhados em várias combinações de amostras, tendo, para cada validação cruzada, a média da acurácia realizada.

2.5.3 Matriz de confusão

A matriz de confusão é uma maneira de visualizar previsões corretas e incorretas de cada classe. Em uma matriz, as linhas representam as classes verdadeiras e as colunas as classes previstas pelo classificador. A Figura 9

apresenta um exemplo de uma matriz de confusão, na qual os valores, que são representados na diagonal principal em azul, são valores preditos corretamente pelo algoritmo.

Figura 9. Exemplo de matriz de confusão



Fonte: Elaborada pelo autor

Como exemplo, na posição (1,1) na classe verdadeira e predita representa o valor classificado corretamente. Portanto, valores que estão na linha (1) da classe verdadeira que não estão na célula marcada de azul, são valores da (classe) 1 classificados errados, no caso (1,2), (1, 3), (1, 4), (1, 5), (1, 6), (1, 7), (1, 8).

2.6 Considerações Finais

Neste Capítulo foram apresentados conceitos fundamentais, como a definição de emoção, modelos e instrumentos para avaliar o estado emocional e componentes emocionais. Além disso, foi apresentado o modelo dimensional de Scherer e os domínios emocionais de excitação, sentimento de controle, valência e facilidade de conclusão de objetivo, bem como os sinais fisiológicos e seus mensuradores, algoritmo de extração de características, diferentes algoritmos de

classificação e seus mecanismos de classificação e métodos de avaliação dos algoritmos.

Com objetivo de identificar métodos de coleta de sinais fisiológicos e algoritmos de classificação do estado emocional, no “Capítulo 3” é apresentada uma revisão da literatura neste contexto.

Capítulo 3

SENSORES E EMOÇÃO: REVISÃO SISTEMÁTICA

O objetivo de realizar esta revisão sistemática consistiu em verificar o estado da arte sobre informações de sinais fisiológicos coletados por sensores para inferir indícios emocionais, assim como métodos e algoritmos para classificação dos sinais.

3.1 Introdução

Como dito, o estado emocional dos usuários influencia na tomada de decisão, assim como em seu comportamento. Sistemas computacionais estão cada dia mais presentes na vida das pessoas, ajudando e influenciando em suas atividades, conseqüentemente, pesquisas buscam respostas para melhorar a classificação do estado emocional utilizando sinais fisiológicos.

Em busca de sensores para a coleta de reações fisiológicas e métodos de reconhecimento de emoções em tempo real. Contudo as emoções se manifestam com a alteração dos componentes, são vários os métodos, técnicas, ferramentas e instrumentos utilizados para a avaliação das emoções. Portanto, apesar recursos disponíveis, a resposta emocional é uma reação complexa, pois envolve todo o organismo do indivíduo, dificultando a sua identificação e classificação.

Foi conduzida uma revisão sistemática para identificar métodos, algoritmos e sensores utilizados para coletar informações do indivíduo e classificar o estado

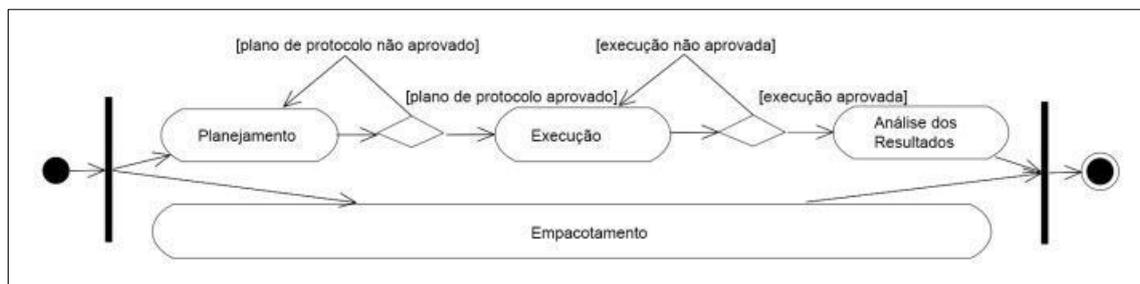
emocional em tempo real. Buscou-se elencar quais dispositivos estão sendo usados, quais métodos de classificação e quais partes do corpo estão sendo observadas.

As buscas foram realizadas em bases de dados eletrônicas identificadas como relevantes para a área da Computação (NAKAGAWA et al., 2017). Dessa forma, as seguintes bases foram escolhidas: *ACM Digital Library*, *SCOPUS Database* e *IEEE Xplore Digital Library*. As buscas nas bases de dados e refinamento da *string* aconteceram no primeiro semestre de 2016. A revisão sistemática foi concluída no final do primeiro semestre de 2017. Foram criadas *strings* de busca para as máquinas de busca, de acordo com a sua sintaxe. Foram retornados 753 artigos a partir das três máquinas de busca, sendo 31 duplicados. Após a aplicação de critérios de inclusão e de exclusão, avaliando-se títulos e resumos, foram aceitos 325 artigos. Na etapa de avaliação dos trabalhos completos, foram aceitos 61 artigos.

3.1.1 Método

A Revisão Sistemática é um método de pesquisa importante no meio científico para a análise de publicações e trabalhos em determinado assunto (Kitchenham, 2004). O processo utilizado na revisão sistemática contempla etapas e atividades definidas e documentadas.

O processo seguido (BIOLCHINI et al., 2005) é composto por três etapas: 1) planejamento, 2) execução e 3) análise dos resultados, como apresentado na Figura 10. Na etapa de planejamento, são definidas as seguintes atividades: a) identificação da necessidade de uma revisão e b) desenvolvimento de um protocolo da revisão. Na etapa de execução são realizadas as atividades definidas de acordo com o protocolo da etapa anterior, com as seguintes atividades: a) pesquisa por estudos nas máquinas de busca, b) seleção dos estudos considerando critérios de inclusão e exclusão do protocolo, c) avaliação da qualidade dos estudos e d) extração de informações dos estudos selecionados. Por fim, na última etapa - análise dos resultados - é realizada uma síntese das informações coletadas. Durante a execução de cada uma dessas etapas, os resultados têm de ser armazenados. Portanto, o empacotamento é realizado durante todo o processo (BIOLCHINI et al., 2005).

Figura 10. Processos da Revisão Sistemática

Fonte: (BIOLCHINI et al., 2005)

Para o gerenciamento das etapas e das atividades do processo da RS, organização dos artigos e documentação, utilizou-se a ferramenta computacional *State of the Art through Systematic Review (StArt)*² como apoio ao pesquisador.

3.1.2 Planejamento

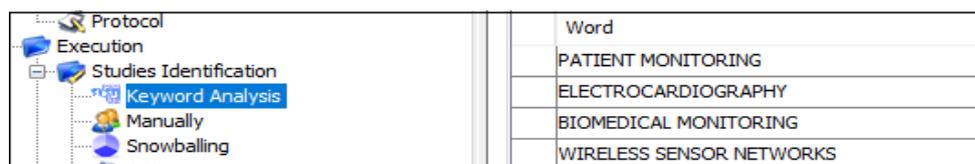
Inicialmente, foram definidas as questões de pesquisa, buscando encontrar quais métodos e sensores estavam sendo usados pelos pesquisadores para análise do estado emocional. As seguintes questões de pesquisa foram identificadas:

- Q1. Em que parte do corpo esses dispositivos são colocados?
- Q2. Quais tecnologias (sensores e algoritmos) são utilizados?

Inicialmente, foram realizadas buscas com uma *string* genérica e, posteriormente, os artigos retornados foram analisados e novas palavras foram adicionadas na *string*. A ferramenta StArt, citada anteriormente, apresenta uma funcionalidade para auxiliar no refinamento da *string*, conforme mostrado na Figura 11.

² http://lapes.dc.ufscar.br/tools/start_tool

Figura 11. Análise de palavras-chave



Word
PATIENT MONITORING
ELECTROCARDIOGRAPHY
BIOMEDICAL MONITORING
WIRELESS SENSOR NETWORKS

Fonte: Elaborada pelo autor

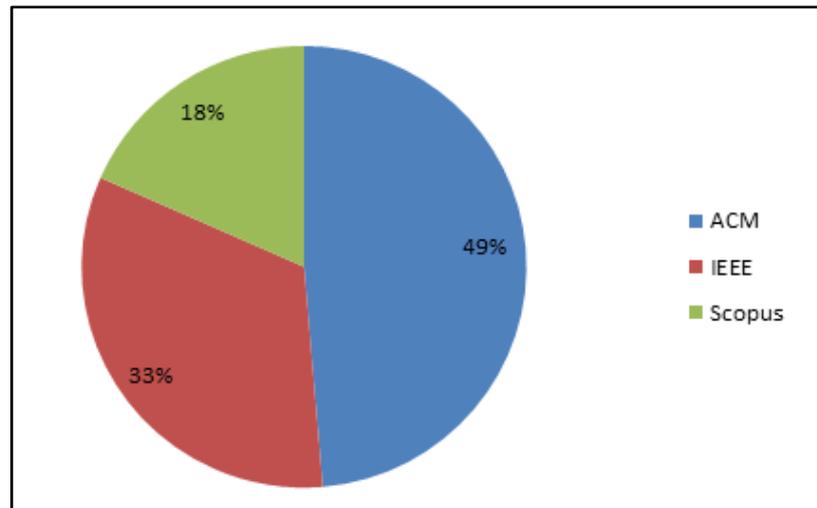
Denominada *Keyword Analysis*, a funcionalidade analisa as palavras repetidas no resumo e título dos artigos, facilitando a localização de sinônimos e termos para refinar a *string*. Por fim, definiu-se a seguinte *string* utilizando operadores do tipo *OR* e *AND* para refinar as buscas: (((*"sensor" AND "emotion"*) AND (*"wearable" AND "emotion"*) AND (*"sensor" OR "vital"*) AND (*"wearable" OR "vital"*) AND (*"wearable sensor" OR "emotion"*) AND (*"adaptive interface" OR "real time" OR "user"*)))

Foram definidos critérios de inclusão e exclusão de modo a guiar o processo de seleção dos artigos. As fases 1 e 2 correspondem a forma como são aplicados os critérios de inclusão e exclusão e a ordem de execução. Na fase 1 são analisados título e resumo e na fase 2 analisa-se o artigo completo. Seguem os critérios de inclusão (I) e exclusão (E):

- (I) Apresentar o uso de sensor vestível e coletar e classificar a emoção em tempo real;
- (I) Trabalhos publicados e disponíveis integralmente em bases de dados científicas;
- (E) Usa sensor que não fornece resposta emocional ao usuário em tempo real;
- (E) Não usa nenhum sensor vestível

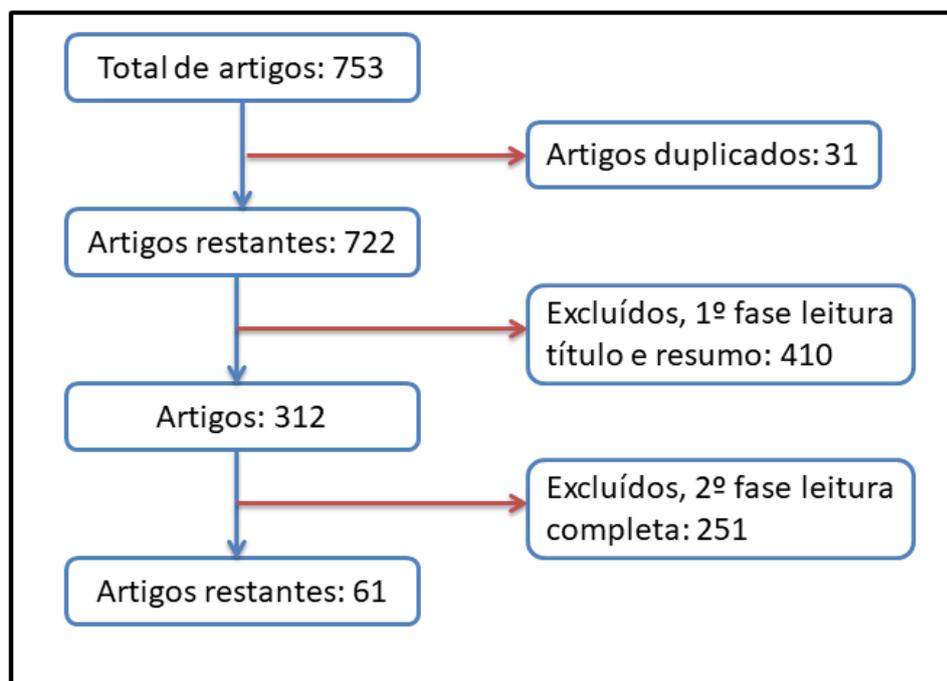
3.1.3 Processo de Seleção

Durante a realização da RS, foram retornados 753 artigos. Na Figura 12 é apresentada a proporção de artigos encontrados em cada máquina de busca (base). Na primeira fase da seleção, 31 artigos duplicados foram identificados e 410 foram rejeitados por não atenderem aos critérios de inclusão. Nesta fase, foram aprovados 312 artigos.

Figura 12. Artigos encontrados por máquina de busca

Fonte: Elaborada pelo autor

Em seguida, na segunda fase, foram excluídos 248 artigos, restando um total de 61 artigos aprovados. A Figura 13 ilustra as etapas do processo de seleção.

Figura 13. Diagrama de seleção dos estudos

Fonte: Elaborada pelo autor

A extração dos dados contou com o apoio da ferramenta computacional StArt que possibilita a criação de um formulário para a coleta dos dados.

3.2 Resultados

Após o processo de seleção, restaram 61 artigos que atenderam aos critérios de inclusão e responderam às questões de pesquisa da RS. Na Tabela 1 são apresentados os artigos aceitos.

Tabela 1. Artigos aceitos

ID	Título	Autores	Ano	Base
1	<i>Jasper: Sensing Gamers' Emotions Using Physiological Sensors</i>	S. Huynhy, Y. Leey, T.Parkz, e R. Krishna Balan	2016	ACM
2	<i>Pervasive and Unobtrusive Emotion Sensing for Human Mental Health</i>	R. Guo, S. Li, L. He, W. Gao, H. Qi, e G.Owenst	2013	ACM
3	<i>MoodMagician - A Pervasive and Unobtrusive Emotion Sensing System using Mobile Phones for Improving Human Mental Health</i>	S. Li, R. Guo, L. He, W. Gao, Hairong Qi, e G. Owens	2014	ACM
4	<i>Zone of Impulse: Physiological Data Enhanced Gaming</i>	K. Reitz, C. Stockhausen, e D. Krömker	2012	ACM
5	<i>Multi-modal Biometric Emotion Recognition Using Classifier Ensembles</i>	L. I. Kuncheva, T. Christy, I. Pierce, e S. P. Mansoor	2011	ACM
6	<i>AffectAura: An Intelligent System for Emotional Memory</i>	D. McDuff, A. Karlson, A. Kapoor, A. Roseway, e Mary Czerwinski	2012	ACM
7	<i>A Discussion of Musical Features for Automatic Music Playlist Generation Using Affective Technologies</i>	D. Griffiths, S. Cunningham, e J. Weinel	2013	ACM
8	<i>Interruptibility of Software Developers and its Prediction Using Psycho-Physiological Sensors</i>	Manuela Zuger e Thomas Fritz	2015	ACM
9	<i>Biometric Valence and Arousal Recognition</i>	C. Martyn Jones e Tommy Troen	2007	ACM
10	<i>Implicit User-centric Personality Recognition Based on Physiological Responses to Emotional Videos</i>	J. Wache, R. Subramanian, M. K. Abadi, Radu-L. Vieriu, N. Sebe, e S. Winkler	2015	ACM
11	<i>A Framework for Psychophysiological Classification Within a Cultural Heritage Context Using Interest</i>	A.J. Karran, S. H. Fairclough, e K. Gilleade	2015	ACM
12	<i>Emotion recognition based on physiological sensor data using codebook approach</i>	K. Shirahama e M. Grzegorzec	2016	Scopus
13	<i>Annotation and Prediction of Stress and Workload from Physiological and Inertial Signals.</i>	(A. Ghosh, M. Danieli, G.Riccardi)	2015	Scopus
14	<i>Reputation-driven Multimodal Emotion Recognition in Wearable Biosensor Network</i>	(Y.Dai, X. Wang, X.Li, e P.Zhang)	2015	IEEE
15	<i>A distributed architecture for multimodal emotion identification</i>	(M. V. Sokolova, A. F.-Caballero, M.T. López, A. Martínez-Rodrigo, R. Zangróniz, e J. Manuel Pastor)	2015	Scopus

16	<i>Real time emotion detection within a wireless sensor network and its impact on power consumption</i>	(J.W. Matiko, S. P. Beeby, e J. Tudor)	2014	Scopus
17	<i>Inference of human affective states from psychophysiological measurements extracted under ecologically valid conditions</i>	(A. Betella, R. Zucca , R. Cetnarski , A.Greco , A Lanatà, D. Mazzei, A. Tognetti, X. D. Arsiwalla, P. Omedas, D. De Rossi , e P. F. M. J. Verschure)	2014	Scopus
18	<i>Wearable device for health care applications</i>	(Prabhakar T.V., Madhuri Sheethala Iyer, Jamadagni H.S., Priyanka P R, Payal Mondal, V. V. S. Sasi Kiran Vaishnavi Govindarajan)	2013	Scopus
19	<i>A wearable multi-sensor system for mobile acquisition of emotion-related physiological data</i>	(Peter, C.a and Ebert, E.a b and Beikirch, H.b)	2005	Scopus
20	<i>EEG-based emotion recognition with brain network using independent components analysis and granger causality</i>	(C.Dongwei, W. Fang, W. Zhen, Li Haifang, e CHEN Junjie)	2013	IEEE
21	<i>Towards Recognition of Rich Non-Negative Emotions Using Daily Wearable Devices</i>	(S. Huynh, R. Krishna Balan, e Youngki Lee)	2015	ACM
22	<i>A Customer Emotion Recognition Through Facial Expression Using Kinect Sensors V1 and V2: A Comparative Analysis</i>	(Le, Hoa T. and Veal, Larry A.)	2016	ACM
23	<i>Empa Talk: A Physiological Data Incorporated Human-computer Interactions</i>	(Myungho Lee, Kangsoo Kim, Hyunghwan Roh, e Si Jung “Jun” Kim)	2014	ACM
24	<i>Adaptive Body Gesture Representation for Automatic Emotion Recognition</i>	(S. Piana, A Stagliano, F. Odone, e A. Camurri)	2016	ACM
25	<i>Semi-automatic Remote Medicine Monitoring System of Miners</i>	(Linlu Liu, Weidan Zhao, Yongjian Yang, e Zhanwei Du)	2015	ACM
26	<i>A Quality Adaptive Multimodal Affect Recognition System for User-Centric Multimedia Indexing</i>	(R.Gupta, M. K. Abadi, J. A. Cárdenes Cabré, F. Morreale, T. H. Falk, e N. Sebe)	2016	ACM
27	<i>Enhancement of Human Computer Interaction with Facial Electromyographic Sensors</i>	(G. Gibert, M. Pruzinec, T. Schultz, e C. Stevens)	2009	ACM
28	<i>Towards in Situ Affect Detection in Mobile Devices: A Multimodal Approach</i>	(A., M. and Jain, Niharika e Steinhafel, Nicholas e Haque, Munir e Ahmed, Ferdous and Ahamed, Shiekh Iqbal e Love, Richard)	2013	ACM
29	<i>Wearable ECG for Tension Assessment in Movie Watching and Adventure Riding</i>	(Hsin-Hsi Tsai e Chih-Wei Yi)	2015	Scopus

30	<i>Wearable EEG headband using printed electrodes and powered by energy harvesting for emotion monitoring in ambient assisted living</i>	(J. W. Matiko, Y. Wei, R. Torah, N. Grabham, G. Paul, S. Beeby, e J. Tudor)	2015	Scopus
31	<i>Using physiological sensors to detect levels of user frustration induced by system delays</i>	(B. Taylor, A. Dey, D. Siewiorek, e A. Smailagic)	2015	Scopus
32	<i>A Kalman filtering framework for physiological detection of anxiety-related arousal in children with autism spectrum disorder</i>	(A. Kushki, A. Khan, J. Brian, e E. Anagnostou)	2015	Scopus
33	<i>An integrated system based on physiological signals for the assessment of affective states in patients with anxiety disorders</i>	(C. D. Katsis, N. S. Katertsidis, e D. I. Fotiadis)	2011	Scopus
34	<i>Emotion monitoring from physiological signals for service robots in the living space</i>	(Kanlaya Rattanyu, Michiko Ohkura, e Makoto Mizukawa)	2010	Scopus
35	<i>Food and Mood: Just-in-Time Support for Emotional Eating</i>	(E. A. Carroll, M. Czerwinski, A. Roseway, M.C. schraefel)	2013	IEEE
36	<i>Eliciting, Capturing and Tagging Spontaneous Facial Affect in Autism Spectrum Disorder</i>	(R. el Kaliouby e A.Teeters)	2007	ACM
37	<i>Impact of Graphical Fidelity on Physiological Responses in Virtual Environments</i>	(V. Ocasio-De Jesus, A. Kennedy, e D. Whittinghill)	2013	ACM
38	<i>DSP.Ear: Leveraging Co-processor Support for Continuous Audio Sensing on Smartphones</i>	(P. Georgiev, N. D. Laney, K. K. Rachuri, C. Mascolo)	2014	ACM
39	<i>Towards Long Term Monitoring of Electrodermal Activity in Daily Life</i>	(C. Kappeler-Setz, F.Gravenhorst, J. Schumm, B. Arnrich, G. Troster)	2013	ACM
40	<i>Health Monitoring Using Gait Phase Effects</i>	(R. Byrne, P. Eslambolchilar, e A. Crossan)	2010	ACM
41	<i>Affective wear: Towards recognizing affect in real life</i>	(K. Masai, Y. Sugiura, K. Suzuki, S. Shimamura, K. Kunze, M. Ogata, M. Inami, e M. Sugimoto)	2015	Scopus
42	<i>Impact of experience sampling methods on tap pattern based emotion recognition</i>	(S. Ghosh, N. Ganguly, P. De, V. Chauhan, e B. Mitra)	2015	Scopus
43	<i>Real-time automatic detection of accelerative cardiac defense response</i>	(G. Fortino e R. Gravina)	2014	Scopus
44	<i>Psychophysiological signals associated with affective states.</i>	(M. Mauri, V. Magagnin, P. Ciproso, L. Mainardi, E. N Brown)	2010	IEEE
45	<i>Applications of sensing platforms with wearable computers</i>	(V. Loseu, H. Ghasemzadeh, S. Ostadabbas, N. Raveendranathan, J. Malan, R. Jafari)	2010	Scopus
46	<i>Automatic quantitative evaluation of emotions in E-learning applications</i>	(S. Scotti, M. Mauri, R. Barbieri, B. Jawad, S. Cerutti, L. Mainardi, E. N. Brown, M. A. Villamira)	2006	IEEE
47	<i>A wearable device for physical and emotional health monitoring</i>	(S. Murali and F. Rincon and D. Atienza)	2015	IEEE

48	<i>ZenTrader, an emotion-reactive interface</i>	(T. Luan Dang, S. Kun Liu, e S. Fels)	2011	Scopus
49	<i>Wearable systems for service based on physiological signals</i>	(Dong-Wan Ryoo, Young-Sung Kim, Jeun-Woo Lee)	2006	Scopus
50	<i>Design of ultra-low-power smart wearable systems</i>	(G. Surrel, F. Rincón, S. Murali, D. Atienza)	2015	IEEE
51	<i>Bio-signal based emotion detection device</i>	(P. Rathod, K. George, e N. Shinde)	2016	IEEE
52	<i>Real-Time Emotion Detection for Neuro-Adaptive Systems</i>	(Kathrin Pollmann)	2015	ACM
53	<i>MAUI: A Multimodal Affective User Interface</i>	(C. L. Lisetti, F. Nasoz)	2002	ACM
54	<i>Cognitive and Context-aware Applications</i>	(S. Rafiqi, S. Nair, e E. Fernandez)	2014	ACM
55	<i>An adaptive user interface based on spatiotemporal structure learning</i>	(H. Lee, Y. Choi, e Y. Kim)	2011	IEEE
56	<i>Evaluation of an adaptive game that uses EEG measures validated during the design process as inputs to a Biocybernetic loop</i>	(K. C. Ewing, S. H. Fairclough, e K. Gillead)	2016	Scopus
57	<i>Design of a Gaze-Sensitive Virtual Social Interactive System for Children With Autism</i>	(U. Lahiri, Z. Warren, e N. Sarkar)	2011	IEEE
58	<i>Intelligent Emotion Decision System for Autonomous Agents</i>	(Xia Mao, Haiyan Bao, e Zheng Li)	2008	IEEE
59	<i>Towards affect detection during human-technology interaction: An empirical study using a combined EEG and fNIRS approach</i>	(K. Pollmann, M. Vukelić, e Matthias Peissner)	2015	Scopus
60	<i>EEG-enabled affective human-computer interfaces</i>	(Olga Sourina e Yisi Liu)	2014	Scopus
61	<i>Dynamic difficulty using brain metrics of workload</i>	(D.I Afergan, E. M. Peck, E. T. Solovey, A. Jenkins, S. W. Hincks, Eli T. Brown, R. Chang, e R. J. K. Jacob)	2014	Scopus

3.2.1 Extração de dados

No contexto desta RS, buscou-se trabalhos que apresentam o uso de sensores para a coleta de informações fisiológicas do indivíduo e os métodos de classificação do estado emocional em tempo real.

Analisando as questões de pesquisa e considerando os diferentes tipos de sensores encontrados, os trabalhos aceitos foram classificados de acordo com as questões de pesquisas. Na Tabela 2 são apresentados os sensores utilizados nos

artigos e em quais locais do corpo esses dispositivos são geralmente colocados, respondendo à questão de pesquisa Q1.

Tabela 2. Tipos de sensores

Sigla	Nome	Colocado em qual parte do corpo	Quantidade de vezes em que aparece em trabalhos	ID Trabalhos
BVP	<i>Blood Volume Pulse</i>	Dedo	6	9, 12, 23, 33, 46, 49
ECG	<i>Electrocardiogram</i>	Pulso	19	7, 10, 11, 14, 17, 19, 20, 26, 29, 30, 31, 32, 34, 43, 44, 47, 50, 51 e 53
EDA	<i>Electrodermal activity</i>	Mão	9	4, 5, 6, 7, 8, 15, 18, 35 e 39
EDR	<i>Electrodermal response</i>	Dedo	1	17
EEG	<i>Electroencephalography</i>	Cabeça	18	1, 5, 8, 10, 11, 14, 16, 19, 26, 30, 44, 45, 46, 52, 56, 59, 60 e 61
EKG	<i>Electrocardiogram</i>	Tórax	2	35 e 46
EMG	<i>Electromyography</i>	Braço	6	12, 15, 19, 27, 41 e 45
FACS	<i>Facial Action Coding</i>	Expressão Facial	12	6, 7, 10, 15, 26, 28, 36, 46, 51, 53, 55 e 58
fNIRS	Espectroscopia de infravermelho	Cabeça	3	52, 59 e 61
GSR	<i>Galvanic skin response</i>	Mão, dedo	17	1, 2, 3, 10, 12, 13, 23, 25, 26, 31, 33, 37, 46, 48, 49, 51 e 53
ICG	Cardiograma de impedância	Tórax	1	1

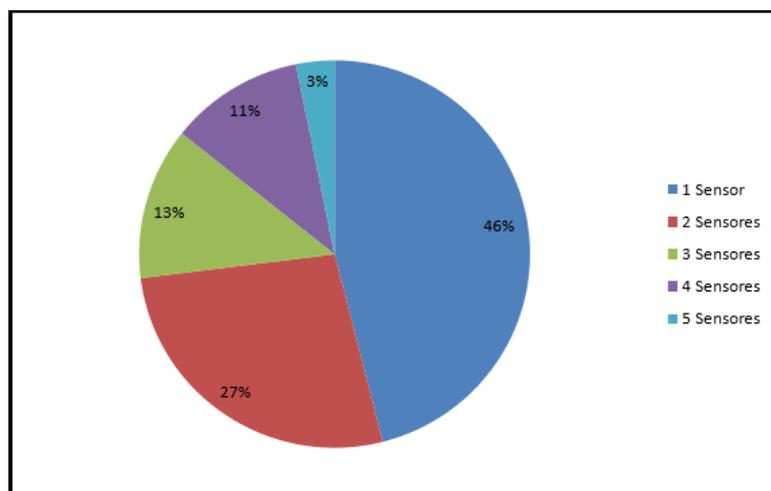
Kinect	Kinect		3	6, 22 e 24
PD	Padrão de digitação		1	42
PPG	<i>Photoplethysmography</i>	Pulso, dedo.	4	1, 13, 21 e 49
PV	Processamento Voz	Celular*	2	38 e 55
RESP	<i>Respiratory monitoring</i>	Tórax	5	9, 12, 33, 44 e 47
RP	Respostas Pupilares	Olho	2	54 e 57
SC	<i>Skin Conductance</i>	Dedo	5	9, 11, 21, 44 e 47
SHAKE	Sensor de movimento	Tórax	1	40
SKT	<i>Skin temperature</i>	Dedo	2	15 e 49

Diversos tipos de sensores de respostas fisiológicas foram apresentados nos artigos, sendo que GSR, EEG e ECG são os sensores mais utilizados pelos artigos da RS. As categorias foram criadas de acordo com tipo de sinal fisiológico, a exemplo, a atividade cerebral e quais sensores coletam este sinal.

Os sensores foram divididos em 6 categorias:

- **Resposta Galvânica:** GSR, EDA, SC e EDR.
- **Atividade Cardíaca:** BVP, EKG ou ECG, ICG e PPG.
- **Atividades Musculares:** EMG.
- **Atividade Cerebral:** EEG e fNIRS.
- **Atividade Térmica da Pele:** Skin Temperature (SKT).
- **Atividade Respiratória:** Respiratory Monitoring (RESP).
- **Sensores Externos:** Respostas Pupilares (PV), FACS, sensores de movimento Kinect ou (SHAKE) com aparelho celular, processamento de voz (PV), utilizando celular, assim como processadores de textos (PD).

Mais de cinquenta por cento (50%) dos artigos analisados usam mais de um sensor para coletar dados do indivíduo e classificar o estado emocional, conforme apresentado na Figura 14.

Figura 14. Quantidade de sensor utilizado por artigo

Fonte: Elaborada pelo autor

Apenas três por cento (3%) utilizaram cinco sensores, onze por cento (11%) usaram quatro sensores, treze por cento (13%) utilizaram três sensores, vinte e sete por cento (27%) contaram com dois sensores para realizar estudo e, por fim, quarenta e seis por centos (46%) usaram apenas um tipo de sensor para a coleta do estado emocional. A combinação entre sensores geralmente acontece entre GSR, EEG, ECG e alguns trabalhos acrescentam o *FACS*.

Para propor um sistema que classifica o estado emocional a partir de sensores, buscou-se na literatura tipos de sensores e algoritmos de classificação. Neste contexto, o algoritmo de classificação recebe os dados do sensor fisiológico, mas, antes, precisam de um treinamento para realizar o reconhecimento de determinados padrões. A análise dos trabalhos da RS respondeu à questão de pesquisa Q2, apresentada na seção 3.1.2, e a Tabela 3 apresenta os métodos de classificação utilizados.

Tabela 3. Algoritmos de classificação

Sigla	Nome	ID Trabalhos
ADA	<i>AdaBoost</i>	5
DT	<i>Decision tree</i>	3, 5 e 8
J48	J48 (Melhoria do ID3)	1 e 22
kNN	k-Vizinho mais próximo	2, 5, 6 e 53
LC	<i>Logistic Classifier</i>	5
LB	<i>LogitBoost</i>	5

LF	Um Sistema de Inferência <i>Fuzzy</i>	7, 16, 58
NB	<i>Naive Bayes</i>	8, 5, 14, 21 e 55
NF	Neuro-Fuzzy	33
RF	<i>Random Forest</i>	1, 5, 13, 21, 22 e 33
RTF	<i>Rotation Forest</i>	5
RNA	Redes Neurais Artificiais	5, 7, 9, 33, 40 e 53
SVM	Máquina de Vetores de Suporte	1, 5, 11, 12, 14, 15, 18, 24, 27, 33, 41, 42 e 60

Entre os algoritmos de classificação mais utilizados, apresentados na Tabela 3, estão: SVM, RF, assim como NB e RNA. Em alguns trabalhos, as técnicas e métodos foram utilizados de maneira a auxiliar na classificação, como a causalidade de *granger*, discriminante linear, distância *mahalanobis*, *kernel gaussiano*, *Fourier*, frequência gaussiana, distância euclidiana, *Kalman filter*, *Sequential Floating Forward Selection* (SFFS) e algoritmo genético.

Os dados fisiológicos são coletados pelos sensores e analisados por um algoritmo de classificação, inferindo o estado emocional. Na Tabela 4 são apresentados os sensores que tiveram como classificador o SVM.

Tabela 4. Sensores que utilizam SVM como classificador

Categoria	Sensor
Resposta Galvânica	GSR, SC, EDA e SCL.
Atividade Cardíaca	PPG, BVP e ECG.
Atividades Musculares	EMG.
Atividade Cerebral	EEG.
Atividade Térmica da Pele	SKT.
Atividade Respiratória	RESP.
Sensores Externos	Kinect, Fotográfico reflexivo e padrões de digitação.

O segundo algoritmo mais utilizado entre os trabalhos analisados é o RF, floresta aleatória. Na Tabela 5, estão representados os sensores e as categorias que usam a RF.

Tabela 5. Sensores que utilizam RF com classificador

Categoria	Sensor
Resposta Galvânica	GSR, EDA e SC.
Atividade Cardíaca	PPG e BVP
Atividade Cerebral	EEG
Atividade Respiratória	RESP
Sensores Externos	Kinect

O terceiro classificador mais utilizado para classificar o estado emocional do indivíduo é NB. Os sensores que tiveram dados analisados por NB são apresentados na Tabela 6.

Tabela 6. Sensores que utilizam NB como classificador

Categoria	Sensor
Resposta Galvânica	EDA e SC
Atividade Cardíaca	PPG
Atividade Cerebral	EEG
Sensores Externos	Expressões faciais e processamento de voz

Por fim, o quarto classificador mais utilizado pelos trabalhos analisados da revisão sistemática é RNA. Na Tabela 7 podem ser vistos os sensores cujos dados foram classificados com RNA.

Tabela 7. Sensores que utilizam RNA como classificador

Categoria	Sensor
Resposta Galvânica	SC e GSR
Atividade Cardíaca	BVP e ECG
Atividade Respiratória	RESP
Sensores Externos	SHAKE e expressões faciais

3.3 Considerações Finais

Considerando a importância dos sinais fisiológicos e algoritmos de classificação, este capítulo apresentou uma revisão sistemática de literatura sobre a utilização de técnicas e métodos que coletam informações do usuário e classificam o estado emocional. Essa revisão sistemática foi realizada com o objetivo de apresentar uma visão geral do estado da arte para auxiliar pesquisadores durante o desenvolvimento de novas investigações.

A análise dos dados permite concluir que, entre os trabalhos considerados nesta revisão, há abordagem de reconhecimento de emoções com diferentes sensores e métodos de classificação. Foi possível compreender a utilização de sensores neste contexto, quais classificadores são adequados para cada tipo de dados e os diversos tipos de sensores aplicados para a coleta do estado emocional, capturando diferentes sinais fisiológicos. No próximo capítulo, serão apresentados os trabalhos relacionados.

Capitulo- 4

TRABALHOS RELACIONADOS

4.1 Considerações iniciais

Este trabalho tem por objetivo a criação um *dataset* (base de dados) para apoiar a captura de sinais fisiológicos com sensores comerciais de baixo custo. E a análise dos indícios emocionais, além da classificação de emoções dimensionais em oito classes. Assim como avaliar quais algoritmos de classificação se adequam às características de cada sinal fisiológico.

Existem vários métodos para avaliar o estado emocional do indivíduo, mas os sinais fisiológicos têm se apresentado como uma boa opção para avaliação em tempo real. Com objetivo de conhecer outros *dataset* e suas características, a Seção 4.2 apresenta trabalhos relacionados à essa pesquisa.

4.2 *Dataset* de sinais fisiológicos

Atualmente, *dataset* de sinais fisiológicos, com rótulos emocionais, são utilizados para treinar algoritmos de aprendizado de máquina gerando modelos de classificação, além de avaliar o desempenho dos algoritmos com diferentes características de dados. Para a criação de um *dataset* de sinais fisiológicos emocionais, estímulos são necessários para que o indivíduo atinja determinado

estado emocional. Desse modo, os estímulos mais utilizados são imagens, trechos de filmes, vídeos e músicas (ABADI et al., 2015; KOELSTRA et al., 2012; PICARD; VYZAS; HEALEY, 2001). Após a coleta dos dados, buscou-se reconhecer o padrão dos sinais fisiológicos para cada emoção.

O desenvolvimento tecnológico dos últimos anos foi responsável pelo aprimoramento dos sensores para coleta de sinais, assim como sua popularização, além do aumento nos trabalhos do reconhecimento das emoções utilizando sensores. Os trabalhos mais relevantes que basearam esta dissertação são apresentados na Tabela 8. O modelo dos sensores utilizados, o custo de cada sensor e os domínios emocionais classificados.

Tabela 8. Trabalhos relacionados

ID	Título	Autor	Sensores	Custos	Domínios	
1	<i>ASCERTAIN: Emotion and Personality Recognition using Commercial Sensors</i>	(SUBRAMANIAN et al., 2016)	EEG	<i>MindWave</i> \$79,99	Valência e Excitação	
			ECG	Não informou modelo		
			GSR	Não informou modelo		
2	<i>DEAP: A Database for Emotion Analysis Using Physiological Signals</i>	(KOELSTRA et al., 2012)	EEG	<i>Biosemi ActiveTwo system</i> EUR 21000,00	Valência, Excitação e Gosto	
3	<i>DECAF: MEG-Based Multimodal Database for Decoding Affective Physiological Responses</i>	(ABADI et al., 2015)	MEG	Não informou modelo	Valência, excitação e dominância	
4	<i>DREAMER: A Database for Emotion Recognition through EEG and ECG Signals from Wireless Low-cost Off-the-Shelf Devices</i>	(KATSIGIANNIS; RAMZAN, 2017)	EEG	<i>Emotiv EPOC</i> \$799,00	Valência, excitação e dominância	
			ECG	Shimmer \$508,10		
5	<i>MAHNOB-HCI A Multimodal Database for Affect Recognition and Implicit Tagging</i>	(SOLEYMANI et al., 2012)	EEG, EEG, GSR, Respiration e temperatura da pele	<i>Biosemi activeTwo system</i> EUR 21000,00	Valência e excitação	
6	<i>Toward Machine Emotional Intelligence: Analysis of Affective Physiological State</i>	(PICARD; VYZAS; HEALEY, 2001)	EMG, BVP, SC e Respiration	ProComp \$ 3995,00	Valência e excitação	
7	Dataset proposto		EEG	<i>MindWave</i> \$79.99	Valência, Excitação, Sentimento de controle e Facilidade de conclusão do objetivo	
			ECG	\$23,87		\$19,80
			GSR	\$9,90		

Na sequência são apresentados detalhes da criação dos trabalhos relacionados, como foram criados *dataset*, tipo de estímulos, número de participantes, ferramentas utilizadas para pré-processamento e classificação dos sinais, assim como o modelo dos sensores utilizados e o custo dos mesmos.

4.2.1 ASCERTAIN

O *dataset ASCERTAIN* proposto por Subramanian (2016) utilizou os sensores ECG, EEG e GSR para compor o conjunto de dados. No entanto, os modelos dos sensores ECG e GSR não foram informados, para EEG foi utilizado *MindWave* com valor de \$ 79,99 dólares (Tabela 8).

Para o pré-processamento dos dados e armazenamento foi utilizada a ferramenta MATLAB Psychtoolbox³. O sensor que apresentou maior perda de dados durante a coleta, com inconsistência de dados faltantes, foi EEG, seguido do ECG. O sensor GSR obteve a menor perda de informações entre os sensores fisiológicos utilizados.

Com base no *circumplex* de Russell (1980), analisou-se os domínios emocionais de Valência e Excitação. Para o processo de extração das características aplicou-se o LDA, e para classificação dos domínios emocionais foram adotados os algoritmos NB e SVM.

Na Tabela 9 são apresentadas as acurácias (taxa de acerto) por sensores e algoritmos. Os dados do sensor GSR apresentou o melhor desempenho para reconhecimento, tanto para Excitação quanto para Valência. O sensor EEG apresentou melhor resultado para reconhecer Excitação quando comparado com Valência. Os demais sensores obtiveram melhor desempenho para reconhecer Valência. Quanto aos algoritmos, NB alcançou o melhor desempenho do que o SVM.

³ <http://psychtoolbox.org/>

Tabela 9. Classificação domínios emocionais NB e SVM

Sensores	ECG		GSR		EEG		(ECG + GSR)	
	SVM	NB	SVM	NB	SVM	NB	SVM	NB
Valência	0,56	0,60	0,64	0,68	0,56	0,60	0,69	0,71
Excitação	0,57	0,59	0,61	0,66	0,58	0,61	0,64	0,67

Fonte: (SUBRAMANIAN et al., 2016)

Este trabalho não teve como objetivo somente o reconhecimento de emoções, mas também a identificação das personalidades. O desenvolvimento deste estudo contou com a participação de 58 indivíduos, além de 36 clips de vídeos utilizados como estímulos, com cerca de 90 minutos de duração para cada sessão do experimento.

4.2.2 DEAP

O *dataset* DEAP, proposto por Koelstra (2012), utilizou o sensor EEG com 32 eletrodos ativos colocados de acordo com o sistema internacional 10-20. Os mensuradores EOG, EMG, GSR, BVP, da temperatura da pele e respiração foram considerados sensores fisiológicos periféricos e foram agrupados às informações do EEG.

O sistema utilizado para gravação dos sinais foi Biosemi Active Two⁴. Com os sensores, este equipamento fica no valor de EUR 21000,00. Tiveram 32 participantes assistindo a 40 trechos de vídeos como estímulo emocional. Os indivíduos foram avaliados em duas etapas: assistiam 20 trechos de vídeos e continuavam a assistir por mais 20 minutos, após um período de pausa. Para o pré-processamento dos dados, foi utilizada a ferramenta EEGLab6 toolbox⁵ e considerados os 30 segundos finais da coleta com estímulos.

Na Tabela 10 é apresentada a acurácia média do algoritmo de classificação NB com dados do sensor EEG e dos sensores periféricos, com classes de domínios emocionais.

⁴ <http://www.biosemi.com>

⁵ <https://sccn.ucsd.edu/eeglab/index.php>

Tabela 10. Classificação domínios emocionais com algoritmo NB

Sensores	Excitação	Valência	Gosto
EEG	0,620	0,576	0,554
Periféricos	0,570	0,627	0,591

Fonte: (KOELSTRA et al., 2012)

Foi realizada a avaliação estatística da correlação da frequência de cada eletrodo. Para extração de características, foi utilizado LDA e para classificação, o algoritmo NB.

4.2.3 DECAF

O dataset DECAF, proposto por Abadi (2015), utilizou o sensor de sinais cerebrais *Magnetoencephalogram* (MEG), o qual requer pouco contato físico com o couro cabeludo do indivíduo, o que facilita a coleta das respostas emocionais. Também utilizou o EOG, de modo a coletar informações sobre movimentações oculares, piscadas do olho e atividade muscular facial, assim como o ECG, para extrair informações dos batimentos cardíacos.

A falta de informações dos modelos dos sensores EOG e ECG impossibilitou o levantamento dos valores dos mesmos. Já com o sensor MEG, apesar do modelo especificado, não foi possível realizar cotação, ainda que tratando-se de um equipamento específico da medicina.

Para a coleta dos dados e sincronização do estímulo, foi utilizado o dispositivo ELEKTA Neuromag⁶ em uma sala com iluminação controlada. Devido à sensibilidade do sensor MEG, todos os outros dispositivos utilizados para aquisição das informações foram colocados em uma sala adjacente. Para salvar e pré-processar os dados, foram utilizados as ferramentas MATLAB Psychtoolbox⁷ e MATLAB Fieldtrip⁸.

Este trabalho teve como objetivo analisar a diferença entre estímulos musicais e trechos de filmes, tal qual seus impactos no reconhecimento de emoções

⁶ <https://www.elekta.com/diagnostic-solutions/elekta-neuromag-triux/>

⁷ <http://psychtoolbox.org/>

⁸ <http://www.fieldtriptoolbox.org/>

a partir de sinais fisiológicos. Sensores EOG e ECG são considerados como sensores periféricos. Para classificação dos sinais fisiológicos, tanto do MEG quanto dos sensores periféricos, foi utilizado o algoritmo SVM.

Na Tabela 11 estão representados os resultados do *dataset* DECAF com estímulos musicais e trechos de filmes, no algoritmo de classificação SVM.

Tabela 11. Resultado classificação SVM *dataset* DECAF

Sensores	Valência	Excitação	Dominância
MEG	0,59	0,62	0,62
Periférico	0,60	0,55	0,50

Fonte: (ABADI et al., 2015)

O experimento contou com 30 participantes e a obtenção dos elementos foi dividida em duas sessões, sendo a primeira sessão com estímulos de trechos de filmes e a segunda sessão com vídeos musicais. A fim de evitar objetos de metal no ambiente de coleta, os participantes trocavam roupas e sapatos e aqueles que usam óculos receberam substituição sem metal. Antes de começar a gravação dos dados cada participante ficou de repouso por 5 minutos.

4.2.4 DREAMER

O *dataset* DREAMER, proposto por Katsigiannis (2017), tem como fonte de informações dois sensores fisiológicos ECG e EEG, sendo a coleta realizada em ambiente controlado, no qual os participantes assistiram trechos de filmes como estímulos. Foram utilizados dois trechos de filmes para estimular cada uma das 9 emoções: divertimento, excitação, felicidade, calma, raiva, nojo, medo, tristeza e surpresa. Cada fragmento possuía, em média, 199 segundos. Dessa forma, para a avaliação do estado emocional, foram analisados 60 segundos finais de cada coleta.

O sensor EEG utilizado neste trabalho foi Emotiv EPOC⁹ com 14 canais, cotado em \$799.00 dólares e SHIMMER ECG¹⁰, no valor de \$508.10 dólares. Para o pré-processamento e análise das informações, foi utilizado o ambiente MATLAB e EEGLAB.

⁹ <https://www.emotiv.com/product/emotiv-epoc-14-channel-mobile-eeeg/>

¹⁰ <http://www.shimmersensing.com/products/shimmer3-ecg-sensor>

Os domínios emocionais considerados neste trabalho são Valência, Excitação e Dominância. Na Tabela 12 são apresentadas as acurácias de classificação dos domínios emocionais e dos sensores EEG e ECG e dos dois sensores juntos.

Tabela 12. Resultado classificação SVM *dataset* DREAMER

Sensores	Valência	Excitação	Dominância
EEG	0,6249	0,6217	0,6184
ECG	0,6237	0,6237	0,6157
(EEG + ECG)	0,6184	0,6232	0,6184

Fonte: (KATSIGIANNIS; RAMZAN, 2017)

O algoritmo de classificação usado foi SVM com *kernel* RBF. Os classificadores 3-NN, 5-NN, 7-NN, LDA e SVM com núcleo linear também foram avaliados usando o mesmo procedimento, mas não conseguiram produzir resultados estatisticamente significativos para todos os casos examinados. Para avaliar desempenho dos classificadores, utilizou-se a validação cruzada com 10-fold.

4.2.5 MAHNOB-HCI

O *dataset* MAHNOB-HCI, proposto por Soleymani (2012), teve como principal sensor EEG e os sensores periféricos GSR, ECG, *RESP* e temperatura da pele.

Para essa análise, foram utilizados 27 indivíduos que assistiram a 20 vídeos como estímulos emocionais, distribuídos nos domínios de valência e excitação. Antes de cada um desses vídeos, o participante assistia a outro vídeo, com estímulo neutro.

Para a classificação, foi utilizado SVM com *kernel* RBF, a ferramenta MATLAB e biblioteca libSVM e para a avaliação de desempenho do algoritmo utilizou-se de validação cruzada com 20 *fold*. A Tabela 13 demonstra as médias das acurácias obtidas de valência e excitação com sensor EEG e sensores periféricos.

Tabela 13. Resultado classificação SVM dataset MAHNOB-HCI

Sensores	Valência	Excitação
EEG	57,0%	52,4%
Sensores Periféricos	45,5%	46,2%

Fonte: (SOLEYMANI et al., 2012)

O sensor EEG utilizado tinha 32 canais e, para a coleta dos sinais ECG e EEG, aplicou-se a ferramenta *Biosemi active II system*¹¹. Os sensores e equipamento de coleta foram cotados em torno de EUR 21000.00 euros.

4.2.6 Toward Machine Emotional Intelligence: Analysis of Affective Physiological State

O *dataset* proposto por Picard (2001) opera com os seguintes sensores: BVP, EMG, SC e *Respiration*, cotados em \$ 3995.00 dólares, somado os equipamentos de coleta. Para estímulos emocionais, foi utilizado conjuntos de imagens. A coleta dos dados ocorreu no período de 6 semanas, com sessões diárias de 25 minutos, sempre no mesmo horário. Este estudo avaliou apenas um indivíduo, com objetivo de encontrar padrões característicos para diferentes emoções. A obtenção das informações foi dividida em 2 partes, a primeira delas, compreendendo 19 dias de coleta com estímulos de 8 emoções, considerando apenas os 100 segundos finais dos sinais de cada sensor, e a segunda foi realizada por 20 dias e levou em consideração todo o seguimento de coleta, não apenas a fração final.

O algoritmo *Maximum a Posteriori* (MAP) foi utilizado para classificação. Os dados passaram por extração de características com LDA e seleção das mesmas com SFFS. Este trabalho utilizou também uma versão híbrida do LDA com SFFS para escolha das amostras.

Com a seleção e extração de características, o melhor desempenho do algoritmo de classificação foi de 87% para valência, 84% para excitação e 81% de acurácia quando as 8 emoções foram categorizadas.

¹¹ <http://www.biosemi.com>

4.3 Considerações finais

Neste capítulo foram apresentados trabalhos que criaram e analisaram *dataset*. Cinco dos trabalhos utilizaram somente um algoritmo de classificação para análise dos dados (ABADI et al., 2015; KATSIKIANNIS; RAMZAN, 2017; KOELSTRA et al., 2012; PICARD; VYZAS; HEALEY, 2001; SOLEYMANI et al., 2012; SUBRAMANIAN et al., 2016), sendo os algoritmos: NB, MAP e SVM com kernel RBF. Apenas um dos trabalhos utilizou dois algoritmos de classificação (SUBRAMANIAN et al., 2016), NB e SVM. Portanto, não há diversificação dos métodos de classificação aplicados, sendo apenas três diferentes, deixando algoritmos potenciais fora da análise.

Os domínios emocionais classificados por dois trabalhos foram a Valência e Excitação e a dominância (ABADI et al., 2015; KATSIKIANNIS; RAMZAN, 2017). Koelstra (2012) utilizou Valência, Excitação e uma emoção discreta. Os demais trabalhos classificaram apenas os domínios de Valência e Excitação. Pesquisas apontam a necessidade de quatro domínios para representar emoções (FONTAINE et al., 2007).

Os custos dos sensores e equipamentos de coleta de sinais, variaram para cada trabalho. No entanto, MAHNOB-HCI (SOLEYMANI et al., 2012), DEAP (KOELSTRA et al., 2012) e (PICARD; VYZAS; HEALEY, 2001) utilizaram equipamentos com valores mais altos (Tabela 8). Já DREAMER (KATSIKIANNIS; RAMZAN, 2017) e ASCERTAIN (SUBRAMANIAN et al., 2016) fizeram uso de equipamentos de baixo custo, aproximando-se deste trabalho. Entretanto, este *dataset* proposto teve custo de \$133,56 dólares com sensores e equipamentos para coleta de dados, sendo detalhado no Capítulo 5.

Com o objetivo de criar *dataset* de sinais fisiológicos e com rótulos do Espaço Semântico contemplando domínios de Valência, Excitação, Sentimento de Controle e Facilidade de Conclusão do Objetivo, no Capítulo 5, são detalhados sensores, estímulos e protocolo do experimento para coleta dos dados.

Capítulo 5

COLETA DE DADOS DOS SENSORES FISIOLÓGICOS

A coleta dos sinais fisiológicos foi realizada enquanto os participantes assistiam a trechos de filmes e videoclipes com estímulos de determinado estado emocional pré-classificados, com o objetivo de induzir o indivíduo a determinado estado emocional.

5.1 Considerações iniciais

Este capítulo descreve o preparo para coleta de sinais fisiológicos e de dados para criação do *Dataset*. Está organizado da seguinte forma: a Seção 5.2 justifica a Seleção de filmes, a Seção 5.3 descreve os Procedimentos do experimento, a Seção 5.4. apresenta a Coleta de sinais fisiológicos. Na sequência, a Seção 5.5 trata das Considerações Finais.

5.2 Seleção de filmes

Para que os participantes tivessem alterações no estado emocional, neste experimento, foram utilizados trechos de filmes e videoclipes pré-classificados no que se refere às emoções. Os trechos de filmes e videoclipes são estímulos para levar o indivíduo ao estado emocional no qual já está classificado.

Para a seleção de estímulos, seguiu-se os seguintes critérios: estímulos pré-classificados na literatura, formato de vídeos de curta duração, sem cenas ou imagens fortes que levem o participante a constrangimento ou desconforto, termos emocionais dos estímulos utilizados relacionados no Espaço Semântico de (SCHERER, 2005). Assim, foi possível mapear as emoções no Espaço Semântico, preenchendo os oitantes.

Os trechos de filmes e clipes utilizados foram pensados e escolhidos a partir de base de dados já classificadas (SCHAEFER et al., 2010) ou de trabalhos neste mesmo contexto de classificação de estado emocional por sinais com outros sensores (KOELSTRA et al., 2012). Na Tabela 14 estão representados os nomes, assim como as bases de vídeos utilizadas, estímulo emocional classificados e oitante do Espaço Semântico de Scherer (2005), na qual a emoção está mapeada. O Espaço Semântico de Scherer apresenta oitantes (8 divisões) e quatro domínios emocionais com os polos positivo e negativo, os estímulos emocionais foram distribuídos neste espaço. Considera-se que o participante apresentou as mudanças no estado emocional durante cada estímulo que foi apresentado durante o experimento.

O estímulo um (1) da Tabela 14, foi apresentado o trecho do filme *Schindler's list*. O trecho retrata campos de concentração onde pessoas estão sendo mortas. Logo o estímulo leva o participante a sentir raiva, a qual é mapeada no espaço semântico no oitante 1.

Tabela 14. Base de vídeos e emoções.

ID	Base de vídeos	Vídeo	Emoção	Oitante
1	(SCHAEFER et al., 2010)	<i>Schindler's list</i>	Raiva	1
2	(KOELSTRA et al., 2012)	<i>Corporate Cannibal</i>	Assustador/Medo	1
3	(KOELSTRA et al., 2012)	<i>Bastard Set Of Dreams</i>	Odioso	1
4	(SCHAEFER et al., 2010)	<i>Honey</i>	Nojo	2
5	(KOELSTRA et al., 2012)	<i>Goodbye My Almost Lover</i>	Depressivo	3
6	(SCHAEFER et al., 2010)	<i>E.T.</i>	Triste	4
7	(KOELSTRA et al., 2012)	<i>How To Fight Loneliness</i>	Melancólico	4

8	(HOWARD, 2014)	<i>My Girl</i>	Empatia	5
9	(HOWARD, 2014)	<i>Bridget Jones Diary</i>	Amor/Amoroso	6
10	(KOELSTRA et al., 2012)	<i>New York I Love You But You're Bringing Me Down</i>	Calma	6
11	(KOELSTRA et al., 2012)	<i>Her Morning Elegance</i>	Relaxado	6
12	(KOELSTRA et al., 2012)	<i>Listen To Your Heart (Edmee's Unplugged Vocal Edit)</i>	Satisfeito	6
13	(SOLEYMANI et al., 2012)	<i>Love actually</i>	Feliz	7
14	(KOELSTRA et al., 2012)	<i>5 Years Time</i>	Alegre	7
15	(KOELSTRA et al., 2012)	<i>Tango</i>	Apaixonado	7
16	(BARTOLINI, 2011)	<i>Ratatouille</i>	Excitação/ agitação	8

As emoções classificadas nos vídeos (estímulos) foram mapeadas no Espaço Semântico de acordo com os termos emocionais distribuídos por Scherer (2005) no espaço (Figura 1). Os estímulos foram distribuídos nos oitantes correspondentes: nos oitantes dois, três, cinco e oito, com um estímulo; no oitante quatro com dois estímulos; nos oitantes um e sete são três estímulos e, por fim, quatro estímulos no oitante seis.

5.3 Procedimentos do experimento

Esta Seção apresenta uma breve descrição do experimento e as tarefas realizadas, além dos riscos e o tempo estimado, conforme o protocolo apresentado no Apêndice C, buscando minimizar qualquer desconforto do participante.

Como este experimento envolve usuários, ele foi submetido e aprovado pelo Comitê de Ética em Pesquisa, sob CAAE 92229318.9.0000.5504, no Anexo B. A

pesquisa foi amplamente divulgada e os participantes foram convidados, tanto da comunidade externa quanto da interna, por meio de e-mail e redes sociais.

Para serem incluídos na pesquisa dos indivíduos, tiveram que preencher os seguintes critérios: idade superior a 18 anos e terem completado o ensino médio. Foram adotados, como critérios de exclusão: presença de problemas cardíacos e hiperidrose.

Com o aceite na participação, o voluntário foi instruído a ler o Termo de Consentimento Livre e Esclarecido (TCLE), Apêndice D, e a Autorização de Captação de Imagem, Som e Nome, conforme o Apêndice E. Em seguida, o participante respondeu um questionário de informações demográficas, como idade, sexo e grau de escolaridade, problemas de saúde e frequência que assistem filmes, mostrado no Apêndice A.

Participaram desta pesquisa 33 pessoas com ensino médio completo, na faixa de idade de 18 a 35 anos, 25 participantes do sexo masculino e 8 participantes do sexo feminino. Em função do horário e da disponibilidade, nem todos os participantes estiveram em todas as sessões. Na primeira sessão, 33 participantes assistiram a 5 trechos de vídeos. Na segunda sessão, 26 indivíduos assistiram a 5 fragmentos. Na terceira sessão, por sua vez, estavam presentes 20 membros que presenciaram 6 vídeos, totalizando 16 vídeos por usuários. Dessa forma, considerando o número de participantes e de vídeos, foram 415 amostras de dados brutos.

Na sequência, os sensores foram colocados no corpo do participante, tendo os eletrodos do ECG adesivo aderente e uma capa plástica para manter o gel, responsável pelo aumento da condutividade, GSR nos dedos e EEG em formato de fone de ouvido na cabeça.

Foram realizadas as divisões em 3 sessões de aproximadamente 45 minutos. Nas duas primeiras sessões, o participante assistiu a 5 trechos de filmes ou vídeos e na última sessão assistiu a 6 trechos de filmes ou vídeos, totalizando 16 vídeos. O tempo dos vídeos variam entre 2 - 5 minutos. A cada trecho assistido, foi realizado uma pausa de 3 minutos, com objetivo de permitir que o participante repouse entre os diferentes estímulos emocionais, seguindo padrão de experimentos anteriores (ABADI et al., 2015; KOELSTRA et al., 2012; SUBRAMANIAN et al., 2016).

Enquanto assistia ao vídeo, os participantes foram orientados a falar o que estavam sentindo no momento, no final de cada trecho assistido responderam ao questionário SAM, apresentado no Anexo A. Ao final da sessão, o participante respondeu ao questionário pós-sessão, apresentado no Apêndice B, uma avaliação de conforto durante a sessão do experimento. As sessões foram agendadas previamente e não aconteceu no mesmo dia mais de uma sessão.

5.4 Coleta de sinais fisiológicos

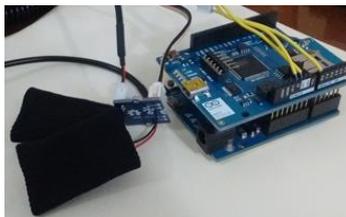
Após a RSL dos sensores fisiológicos e inferências do estado emocional apresentada no “Capítulo 3”, deu-se início à criação da rede de sensores para a coleta dos sinais fisiológicos. Para a escolhas dos sensores foram considerados resultados da RSL, custo dos sensores e conforto que o sensor possibilita aos participantes. Os mensuradores mais utilizados entre os pesquisadores para a coleta de sinais e classificação do estado emocional, apresentados na RSL (ECG, EEG e GSR), foram adotados neste trabalho.

O sensor para a coleta, o eletrodo de condutividade da pele GSR, é acessível e de baixo custo, com possibilidade de ser acoplado à uma placa microcontroladora (Arduino). O modelo com dois anéis elásticos, colocado nos dedos, não impede o participante de realizar atividades, como, por exemplo, o digitar. Este modelo é indicado na literatura pois os dois eletrodos têm contato com a pele da palma da mão, parte do corpo apropriada para coleta dos dados de condutividade da pele (BOUCSEIN, 2012).

Para a coleta de resposta galvânica foi utilizado o Grove - GSR Sensor¹². Desenvolveu-se uma plataforma de coleta e envio de dados com Arduino Leonardo¹³ utilizando os módulos *wifi shield*, *Bluetooth HC-05*, apresentado na Figura 15. Optou-se pela construção de um equipamento de coleta com baixo custo, tornando-o acessível para projetos que buscam inferir o estado emocional a partir de sinais fisiológicos.

¹² http://wiki.seeedstudio.com/Grove-GSR_Sensor/

¹³ https://www.arduino.cc/en/Main/Arduino_BoardLeonardo

Figura 15. Arduino Leonardo, *wifi shield* e Sensor GSR

Fonte: Elaborada pelo autor

Entre os sensores de atividade cardíaca, o ECG está entre os mais populares e de baixo custo, com versões para utilização placa microcontroladora (Arduino). Foi utilizado o sensor ECG Heart Monitor AD8232¹⁴, conectado em conjunto com o GSR ao Arduino Leonardo com módulos de comunicação *wifi*, *Bluetooth*, representados na Figura 16.

Figura 16. Arduino com sensor ECG, GSR e módulos de comunicação

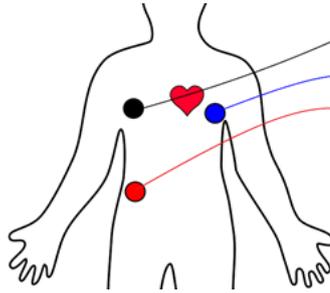
Fonte: Elaborada pelo autor

O ECG contém 3 eletrodos que são posicionados no tronco do indivíduo para mensurar sua atividade cardíaca. A cor de cada pino está associada à posição na qual devem ser colocados os eletrodos descartáveis, conforme a Figura 17.

Para a coleta dos sinais ECG e GSR, foi desenvolvida uma interface de comunicação para receber os dados e salvar em banco de dados *mysql*¹⁵. A comunicação *wifi* e *Bluetooth* permite a mobilidade do participante, mas optou-se por fazer o envio pelo *Universal Serial Bus* (USB) para este experimento.

¹⁴ <http://www.theorycircuit.com/heart-rate-monitor-ad8232-interface-arduino/>

¹⁵ <https://www.mysql.com>

Figura 17. Locais do corpo onde foram posicionados eletrodos ECG

Fonte: <http://www.theorycircuit.com/heart-rate-monitor-ad8232-interface-arduino/>

Para mensurar a atividade cerebral, apesar do EEG ser a opção de baixo custo, ele mesmo apresenta variações no número de canais (eletrodos) e formatos que podem ocasionar desconforto no participante, por exemplo, o formato de capacete com muitos eletrodos. Portanto, visando baixo custo e quantidade confortável de eletrodos, o EEG adotado é em formato de fone de ouvido com dois eletrodos.

Para a coleta dos sinais de atividade cerebral, foi utilizado o sensor *NeuroSky MindWave Headset*¹⁶ que conta com dois canais de coleta a seco, como apresentado na Figura 18. Os sinais obtidos são: beta, alfa, teta e delta, apresentam variações de acordo com a atividade do indivíduo e parte do cérebro. Os sinais foram recebidos por interface de comunicação USB e salvos no banco de dados¹⁷.

Figura 18. Sensor EEG *MindWave Headset*

Fonte: <https://store.neurosky.com/>

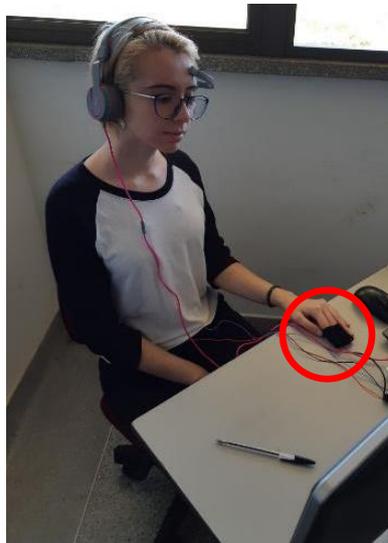
¹⁶ <https://store.neurosky.com/pages/mindwave>

¹⁷ <https://github.com/isaqueelcio/Emoweb>

Foi utilizada também uma *webcam* para a coleta de expressões faciais com FACS, com a API *Affectiva*¹⁸. As emoções classificadas foram salvas na no banco de dados *mysql*¹⁹. Com o objetivo de avaliar se os estímulos estavam alterando estado emocional do indivíduo.

Na Figura 19 o participante está assistindo trechos de vídeos utilizando fone de ouvido para evitar interferência externa. Na cabeça há o sensor de atividade cerebral EEG, na qual um eletrodo é preso na orelha e outro e posicionado na parte frontal da cabeça, na mão esquerda, envolvendo dois dedos, foi colocado o sensor GSR (marcado com círculo vermelho). O sensor ECG é colocado pelo próprio participante na parte de baixo da roupa, por isso não está visível.

Figura 19. Sensores para coleta de sinais fisiológico no participante



Fonte: Elaborada pelo autor

Na Figura 20 é apresentada, em uma perspectiva frontal, a posição do monitor onde participante assistia aos trechos de vídeos (estímulos) A câmera que coletava dados de expressão fácil ficava posicionada em cima do monitor direcionada para participante (marcado com círculo vermelho).

¹⁸ <https://www.affectiva.com>

¹⁹ <https://github.com/isaqueelcio/Facs>

Figura 20. Câmera frontal para coleta expressões faciais

Fonte: Elaborada pelo autor

Para conduzir o experimento, foi criada uma equipe de pesquisadores sendo um doutorando, dois mestrandos do Programa de Pós-graduação em Ciência da Computação (PPG-CC) da Universidade Federal de São Carlos (UFSCar) e quatro alunos de graduação do curso de Ciência da Computação, seguindo uma escala de trabalho para acompanhar participantes nas três sessões de coleta de dados.

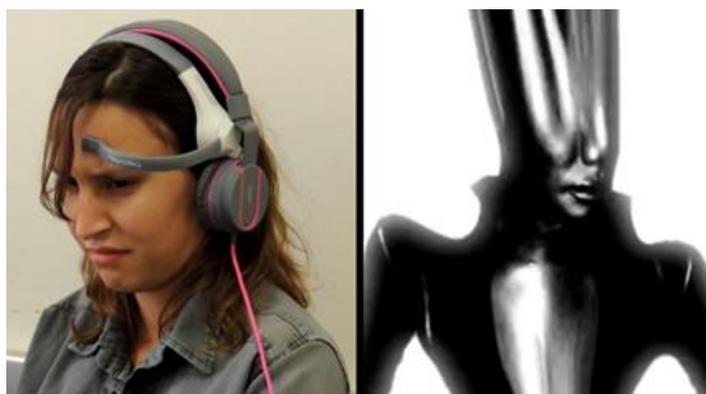
Outra câmera foi posicionada ao lado do participante para gravar as expressões e relatos do mesmo. O participante também foi orientado a relatar o que estava sentindo, seguimos o método *Think aloud* (VAN SOMEREN; BARNARD; SANDBERG, 1994). Os relatos eram anotados pela equipe de pesquisadores presentes para confirmar se o estímulo conduzia o indivíduo ao estado emocional proposto pelo trecho de filme ou videoclipe. Em cada trecho assistido o participante respondeu a um questionário (SAM), apresentado no Anexo A.

No início do experimento os participantes responderam a um questionário para a coleta de suas informações demográficas, apresentado no Apêndice A. No final de cada sessão os participantes responderam a um questionário relacionado ao conforto sentido durante a experiência, no qual o participante marcava, em uma escala de conforto de 0 a 10, sua sensação de conforto durante a sessão do experimento, apresentado no Apêndice B.

Os estímulos de trechos de filmes e videoclipes, os relatos durante os estímulos com método *Think aloud* (relato) e FACS apresentam pré-classificação

das emoções. Possibilitando, ao final, validar os estímulos e analisar se o participante atingiu o estado emocional desejado. Na Figura 21 o participante assiste ao videoclipe “*Corporate Cannibal*”, correspondente ao número dois (2) da Tabela 14, com estímulo de assustador/medo mapeado no oitante 1 do Espaço Semântico. A primeira parte a expressão da participante com estímulo. Na segunda parte o videoclipe (estímulo) assistido no momento.

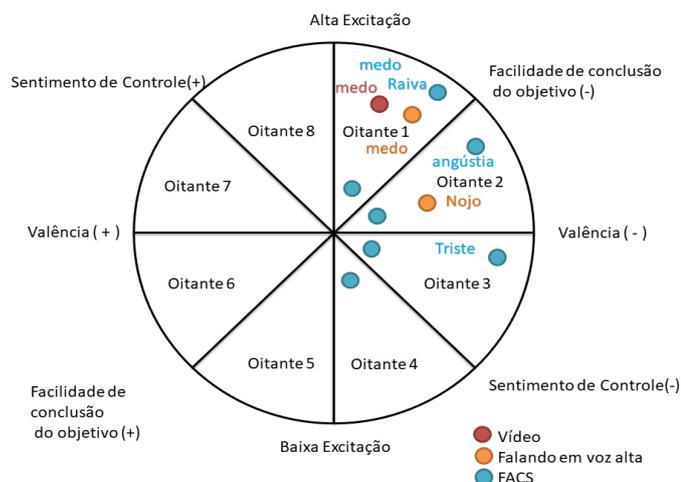
Figura 21. Participante assiste vídeo com estímulo de assustador/medo



Fonte: Elaborada pelo autor

Para validar se os sinais fisiológicos coletados de cada participante correspondem ao estado emocional proposto pelo estímulo ou emoções próximas no Espaço Semântico, foram utilizadas as informações da classificação do estímulo, o método *Think aloud* (relato) e do FACS coletadas enquanto participante assistia videoclipe. As emoções foram mapeadas no Espaço Semântico, apresentado na Figura 22. O método *Think aloud* (relato) inferiu emoções de medo (oitante 1) e nojo (oitante 2). O FACS inferiu emoções de raiva e medo (oitante 1) e tristeza (oitante 3) e o domínio de baixa Valência.

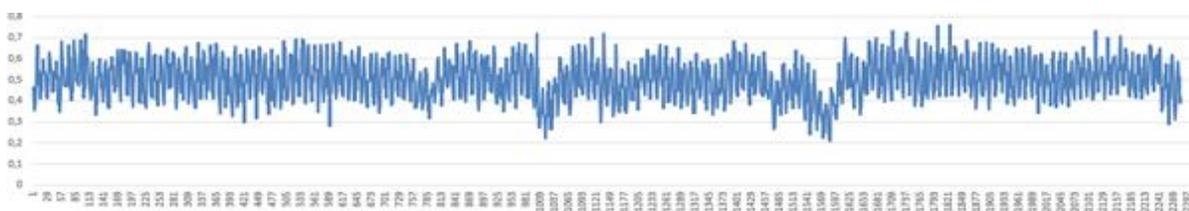
Figura 22. Emoções participantes mapeado espaço semântico



Fonte: Elaborada pelo autor

Com a confirmação de que o vídeo assistido atingiu objetivo de estimular emoções do participante, na Figura 23 são apresentados os sinais do sensor ECG coletados enquanto o participante assistia vídeo com estímulo de assustador/medo, apenas amostra dos sinais coletados.

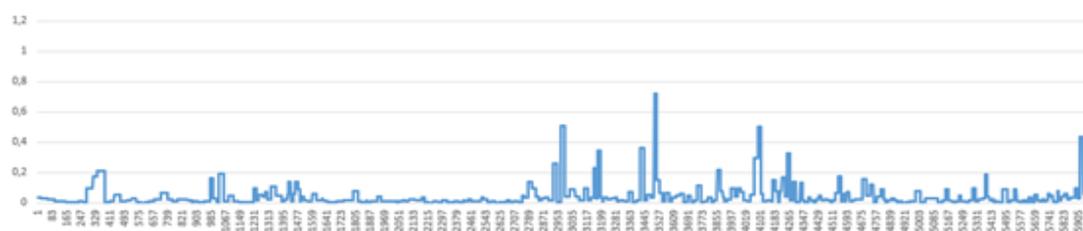
Figura 23. Sinais ECG com estímulo assustador/medo



Fonte: Elaborada pelo autor

Os sinais do sensor EEG *theta* de atividade cerebral durante estímulo de assustador/medo é apresentado a seguir (Figura 24). É possível observar o aumento da oscilação do sinal no decorrer do estímulo, apenas amostras de sinais coletados.

Figura 24. Sinais EEG com estímulo assustador/medo



Fonte: Elaborada pelo autor

Os sinais do sensor GSR que mede a condutividade da pele coletados com estímulo assustador/medo, é apresentado na Figura 25. Durante este período do estímulo, é possível notar alterações do sinal.

Figura 25. Sinais GSR com estímulo assustador/medo



Fonte: Elaborada pelo autor

Ambos os sinais apresentaram alterações sutis. Portanto, foram utilizados algoritmos de extração de características e classificação.

5.5 Considerações Finais

Neste capítulo foram apresentados os detalhes do experimento de coleta de sinais fisiológicos com estímulos de trechos de filmes e videoclipes. Outros dados foram coletados, como expressões faciais, relato dos participantes e SAM, para confirmar se o participante atingiu o estado emocional proposto. Após a coleta dos sinais fisiológicos, eles foram processados a fim de eliminar dados inconsistentes.

Capítulo 6

DATASET

Neste capítulo apresentamos a *análise dos dados e definição do dataset de sinais fisiológicos e ré-processamento dos sinais fisiológicos eliminando dados inconsistentes através de filtros, posteriormente criação de modelos de classificação com algoritmos de aprendizado de máquina.*

6.1 Definição da base de dados

Os sinais fisiológicos dos sensores ECG, EEG e GSR foram pré-processados e normalizados, posteriormente, com o método estatístico LDA utilizado para agrupar e extrair as características. Aos dados tratados foram aplicados, individualmente, algoritmos de classificação para os sinais mensurados por cada sensor, gerando os modelos de classificação e testando a acurácia dos mesmos. Para avaliar os modelos gerados pelos algoritmos de aprendizado de máquina, foram utilizados os métodos estatísticos de Friedman e Nemenyi, buscando encontrar a diferença de desempenho entre eles.

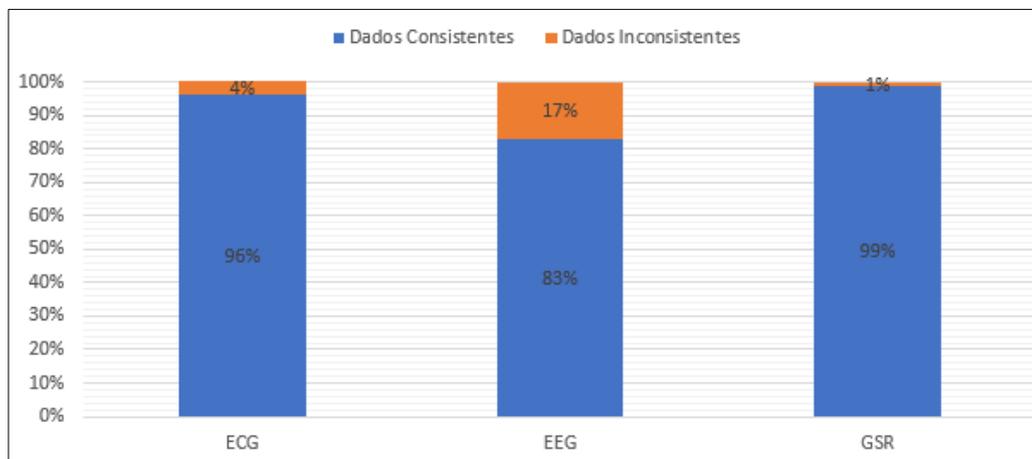
A prévia categorização (rotulação) dos dados coletados pela API *Affective* de expressões faciais, SAM e o “*Think aloud*”, contribuiu para a validação da classificação dos sinais fisiológicos e o mapeamento das emoções no Espaço Semântico de Scherer (2005). Como no exemplo apresentado anteriormente, na Figura 22, na qual são mapeados os oitantes com as emoções gerado pelo estímulo (vídeo).

6.2 Pré-processamento

Aos 415 dados mensurados dos sinais fisiológicos foram aplicados filtros de passa alta e baixa para eliminar sinais inconsistentes, enquanto o filtro de *Wiener* foi utilizado para eliminar os ruídos presentes. Ambos os filtros foram usados na biblioteca de *python scipy*²⁰, específica para tratamento de dados desta natureza. Após aplicação de filtros nos sinais, estes foram normalizados para se adequarem aos algoritmos de classificação. Sendo assim, dados inconsistentes com registros zero ou valor muito alto, fora da faixa da coleta do sensor foram eliminados pelos filtros.

O sensor que apresentou maior perda de dados foi o EEG de atividade cerebral, com 17% dos dados dos coletados eliminados. O ECG de atividade cardíaca, por sua vez, obteve perda de 4% do total de dados coletados e GSR de resposta galvânica apenas 1% dos dados estão inconsistentes (Figura 26).

Figura 26. Porcentagem de dados consistentes e eliminados



Fonte: Elaborada pelo autor

Subramanian (2018) analisou a inconsistência dos dados em um experimento semelhante e o sensor que apresentou maior índice de perdas foi

²⁰ <https://www.scipy.org>

sensor ECG e o que apresentou menor índice de perdas de dados foi o sensor GSR, semelhante ao encontrado neste estudo.

6.3 Protocolo dos testes

Após a eliminação dos dados inconsistentes, o próximo passo foi aplicar o mecanismo de extração de características e agrupar as classes. Para isso, foi utilizado o método de redução de dimensionalidade, agrupamento e extração de características LDA, considerando o número de classes para dimensionar as características, sendo o número de classe menos um ($nClasses - 1$).

Para as classificação, foram utilizados: KNN, NB, DT, RF, XGBoost, SVM e RNA. As escolhas foram inspiradas nos métodos e algoritmos apontados na RS (Capítulo 3), demais trabalhos relacionados, além de novas metodologias que estão apresentando alto desempenho na classificação em outras áreas. A classificação foi realizada individualmente, combinando algoritmos para cada sinal de ECG, EEG e GSR. A implementação de extração de características e dos classificadores foram realizadas em *python*, com a biblioteca *scikit-learn*²¹.

Para os testes de algoritmos de classificação, foi utilizada a validação cruzada 10 *folds*. Foram realizados 30 testes com 10-*fold*, nos quais os grupos de treinamentos e testes foram sorteados aleatoriamente, constituindo, assim, uma estimativa média dos acertos e erros, totalizando 300 execuções de cada algoritmo. Dessa forma, fica garantida que as informações de determinado participante fiquem apenas no treinamento ou somente na validação, impedindo que algoritmo não aprenda as características do participante, evitando, assim, um viés. A cada execução do modelo foi analisada a acurácia, o número de acertos e o total de amostras de cada classe.

A avaliação de desempenho de cada algoritmo de classificação relacionado ao número de erro e acertos nas classes foi realizado a partir da matriz de confusão. A cada validação cruzada é gerada uma matriz, e para cada realização dos 30

²¹ <http://scikit-learn.org/>

testes de validação cruzada foi criada uma matriz de confusão com a média de acertos e erros de todos os testes.

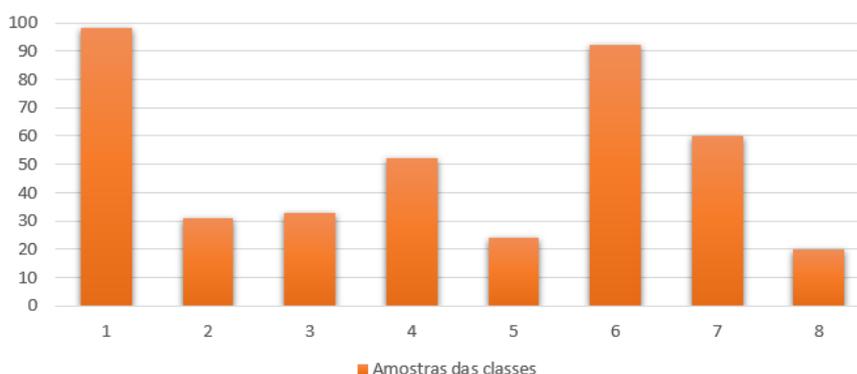
E, por fim, foi possível extrair a média da acurácia de cada teste e a criação do *rank* desempenho dos algoritmos. Com o *rank* dos 30 testes dos algoritmos foi realizado o teste de Friedman, e o teste de Nemenyi.

O teste de Friedman, para verificação se há evidência significativa de que a hipótese nula, em que desempenho dos algoritmos provêm da mesma distribuição. Quando o teste de Friedman resulta em valor 0,00, a hipótese nula é rejeitada, permitindo afirmar que a diferença estatisticamente significativa nos resultados dos algoritmos. O teste post-hoc como a e comparações múltiplas de Nemenyi que calcula a distâncias críticas (CD- *Critical Distance*) entre os resultados dos algoritmos (DEMŠAR, 2006).

6.4 Análise de dados do sensor GSR

Após o processamento e eliminação dos ruídos das informações obtidas, foram aplicados métodos para reduzir a dimensionalidade LDA, buscando agrupar as classes e reduzir a dimensionalidade dos dados, obtidas no último minuto do trecho assistido. O desbalanceamento dos dados em relação às classes (Figura 27) se deu pela dificuldade de encontrar vídeos (estímulos) relacionados à determinadas emoções que compõem os oitantes e também aos dados que foram eliminados por inconsistência.

Figura 27. Distribuição dos dados em função das classes GSR

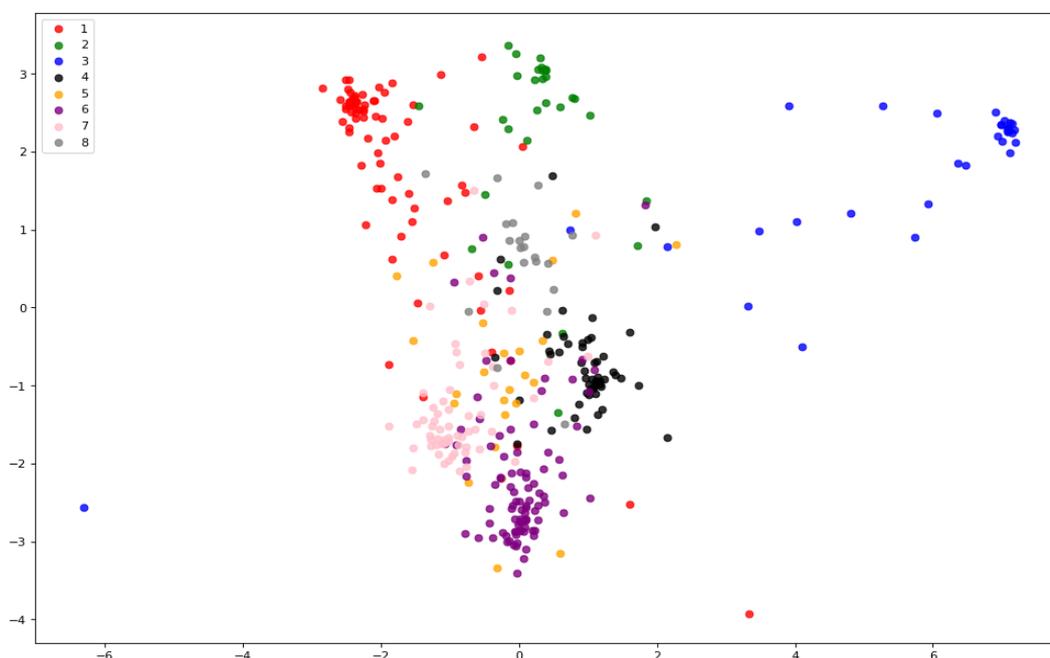


Fonte: Elaborada pelo autor

Com a distribuição das classes representando os oitantes do Espaço Semântico, pôde ser observado o agrupamento das amostras em suas classes (Figura 28). Portanto, nas classes (oitantes) 1, 2, 3, 4, 6 e 7 é possível visualizar a homogeneização dos dados, a distância entre classes e a falta de sobreposição entre elas. Os oitantes 5 e 8 estão mais dispersos e não apresentam distância definida quando comparado às demais classes.

Para a classificação, os algoritmos utilizaram os seguintes parâmetros: KNN ($K = 5$), RF (estimadores = 40), SVM (kernel = RBF e $C = 3,0$), RNA (Camadas = 100, interações = 1000). O algoritmo *XGBoost* utilizou parâmetro padrão.

Figura 28. Distribuição das classes GSR



Fonte: Elaborada pelo autor

Os algoritmos de NB, KNN, SVM e RNA foram os que apresentaram melhor desempenho na classificação, com 77% de acurácia (Tabela 15). Os algoritmos que apresentaram maior variação na acurácia no *rank* de desempenho da validação cruzada, de acordo com as medidas de desvio padrão, foram SVM e KNN, não se adaptando às alterações no conjunto de dados de treinamento. Os algoritmos que apresentaram menor variação e desempenho mais estável são RF e *XGBoost*.

Tabela 15. Resultados dos modelos de classificação com sinais GSR

Acurácia e D. Padrão/Algoritmos	NB	DT	RF	XGBoost	kNN	SVM	RNA
Média da acurácia	0,7786	0,6815	0,7317	0,7405	0,7764	0,7740	0,7765
Desvio Padrão	0,0193	0,0213	0,0139	0,0165	0,0217	0,0238	0,0196

Após avaliação do desempenho dos modelos de classificação, observou-se que a classe três obteve maior índice de acertos, com 94%, seguida pela classe um, com 89%. A classe 5 apresentou menor índice de acerto, 1% (Tabela 16). Portanto, considerando os erros e acertos do classificador NB, nesta matriz de confusão, temos 22% de erros e 78% em acertos.

Tabela 16. Matriz de confusão modelo NB com sinais GSR

Classes	1	2	3	4	5	6	7	8	Erros	Acertos
1	18,49	0,24	0,00	0,10	0,46	0,49	0,60	0,38	11%	89%
2	0,51	5,00	0,33	0,43	0,00	0,10	0,00	0,26	25%	75%
3	0,13	0,16	6,58	0,01	0,06	0,00	0,00	0,06	6%	94%
4	0,00	0,21	0,22	9,29	0,01	0,64	0,21	0,39	15%	85%
5	0,42	0,23	0,18	0,25	0,06	2,56	1,19	0,21	99%	1%
6	0,22	0,01	0,22	1,31	0,01	15,07	1,78	0,62	22%	78%
7	0,47	0,21	0,00	0,48	0,05	0,65	10,22	0,28	17%	83%
8	0,31	0,51	0,00	0,46	0,05	0,13	0,33	2,33	43%	57%

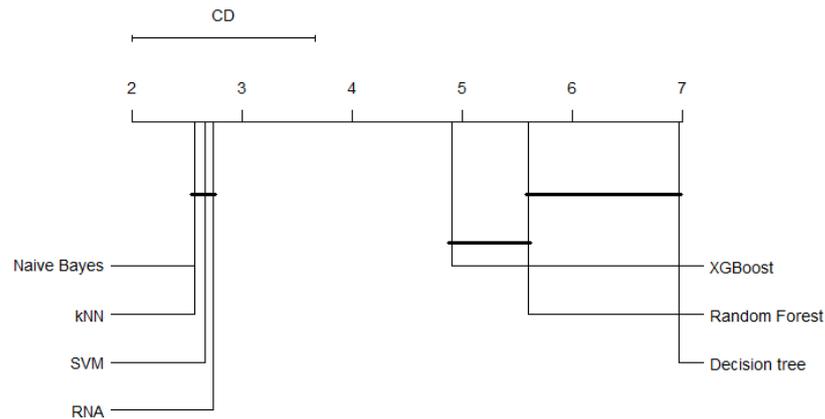
A Tabela 17 apresenta a matriz de confusão do modelo de classificação RNA, sendo a classe 3 com maior índice de acertos e classe 5, por sua vez, obteve o menor índice de acerto. Portanto, o modelo apresentou 78% de acerto na matriz de confusão e 22% de erro.

Tabela 17. Matriz de confusão modelo RNA com sinais GSR

Classes	1	2	3	4	5	6	7	8	Erros	Acertos
1	18,02	0,65	0,00	0,23	0,39	0,46	0,82	0,22	13%	87%
2	0,38	5,00	0,18	0,37	0,02	0,22	0,01	0,39	24%	76%
3	0,13	0,00	6,43	0,12	0,02	0,00	0,09	0,21	8%	92%
4	0,00	0,29	0,15	9,22	0,17	0,57	0,13	0,42	16%	84%
5	0,53	0,11	0,22	0,41	0,54	1,77	1,20	0,28	89%	11%
6	0,24	0,16	0,02	1,34	0,21	15,20	1,65	0,56	22%	78%
7	0,52	0,11	0,00	0,55	0,22	0,81	10,28	0,15	19%	81%
8	0,21	0,36	0,00	0,32	0,05	0,16	0,33	2,79	34%	66%

Ao analisar o ranking dos testes de validação cruzadas dos algoritmos, o teste de Friedman apresentou o resultado 0,00, rejeitando a hipótese nula e indicando que há diferença entre os dados analisados. A Figura 29 apresenta o teste de Nemeyi com as distâncias críticas (CD- *Critical Distance*) entre os modelos, sendo a $CD = 1,66$, indicando que a distância entre os modelos.

Figura 29. Teste de Nemeyi modelos com dados GSR



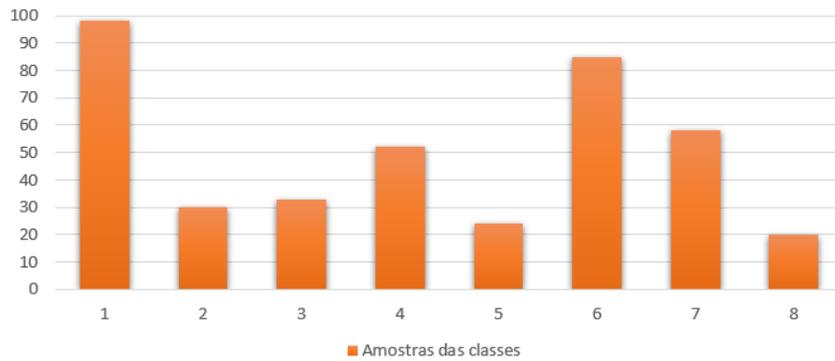
Fonte: Elaborado pelo autor

Os algoritmos que apresentaram equivalência na significância estatística foram NB, KNN, SVM e RNA. No entanto, os algoritmos XGBoost, RF e DT apresentaram a menor significância em relação aos demais.

6.5 Análise de dados do sensor ECG

Com os dados do sensor ECG pré-processados e os ruídos eliminados, aplicou-se o método de redução de dimensionalidade e extração de características, buscando agrupar as classes. Considerando que o estímulo conseguiu alterar o estado emocional do indivíduo, foi avaliado o último minuto do trecho do vídeo dos sinais fisiológicos coletados. Na Figura 30 é apresentada a distribuição das amostras de dados em relação às classes, apresentando desbalanceamento do número de amostras de dados em relação às classes. Este desbalanceamento se deu pela dificuldade de encontrar vídeos (estímulos) de determinadas emoções que compõem os oitantes e também dados que foram eliminados por inconsistência.

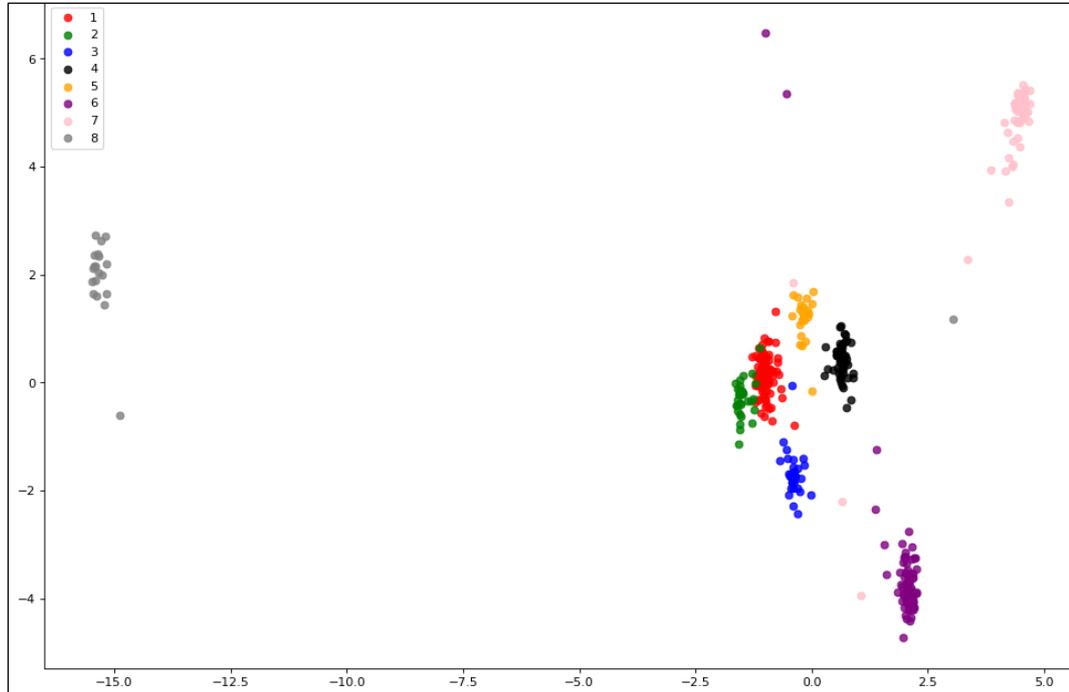
Figura 30. Distribuição dos dados em função das classes ECG



Fonte: Elaborado pelo autor

Com as amostras de dados distribuídos em suas classes, representado os oitantes do Espaço Semântico (Figura 31), pode ser observado o agrupamento das classes e a distância entre elas. Apenas as classes 1 e 2 apresentaram sobreposição. As demais estão separadas, possibilitando melhor desempenho na classificação.

Figura 31. Distribuição das classes ECG



Fonte: Elaborada pelo autor

Para a classificação os algoritmos, utilizaram os seguintes parâmetros: KNN (K = 13), RF (estimadores = 15), SVM (kernel = RBF e C = 5,0), RNA (Camadas = 100, interações = 1200). O algoritmo *XGBoost* utilizou parâmetro padrão.

Os modelos gerados a partir dos algoritmos e dados de treinamento, aplicando 30 testes de validação cruzada, estão apresentados na Tabela 18. O algoritmo que melhor se adequou aos dados de atividade cardíaca foi o NB, com média de acurácia de 97%, por sua vez, aquele que apresentou menor desempenho foi DT, com acurácia de 94%, embora os modelos tenham apresentado desempenhos muito semelhantes. Portanto, o modelo RF apresentou a menor variação da acurácia entre os modelos de acordo com desvio padrão de 0,0081 e o modelo que apresentou maior variação foi RNA.

Tabela 18. Resultados dos modelos de classificação com sinais ECG

Acurácia e D. Padrão/Algoritmos	NB	DT	RF	XGBoost	kNN	SVM	RNA
Média da acurácia	0,9650	0,9434	0,9551	0,9522	0,9605	0,9568	0,9606
Desvio Padrão	0,0105	0,0213	0,0081	0,0117	0,0090	0,0108	0,0119

Para avaliação de desempenho dos modelos em relação a erros e acertos das classes individualmente, foram analisadas as matrizes de confusão que apresentaram melhor desempenho (Tabela 18).

Na Tabela 19 é apresentada a matriz de confusão do modelo de classificação NB com sinais ECG. A classe 4 obteve 100% de acerto, seguida pelas classes 1, com 99%, e 3, com 97%. A classe que obteve menor índice de desempenho foi a 2, com 87% de acertos. Este modelo apresentou 97% de acertos no total de todas as classes e apenas 3% de erros.

Tabela 19. Matriz de confusão modelo NB com sinais ECG

Classes	1	2	3	4	5	6	7	8	Erros	Acertos
1	20,55	0,01	0,24	0,00	0,00	0,00	0,00	0,00	1%	99%
2	0,82	5,57	0,00	0,00	0,00	0,00	0,00	0,00	13%	87%
3	0,03	0,00	6,76	0,00	0,21	0,00	0,00	0,01	3%	97%
4	0,00	0,00	0,00	11,06	0,00	0,00	0,00	0,00	0%	100%
5	0,00	0,00	0,09	0,00	4,92	0,09	0,00	0,00	4%	96%
6	0,05	0,00	0,00	0,04	0,38	17,53	0,00	0,00	3%	97%
7	0,00	0,00	0,10	0,11	0,22	0,23	11,63	0,00	5%	95%
8	0,00	0,00	0,00	0,00	0,00	0,00	0,21	4,02	5%	95%

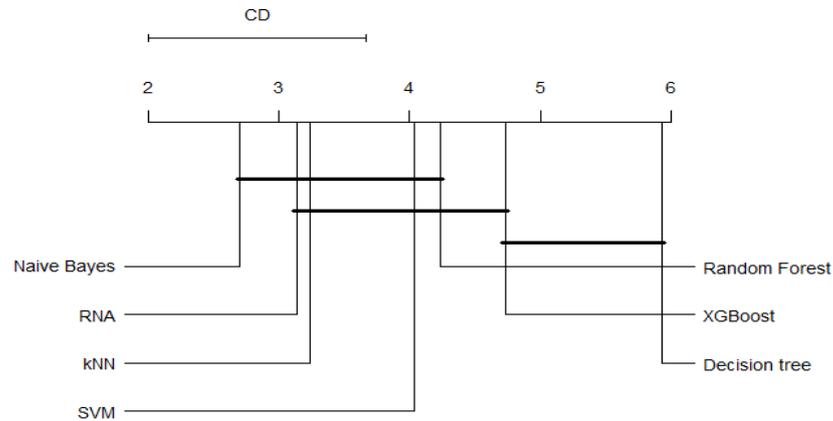
A matriz de confusão do modelo de RNA, demonstrou que as classes com maior índice de acerto foram: classe 4, com 100% de acertos, seguida da classe 1, com 98% de acertos. As classes que apresentaram menores índices foram: classe 2, com 88% e classe 8, com 90% de acertos (Tabela 20). Portanto, este modelo obteve desempenho de 96% de acertos e 4% de erros na matriz de confusão.

Tabela 20. Matriz de confusão modelo RNA com sinais ECG

Classes	1	2	3	4	5	6	7	8	Erros	Acertos
1	20,48	0,13	0,01	0,00	0,18	0,00	0,01	0,00	2%	98%
2	0,75	5,62	0,00	0,00	0,00	0,00	0,00	0,00	12%	88%
3	0,26	0,00	6,74	0,00	0,00	0,00	0,00	0,00	4%	96%
4	0,00	0,00	0,00	10,97	0,00	0,00	0,00	0,00	0%	100%
5	0,00	0,00	0,02	0,21	4,90	0,00	0,00	0,00	4%	96%
6	0,00	0,00	0,00	0,19	0,44	17,20	0,00	0,00	4%	96%
7	0,00	0,00	0,03	0,05	0,22	0,42	11,32	0,13	7%	93%
8	0,00	0,21	0,00	0,10	0,00	0,00	0,12	3,75	10%	90%

Nestes dois modelos (NB e RNA) analisados pelas matrizes de confusão, as classes 1 e 4 apresentaram maior desempenho em ambos, enquanto a classe 2 apresentou menor índice de acerto nos dois modelos. Também pode ser observado que o erro da classe 2 nos dois modelos são classificados erradamente na classe 1.

Avaliando os resultados dos modelos com média da acurácia dos 30 treinamento e teste, utilizando o teste de Friedman, apresentou (0,00) rejeitando a hipótese nula, indicando que há diferença entre os modelos utilizados. Na Figura 32 é apresentado o teste de Nemeyi com as distâncias críticas (CD- *Critical Distance*) entre eles, sendo a CD = 1,66. Isso indica que a distância entre os modelos tem que ser maior CD para representar uma diferença estatística significativa.

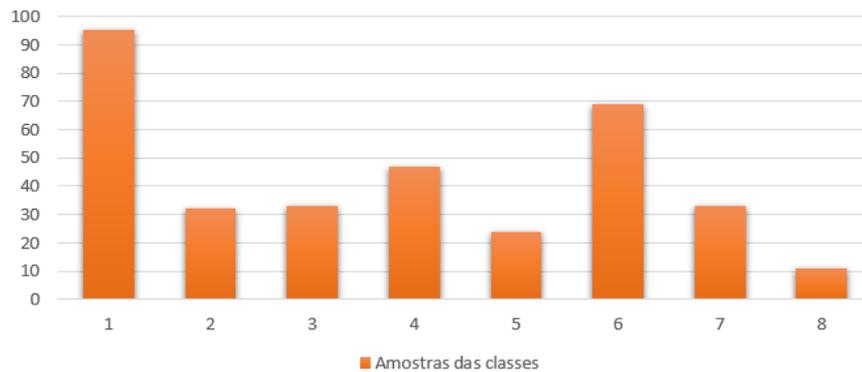
Figura 32. Teste de Nemenyi modelos com dados ECG

Fonte: Elaborada pelo autor

Os algoritmos NB, RNA, KNN e SVM não obtiveram equivalência de acordo com diferencial crítico. No entanto, algoritmos RF, XGBoost e DT apresentaram baixa significância em relação aos demais.

6.6 Análise de dados do sensor EEG

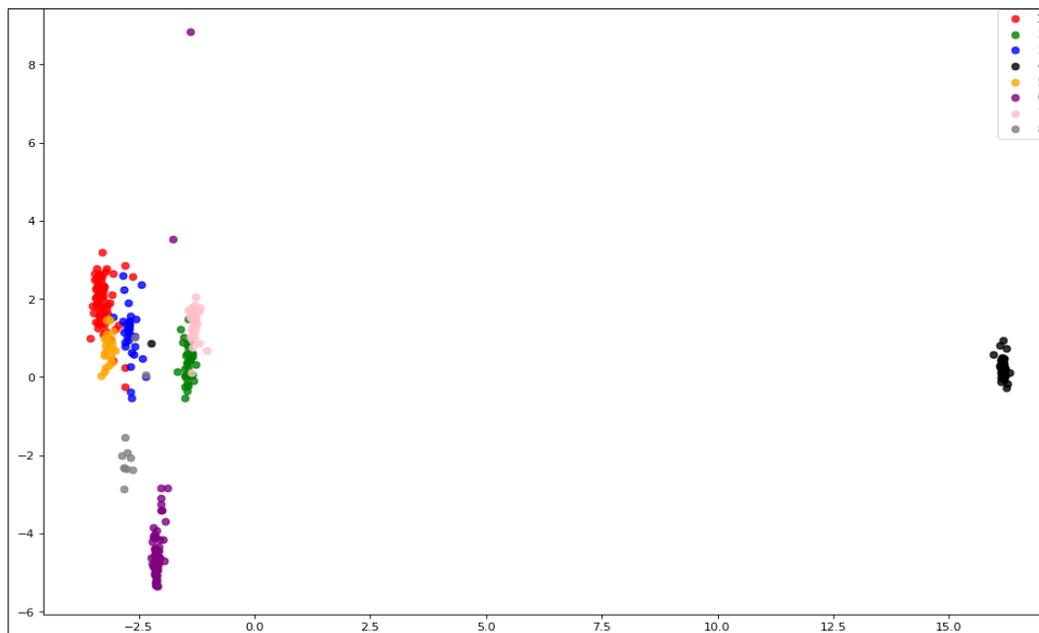
Com os dados do sensor EEG pré-processados e com eliminação dos ruídos, foi aplicado método para reduzir a dimensionalidade LDA, buscando agrupar as classes e reduzir a dimensionalidade dos dados. O desbalanceamento das amostras em cada classe (Figura 33) deu-se pela dificuldade de encontrar vídeos (estímulos) de determinadas emoções que compõem os oitantes e também dados que foram eliminados por inconsistência, semelhante ao encontrado com os demais sensores.

Figura 33. Distribuição dos dados em função das classes EEG

Fonte: Elaborada pelo autor

Na Figura 34 está representada a distribuição dos dados do sensor EEG do sinal delta dividido por classes. Lembrando que sinais EEG são divididos em *delta*, *theta*, *alpha*, *beta* e *gamma*. Com os dados distribuídos nas classes que representam os oitantes do espaço semântico, pôde ser observado o agrupamento das amostras de dados.

A análise da distribuição das classes nos oitantes do Espaço Semântico mostra que as amostras não possuem grande dispersão e comporta-se de forma agrupada (Figura 34), além disso, apenas as classes 1, 3 e 5 apresentam sobreposição de algumas amostras.

Figura 34. Distribuição das classes sinal Delta EEG

Fonte: Elaborada pelo autor

Para a classificação, os algoritmos utilizaram os seguintes parâmetros: KNN (K = 15), RF (estimadores = 15), SVM (kernel = RBF e C = 4,0), RNA (Camadas = 100, interações = 1000). O algoritmo *XGBoost* utilizou parâmetro padrão.

A Tabela 21 apresenta a média da acurácia dos testes de validação cruzada, assim como o desvio padrão do desempenho de cada modelo com dados do sensor EEG.

Tabela 21. Resultados dos modelos de classificação com sinais EEG

Acurácia e D. Padrão/Algoritmos	NB	DT	RF	XGBoost	kNN	SVM	RNA
Média da acurácia	0,9858	0,9786	0,9896	0,9893	0,9900	0,9909	0,9876
Desvio Padrão	0,0037	0,0056	0,0033	0,0036	0,0039	0,0026	0,0037

Os dois algoritmos de classificação que tiveram melhor desempenho, com as informações obtidas pelo EEG, foram SVM e KNN, com média de acurácia de 99%. Para avaliar a variação de desempenho dos algoritmos, foi aplicado o desvio padrão, sendo os modelos KNN e DT aqueles que apresentaram maior variação. Os modelos SVM e RF, por sua vez, que apresentaram menor desvio padrão e com isso menor distribuição dos dados em torno da média.

Para uma avaliação de desempenho individual dos modelos em cada classe, foi utilizada matriz de confusão. Os dois algoritmos que apresentaram melhor acurácia foram SVM e KNN (Tabela 21).

Na matriz de confusão do algoritmo de classificação KNN, as classes 1, 2, 5, 7 e 8 obtiveram o melhor desempenho, com 100% de acertos. A classe 3 apresentou menor desempenho, 97% de acertos, e os 3% de erros do modelo foram atribuídos à classe 1. O desempenho do algoritmo nesta matriz de confusão foi de 99% de acertos e 1% de erro (Tabela 22).

Tabela 22. Matriz de confusão modelo KNN com sinais EEG

Classes	1	2	3	4	5	6	7	8	Erros	Acertos
1	20,22	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0%	100%
2	0,00	6,78	0,00	0,00	0,00	0,00	0,00	0,00	0%	100%
3	0,22	0,00	6,77	0,00	0,00	0,00	0,00	0,00	3%	97%
4	0,21	0,00	0,00	9,87	0,00	0,00	0,00	0,00	2%	98%
5	0,00	0,00	0,00	0,00	5,15	0,00	0,00	0,00	0%	100%
6	0,00	0,00	0,22	0,00	0,00	14,66	0,00	0,00	1%	99%
7	0,00	0,00	0,00	0,00	0,00	0,00	7,12	0,00	0%	100%
8	0,00	0,00	0,00	0,00	0,00	0,00	0,00	2,84	0%	100%

A Tabela 23 apresenta a matriz de confusão com desempenho em cada classe, no modelo de categorização SVM com sinais do EEG. As classes que o modelo apresentou melhor desempenho foram 2, 5, 7 e 8, todas com 100% de acertos. A classe 3 apresentou o menor desempenho, 96% de acerto, sendo os erros do modelo distribuídos nas classes 1, 4 e 7. O modelo obteve o índice de 99% de acertos e 1% de erro nesta matriz de confusão.

Tabela 23. Matriz de confusão modelo SVM com sinais EEG

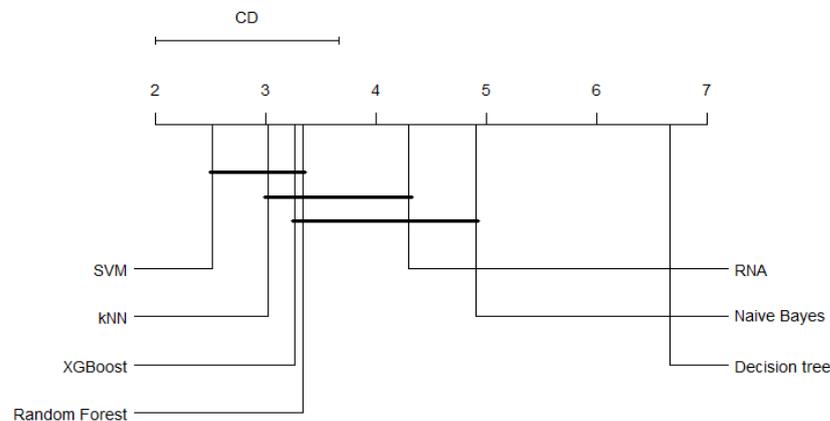
Classes	1	2	3	4	5	6	7	8	Erros	Acertos
1	19,96	0,00	0,00	0,01	0,00	0,16	0,00	0,00	1%	99%
2	0,00	6,81	0,00	0,00	0,00	0,00	0,00	0,00	0%	100%
3	0,05	0,00	6,73	0,02	0,00	0,20	0,00	0,00	4%	96%
4	0,00	0,00	0,00	9,70	0,00	0,23	0,00	0,00	2%	98%
5	0,00	0,00	0,00	0,00	5,06	0,00	0,00	0,00	0%	100%
6	0,01	0,00	0,00	0,08	0,00	14,66	0,00	0,00	1%	99%
7	0,00	0,00	0,00	0,00	0,00	0,00	7,26	0,00	0%	100%
8	0,00	0,00	0,00	0,00	0,00	0,00	0,00	2,81	0%	100%

Os dois modelos de classificação KNN e SVM apresentaram maior número de erros na classe 3. No Enquanto as classes 2, 5, 7 e 8 demonstraram melhor classificação.

A análise dos resultados obtidos no teste de validação cruzada gerou ranking dos algoritmos em cada teste. Avaliando o desempenho dos algoritmos de classificação com dados EEG, no teste de Friedman obteve-se o resultado (0,00), rejeitando, portanto, a hipótese nula, indicando que há diferença entre os modelos

utilizados. Para uma análise de quais modelos tiveram o desempenho equivalente, foi utilizado teste de Nemenyi (Figura 35).

Figura 35. Teste de Nemenyi modelos com dados EEG



Fonte: Elaborada pelo autor

Com distâncias críticas $CD = 1,66$, os modelos SVM, KNN, Xgboost e RF apresentam equivalência no desempenho. Entretanto, RNA, NB e DT obtiveram a menor significância em relação aos demais.

6.7 Considerações finais

As avaliações realizadas e apresentadas neste capítulo tiveram como objetivo verificar os sinais fisiológicos coletados dos sensores GSR, ECG e EEG analisar se corresponderam aos estímulos emocionais propostos, além de verificar quais dos algoritmos de aprendizado de máquina melhor se adequaram às características dos dados de cada sensor. Para tanto, foi realizada validação cruzada com 10 *fold*, realizado 30 validações gerando a média da acurácia e média da matriz de confusão de cada validação. Com a média do desempenho foi criado um ranking dos algoritmos para avaliação estatística.

Os algoritmos que mais se adequaram às características dos dados foram NB para dados GSR, com 78% de acurácia, NB para dados ECG, com 99% de acurácia e SVM para os dados EEG, com 99% de acurácia.

O “Capítulo 7” apresenta a síntese das contribuições, as limitações encontradas e sugestões para trabalhos futuros.

Capítulo 7

CONCLUSÃO E TRABALHOS FUTUROS

Com o dataset rotulado, há a possibilidade de criação de uma infraestrutura de sensores fisiológicos e algoritmos de classificação, os quais capturam sinais e classificam os indícios de respostas emocionais, permitindo avaliação em tempo real.

7.1 Considerações iniciais

No “Capítulo 3”, foi apresentado a RS que concluiu que há necessidade de algoritmos para extrair características dos sinais fisiológicos, de aprendizado e máquina para reconhecimento do estado emocional.

No “Capítulo 4”, foram apresentados trabalhos relacionados, outros *dataset* que relacionam sinais fisiológicos com emoções, detalhando domínios classificados e custo dos sensores utilizados.

No “Capítulo 5”, foram apresentados sensores de coleta dos sinais fisiológicos e estímulos emocionais no formato de videoclipes e trechos de filmes com estímulos pré-classificados, na qual sinais coletados no momento que indivíduo assiste videoclipes e trechos de filmes, representa uma emoção no Espaço Semântico.

Portanto, no “Capítulo 6”, foi apresentada a avaliação dos dados coletados e desempenho dos algoritmos de aprendizado de máquina.

Este Capítulo 7 apresenta, na Seção 7.2, sínteses das contribuições deste trabalho relacionando sensores, emoções e sinais fisiológicos. Já na Seção 7.3 limitações do trabalho e por fim na Seção 7.4 trabalhos futuros.

7.2 Síntese das Contribuições

Nesta pesquisa, é apresentado um *dataset* de sinais fisiológicos (frequência cardíaca, atividade cerebral e resposta galvânica) rotulado com os oitantes do Espaço Semântico, contemplando quatro domínios emocionais, com o foco em componentes que reconheçam o estado emocional do indivíduo em tempo real. Para avaliação de cada um dos sinais coletados com sensores de baixo custo (Tabela 8), foram utilizados algoritmos de aprendizado de máquina e estímulos de vídeos e trechos de filmes com rótulos emocionais, com as emoções distribuídas no Espaço Semântico combinado com os domínios emocionais. Entre as principais contribuições deste trabalho, pode-se ressaltar:

- Esta pesquisa realizou levantamento bibliográfico dos principais métodos de inferência do estado emocional em tempo real, de modo a identificar quais os principais sensores utilizados para a coleta de indícios emocionais que permitem interação em tempo real e quais algoritmos são mais utilizados para a classificação e extração de características. Quais domínios emocionais estão sendo classificados.
- Utilização de módulos para a coleta de sinais e sensores comerciais de baixo custo para inferir indícios emocionais, permitindo, dessa forma, a utilização por outros trabalhos que avaliem interação com indivíduo, além do benefício do uso desta infraestrutura, com custo de \$133,56 dólares, utilizando um sistema de coleta com Arduino e módulos ECG, GSR e *MindWave* para coleta de sinais EEG (Tabela 8).

- *Dataset* de sinais fisiológicos, ECG, EEG e GSR, rotulados em 8 divisões do Espaço Semântico de Scherer (2005), permitindo treinar algoritmos e inferir emoções nos domínios emocionais: Valência, Excitação, Sentimento de controle e Facilidade de Conclusão do Objetivo.
- Foi criado, individualmente, um *Dataset* para cada sensor, permitindo classificar o estado emocional com apenas um dos sensores, se necessário.

Portanto, com resultados apresentados, na classificação, é possível confirmar a Hipótese alternativa 2. Segundo a qual, os sinais fisiológicos coletados com os sensores de baixo custo são mensuráveis e podem representar os quatro domínios emocionais, mapeados nos oitantes do Espaço Semântico.

7.3 Limitações do trabalho

Uma limitação encontrada está relacionada à dificuldade de encontrar participantes para as 3 sessões, uma vez que não aconteciam no mesmo dia. Algumas classes ficaram com poucas amostras para treinar e testar algoritmos de classificação.

Uma nova avaliação dos modelos para avaliar o desempenho em ambiente de produção, com coletando dados de novos participantes e até mesmo novos estímulos emocionais pré-classificados, permitindo melhorar análise de desempenho.

7.4 Trabalhos Futuros

Durante o projeto, foi realizada a coleta de sinais fisiológicos com estímulos emocionais, tratamento dos dados, extração de características e classificação. Portanto, pretendeu-se:

- Realizar seleção de características, separando as amostras mais relevantes para cada classe;
- Balanceamento das classes a partir da seleção de características, deixando as classes com a mesma quantidade de amostras;
- Investigar quais sinais de EEG correspondem aos oitantes do Espaço Semântico;
- Analisar a densidade espectral dos sinais fisiológicos;
- Analisar a tendência, sazonalidade e ciclos dos sinais fisiológicos;
- A combinação de classificadores de acordo com o sensor utilizado;
- A combinação dos resultados da classificação de cada sensor.

7.5 Desafios Futuros

Os desafios futuros podem ser divididos em: dispositivo de coleta e inferência do estado emocional. O dispositivo de coleta são os sensores e o microcontrolador, a inferência envolve o tratamento dos dados e a classificação do estado emocional. No entanto, às duas partes colaboram para a qualidade dos dados coletados e com objetivo de melhorar o desempenho da classificação.

O dispositivo tem os seguintes desafios, diminuir o tamanho do microcontrolador e dos sensores ECG e GSR, possibilitando acoplar ao corpo do usuário. Acrescentado conforto ao usuário e a perceptiva de mobilidade para o mesmo, aproximando o desenvolvimento de uma pulseira. Já o sensor EEG, o desafio está na melhora da qualidade dos sinais coletados, diminuir ruído e dados inconsistentes, aprimorando o software de coleta ou substituindo o sensor por uma versão mais nova.

Na inferência do estado emocional os desafios se concentram na qualidade dos sinais coletados e na quantidade de amostras por classe. O balanceamento das classes para treinamento e o aumento do número de classes para classificação, aproximando as emoções discretas. Criando dados sintéticos ou agrupando outros conjuntos de dados para balanceamento das classes e o aumento do número de classes aproximando de emoções discretas.

7.6 Considerações finais

Com o estudo realizado, assim como a avaliação dos dados e algoritmos de classificação utilizados, foi possível compreender que os sinais fisiológicos são importantes para inferência do estado emocional.

Os algoritmos de classificação apresentam características diferentes para análise de informações estatísticas, a distância das amostras e otimização. Portanto, a análise dos dados com diversos algoritmos de classificação permitiu avaliar qual algoritmo se adequou às características dos traços fisiológicos, visto que esses vestígios são difíceis de ser mensurados. (PICARD; VYZAS; HEALEY, 2001; PINTO, 2001).

REFERÊNCIAS

ABADI, M. K. et al. DECAF: MEG-Based Multimodal Database for Decoding Affective Physiological Responses. **IEEE Transactions on Affective Computing**, v. 6, n. 3, p. 209–222, 2015.

ADIBUZZAMAN, M. et al. **Towards in Situ Affect Detection in Mobile Devices: A Multimodal Approach**. Proceedings of the 2013 Research in Adaptive and Convergent Systems. **Anais...: RACS '13**. New York, NY, USA: ACM, 2013. Disponível em: <<http://doi.acm.org/10.1145/2513228.2513290>>

AFERGAN, D. et al. **Dynamic Difficulty Using Brain Metrics of Workload**. Proceedings of the SIGCHI Conference on Human Factors in Computing Systems. **Anais...: CHI '14**. New York, NY, USA: ACM, 2014. Disponível em: <<http://doi.acm.org/10.1145/2556288.2557230>>

ALZOUBI, O. et al. Affect detection from non-stationary physiological data using ensemble classifiers. **Evolving Systems**, v. 6, n. 2, p. 79–92, jun. 2015.

ATKINSON, J.; CAMPOS, D. Improving BCI-based emotion recognition by combining EEG feature selection and kernel classifiers. **Expert Systems with Applications**, v. 47, p. 35–41, 2016.

BARBOSA, S.; SILVA, B. **Interação humano-computador**. [s.l.] Elsevier Brasil, 2010.

BARTOLINI, E. E. Eliciting emotion with film: Development of a stimulus set. 2011.

BETELLA, A. et al. Inference of human affective states from psychophysiological measurements extracted under ecologically valid conditions. **Frontiers in Neuroscience**, v. 8, p. 286, 2014.

BIOLCHINI, J. et al. Systematic review in software engineering. **System Engineering and Computer Science Department COPPE/UFRJ, Technical Report ES**, v. 679, n. 5, p. 45, 2005.

BOUCSEIN, W. **Electrodermal activity**. [s.l.] Springer Science & Business Media, 2012.

BRAGHIROLI, E. M. et al. **Psicologia geral**. 22. ed. Porto Alegre: Vozes, 2001.

BRANDÃO, M. L. **As bases biológicas do comportamento: introdução á neurociência**. São Paulo, Editora Pedagógica e Universitária, 2004. [s.l: s.n.].

BREIMAN, L. Random forests. **Machine learning**, v. 45, n. 1, p. 5–32, 2001.

BYRNE, R.; ESLAMBOLCHILAR, P.; CROSSAN, A. **Health monitoring using gait phase effects**. Proceedings of the 3rd International Conference on Pervasive Technologies Related to Assistive Environments. **Anais...2010**

CALVO, R. A.; D'MELLO, S. Affect Detection: An Interdisciplinary Review of Models, Methods, and Their Applications. **IEEE Transactions on Affective Computing**, v. 1, n. 1, p. 18–37, jan. 2010.

CARROLL, E. A. et al. **Food and Mood: Just-in-Time Support for Emotional Eating**. 2013 Humaine Association Conference on Affective Computing and Intelligent Interaction. **Anais...2013**

CARVALHO, A. et al. Inteligência Artificial uma abordagem de aprendizado de máquina. **Rio de Janeiro: LTC**, 2011.

CHANG, L. J. et al. A Sensitive and Specific Neural Signature for Picture-

Induced Negative Affect. **PLOS Biology**, v. 13, n. 6, p. 1–28, 2015.

CHEN, T.; GUESTIN, C. **Xgboost: A scalable tree boosting system**. Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining. **Anais...2016**

COPPIN, G.; SANDER, D. 1 - Theoretical Approaches to Emotion and Its Measurement. In: MEISELMAN, H. L. (Ed.). **Emotion Measurement**. [s.l.] Woodhead Publishing, 2016. p. 3–30.

DAI, Y. et al. **Reputation-driven multimodal emotion recognition in wearable biosensor network**. Instrumentation and Measurement Technology Conference (I2MTC), 2015 IEEE International. **Anais...2015**

DAMÁSIO, A. Ao encontro de Espinosa: as emoções sociais ea neurologia do sentir. **Temas & Debates**, 2003.

DARWIN, C. **The expression of the emotions in man and animals**. [s.l.: s.n.].

DEMŠAR, J. Statistical Comparisons of Classifiers over Multiple Data Sets. **J. Mach. Learn. Res.**, v. 7, p. 1–30, 2006.

DIXON, T. “Emotion”: One Word, Many Concepts. **Emotion Review**, v. 4, n. 4, p. 387–388, 2012.

DONGWEI, C. et al. **Eeg-based emotion recognition with brain network using independent components analysis and granger causality**. 2013 International Conference on Computer Medical Applications (ICMA). **Anais...jan. 2013**

EKMAN, P. et al. Universals and cultural differences in the judgments of facial expressions of emotion. **Journal of personality and social psychology**, v. 53, n. 4, p. 712, 1987.

EKMAN, P. Are there basic emotions? **COPYrihl1992 by lthe American Ps~holic.1 “ssoc.a”on.**, 1992.

EKMAN, P.; FRIESEN, W. V.; HAGER, J. C. Facial action coding system (FACS). **A human face**, 2002.

EL KALIOUBY, R.; TEETERS, A. **Eliciting, Capturing and Tagging Spontaneous Facialaffect in Autism Spectrum Disorder**. Proceedings of the 9th International Conference on Multimodal Interfaces. **Anais...: ICMI '07**. New York, NY, USA: ACM, 2007Disponível em: <<http://doi.acm.org/10.1145/1322192.1322203>>

EWING, K. C.; FAIRCLOUGH, S. H.; GILLEADE, K. Evaluation of an adaptive game that uses EEG measures validated during the design process as inputs to a biocybernetic loop. **Frontiers in human neuroscience**, v. 10, 2016.

FISHER, R. A. The use of multiple measurements in taxonomic problems. **Annals of eugenics**, v. 7, n. 2, p. 179–188, 1936.

FONTAINE, J. R. J. et al. Cognitive structure of emotion terms in Indonesia and The Netherlands. **Cognition & Emotion**, v. 16, n. 1, p. 61–86, 2002.

FONTAINE, J. R. J. et al. The world of emotions is not two-dimensional. **Psychological science**, v. 18, n. 12, p. 1050–1057, 2007.

FORTINO, G.; GRAVINA, R. **Real-time Automatic Detection of Accelerative Cardiac Defense Response**. Proceedings of the 9th International Conference on Body Area Networks. **Anais...: BodyNets '14**. ICST, Brussels, Belgium, Belgium: ICST (Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering), 2014Disponível em: <<http://dx.doi.org/10.4108/icst.bodynets.2014.256997>>

FUKUNAGA, K.; NARENDRA, P. M. A branch and bound algorithm for computing k-nearest neighbors. **IEEE transactions on computers**, v. 100, n. 7, p.

750–753, 1975.

GEORGIEV, P. et al. **DSP.Ear: Leveraging Co-processor Support for Continuous Audio Sensing on Smartphones**. Proceedings of the 12th ACM Conference on Embedded Network Sensor Systems. **Anais...: SenSys '14**. New York, NY, USA: ACM, 2014. Disponível em: <<http://doi.acm.org/10.1145/2668332.2668349>>

GERHARDT, T. E.; SILVEIRA, D. T. **Métodos de pesquisa**. [s.l.] Plageder, 2009.

GHOSH, A.; DANIELI, M.; RICCARDI, G. **Annotation and prediction of stress and workload from physiological and inertial signals**. Engineering in Medicine and Biology Society (EMBC), 2015 37th Annual International Conference of the IEEE. **Anais...2015**

GHOSH, S. et al. **Impact of Experience Sampling Methods on Tap Pattern Based Emotion Recognition**. Adjunct Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing and Proceedings of the 2015 ACM International Symposium on Wearable Computers. **Anais...: UbiComp/ISWC'15 Adjunct**. New York, NY, USA: ACM, 2015. Disponível em: <<http://doi.acm.org/10.1145/2800835.2804396>>

GONÇALVES, V. P. **Uma abordagem para indicar o estado emocional de usuários em tempo de interação**. [s.l.] Universidade de São Paulo, 2016.

GRECO, A.; VALENZA, G.; SCILINGO, E. P. **Advances in Electrodermal Activity Processing with Applications for Mental Health: From Heuristic Methods to Convex Optimization**. 1st. ed. [s.l.] Springer Publishing Company, Incorporated, 2016.

GRIFFITHS, D.; CUNNINGHAM, S.; WEINEL, J. **A Discussion of Musical Features for Automatic Music Playlist Generation Using Affective Technologies**. Proceedings of the 8th Audio Mostly Conference. **Anais...: AM '13**. New York, NY, USA: ACM, 2013. Disponível em: <<http://doi.acm.org/10.1145/2544114.2544128>>

GUO, R. et al. **Pervasive and unobtrusive emotion sensing for human mental health**. 2013 7th International Conference on Pervasive Computing Technologies for Healthcare and Workshops. **Anais...2013**

HAYASHI, E. C. S.; BARANAUSKAS, M. C. C. **Towards a framework for the affective and emotional faces of usability**. Information Society (i-Society), 2011 International Conference on. **Anais...2011**

HEALEY, J.; PICARD, R. W.; OTHERS. Detecting stress during real-world driving tasks using physiological sensors. **IEEE Transactions on intelligent transportation systems**, v. 6, n. 2, p. 156–166, 2005.

HO, T. K. **Random decision forests**. Document analysis and recognition, 1995., proceedings of the third international conference on. **Anais...1995**

HOWARD, A. Elicitation of empathic emotions using film: Development of a stimulus set. 2014.

HUYNH, S. et al. **Jasper: Sensing Gamers' Emotions Using Physiological Sensors**. Proceedings of the 3rd Workshop on Mobile Gaming. **Anais...: MobiGames '16**. New York, NY, USA: ACM, 2016. Disponível em: <<http://doi.acm.org/10.1145/2934646.2934648>>

HUYNH, S.; BALAN, R. K.; LEE, Y. **Demo: Towards Recognition of Rich Non-Negative Emotions Using Daily Wearable Devices**. Proceedings of the 13th ACM Conference on Embedded Networked Sensor Systems. **Anais...: SenSys '15**. New York, NY, USA: ACM, 2015. Disponível em:

<<http://doi.acm.org/10.1145/2809695.2817859>>

JAIN, A. K.; DUIN, R. P. W.; MAO, J. Statistical pattern recognition: A review. **IEEE Transactions on pattern analysis and machine intelligence**, v. 22, n. 1, p. 4–37, 2000.

JONES, C. M.; TROEN, T. **Biometric Valence and Arousal Recognition**. Proceedings of the 19th Australasian Conference on Computer-Human Interaction: Entertaining User Interfaces. **Anais...: OZCHI '07**. New York, NY, USA: ACM, 2007. Disponível em: <<http://doi.acm.org/10.1145/1324892.1324929>>

KAPPELER-SETZ, C. et al. Towards Long Term Monitoring of Electrodermal Activity in Daily Life. **Personal Ubiquitous Comput.**, v. 17, n. 2, p. 261–271, 2013.

KARRAN, A. J.; FAIRCLOUGH, S. H.; GILLEADE, K. A Framework for Psychophysiological Classification Within a Cultural Heritage Context Using Interest. **ACM Trans. Comput.-Hum. Interact.**, v. 21, n. 6, p. 34:1–34:19, 2015.

KATSIGIANNIS, S.; RAMZAN, N. DREAMER: A Database for Emotion Recognition Through EEG and ECG Signals From Wireless Low-cost Off-the-Shelf Devices. **IEEE Journal of Biomedical and Health Informatics**, v. 22, n. 1, p. 98–107, jan. 2017.

KATSIS, C. D.; KATERTSIDIS, N. S.; FOTIADIS, D. I. An integrated system based on physiological signals for the assessment of affective states in patients with anxiety disorders. **Biomedical Signal Processing and Control**, v. 6, n. 3, p. 261–268, 2011.

KITCHENHAM, B. Procedures for performing systematic reviews. **Keele, UK, Keele University**, v. 33, n. 2004, p. 1–26, 2004.

KO, Y.-J. et al. **A Patient-centered medical environment with wearable sensors and cloud monitoring**. Internet of Things (WF-IoT), 2015 IEEE 2nd World Forum on. **Anais...2015**

KOELSTRA, S. et al. Deap: A database for emotion analysis; using physiological signals. **IEEE Transactions on Affective Computing**, v. 3, n. 1, p. 18–31, 2012.

KUNCHEVA, L. I. et al. **Multi-modal Biometric Emotion Recognition Using Classifier Ensembles**. Proceedings of the 24th International Conference on Industrial Engineering and Other Applications of Applied Intelligent Systems Conference on Modern Approaches in Applied Intelligence - Volume Part I. **Anais...: IEA/AIE'11**. Berlin, Heidelberg: Springer-Verlag, 2011. Disponível em: <<http://dl.acm.org/citation.cfm?id=2025756.2025796>>

KUSHKI, A. et al. A Kalman Filtering Framework for Physiological Detection of Anxiety-Related Arousal in Children With Autism Spectrum Disorder. **IEEE Transactions on Biomedical Engineering**, v. 62, n. 3, p. 990–1000, 2015.

LAHIRI, U.; WARREN, Z.; SARKAR, N. Design of a Gaze-Sensitive Virtual Social Interactive System for Children With Autism. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 19, n. 4, p. 443–452, 2011.

LANG, P. J. Behavioral treatment and bio-behavioral assessment: Computer applications. 1980.

LAURANS, G. F. G.; DESMET, P. M. A.; HEKKERT, P. P. M. **Assessing emotion in interaction: some problems and a new approach**. Proceedings of the 4th International Conference on Designing Pleasurable Products and Interfaces, DPPI'09, Compiegne, Oct. 2009. **Anais...2009**

LE, H. T.; VEA, L. A. **A Customer Emotion Recognition Through Facial Expression Using Kinect Sensors V1 and V2: A Comparative Analysis**. Proceedings of the 10th International Conference on Ubiquitous Information

Management and Communication. **Anais...: IMCOM '16**. New York, NY, USA: ACM, 2016. Disponível em: <<http://doi.acm.org/10.1145/2857546.2857628>>

LEE, H.; CHOI, Y. S.; KIM, Y. J. An adaptive user interface based on spatiotemporal structure learning. **IEEE Communications Magazine**, v. 49, n. 6, p. 118–124, 2011.

LEE, M. et al. **Empa talk: a physiological data incorporated human-computer interactions**. Proceedings of the extended abstracts of the 32nd annual ACM conference on Human factors in computing systems. **Anais...2014**

LI, S. et al. **MoodMagician: A Pervasive and Unobtrusive Emotion Sensing System Using Mobile Phones for Improving Human Mental Health**. Proceedings of the 12th ACM Conference on Embedded Network Sensor Systems. **Anais...: SenSys '14**. New York, NY, USA: ACM, 2014. Disponível em: <<http://doi.acm.org/10.1145/2668332.2668371>>

LICHTENSTEIN, A. et al. Comparing Two Emotion Models for Deriving Affective States from Physiological Data. In: PETER, C.; BEALE, R. (Eds.). **Affect and Emotion in Human-Computer Interaction: From Theory to Applications**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008. p. 35–50.

LISETTI, C. L.; NASOZ, F. **MAUI: A Multimodal Affective User Interface**. Proceedings of the Tenth ACM International Conference on Multimedia. **Anais...: MULTIMEDIA '02**. New York, NY, USA: ACM, 2002. Disponível em: <<http://doi.acm.org/10.1145/641007.641038>>

LOSEU, V. et al. **Applications of Sensing Platforms with Wearable Computers**. Proceedings of the 3rd International Conference on Pervasive Technologies Related to Assistive Environments. **Anais...: PETRA '10**. New York, NY, USA: ACM, 2010. Disponível em: <<http://doi.acm.org/10.1145/1839294.1839358>>

MAHLKE, S.; MINGE, M. Consideration of multiple components of emotions in human-technology interaction. In: **Affect and emotion in human-computer interaction**. [s.l.] Springer, 2008. p. 51–62.

MANLY, B. F. J. M. **Métodos estatísticos multivariados: uma introdução**. [s.l.] Bookman, 2008.

MAO, X.; BAO, H.; LI, Z. **Intelligent Emotion Decision System for Autonomous Agents**. 2008 Eighth International Conference on Intelligent Systems Design and Applications. **Anais...nov. 2008**

MASAI, K. et al. **AffectiveWear: towards recognizing affect in real life**. Adjunct Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing and Proceedings of the 2015 ACM International Symposium on Wearable Computers. **Anais...2015**

MATIKO, J. W. et al. Wearable EEG headband using printed electrodes and powered by energy harvesting for emotion monitoring in ambient assisted living. **Smart Materials and Structures**, v. 24, n. 12, 2015.

MATIKO, J. W.; BEEBY, S. P.; TUDOR, J. Real time emotion detection within a wireless sensor network and its impact on power consumption. **IET Wireless Sensor Systems**, v. 4, n. 4, p. 183–190, 2014.

MAURI, M. et al. **Psychophysiological signals associated with affective states**. Engineering in Medicine and Biology Society (EMBC), 2010 Annual International Conference of the IEEE. **Anais...2010**

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, v. 5, n. 4, p. 115–133, 1943.

MCDUFF, D. et al. **AffectAura: an intelligent system for emotional memory**. Proceedings of the SIGCHI Conference on Human Factors in Computing Systems. **Anais...2012**

MURALI, S.; RINCON, F.; ATIENZA, D. **A wearable device for physical and emotional health monitoring**. 2015 Computing in Cardiology Conference (CinC). **Anais...2015**

NAKAGAWA, E. Y. et al. **Revisão Sistemática da Literatura em Engenharia de Software: Teoria e Prática**. [s.l.] Elsevier Brasil, 2017.

NORMAN, D. A. **Emotion design: Why we love (or hate) everyday things** Basic Books, , 2004.

OCASIO-DE JESÚS, V.; KENNEDY, A.; WHITTINGHILL, D. **Impact of Graphical Fidelity on Physiological Responses in Virtual Environments**. Proceedings of the 19th ACM Symposium on Virtual Reality Software and Technology. **Anais...: VRST '13**. New York, NY, USA: ACM, 2013 Disponível em: <<http://doi.acm.org/10.1145/2503713.2503751>>

PARROTT, W. G. **Emotions in social psychology: Essential readings**. [s.l.] Psychology Press, 2001.

PECCHINENDA, A. The psychophysiology of appraisals. **Appraisal processes in emotion: Theory, methods, research**, p. 301–315, 2001.

PETER, C.; EBERT, E.; BEIKIRCH, H. **A Wearable Multi-sensor System for Mobile Acquisition of Emotion-related Physiological Data**. Proceedings of the First International Conference on Affective Computing and Intelligent Interaction. **Anais...: ACII'05**. Berlin, Heidelberg: Springer-Verlag, 2005 Disponível em: <http://dx.doi.org/10.1007/11573548_89>

PICARD, R. W.; VYZAS, E.; HEALEY, J. Toward machine emotional intelligence: analysis of affective physiological state. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 23, n. 10, p. 1175–1191, 2001.

PINTO, A. Psicologia geral. **Lisboa Universidade Aberta**, n. 227, p. 340, 2001.

PLUTCHIK, R. The nature of emotions: Human emotions have deep evolutionary roots, a fact that may explain their complexity and provide tools for clinical practice. **American scientist**, v. 89, n. 4, p. 344–350, 2001.

POLLMANN, K. **Real-Time Emotion Detection for Neuro-Adaptive Systems**. Proceedings of the 20th International Conference on Intelligent User Interfaces Companion. **Anais...: IUI Companion '15**. New York, NY, USA: ACM, 2015 Disponível em: <<http://doi.acm.org/10.1145/2732158.2732161>>

POLLMANN, K.; VUKELIĆ, M.; PEISSNER, M. **Towards affect detection during human-technology interaction: An empirical study using a combined EEG and fNIRS approach**. 2015 International Conference on Affective Computing and Intelligent Interaction (ACII). **Anais...2015**

RAFIQI, S.; NAIR, S.; FERNANDEZ, E. **Cognitive and Context-aware Applications**. Proceedings of the 7th International Conference on Pervasive Technologies Related to Assistive Environments. **Anais...: PETRA '14**. New York, NY, USA: ACM, 2014 Disponível em: <<http://doi.acm.org/10.1145/2674396.2674445>>

RATHOD, P.; GEORGE, K.; SHINDE, N. **Bio-signal based emotion detection device**. 2016 IEEE 13th International Conference on Wearable and Implantable Body Sensor Networks (BSN). **Anais...2016**

RATTANYU, K.; OHKURA, M.; MIZUKAWA, M. **Emotion monitoring from physiological signals for service robots in the living space**. ICCAS 2010.

Anais...2010

REITZ, K.; STOCKHAUSEN, C.; KRÖMKER, D. **Zone of Impulse: Physiological Data Enhanced Gaming**. Proceedings of the 14th International Conference on Human-computer Interaction with Mobile Devices and Services Companion. **Anais...: MobileHCI '12**. New York, NY, USA: ACM, 2012. Disponível em: <<http://doi.acm.org/10.1145/2371664.2371718>>

RUSSELL, J. A Circumplex Model of Affect. **Journal of Personality and Social Psychology**, v. 39, p. 1161–1178, 1980.

RUSSELL, J. A. Introduction to Special Section: On Defining Emotion. **Emotion Review**, v. 4, n. 4, p. 337, 2012.

RYOO, D.-W.; KIM, Y.-S.; LEE, J.-W. **Wearable systems for service based on physiological signals**. Engineering in Medicine and Biology Society, 2005. IEEE-EMBS 2005. 27th Annual International Conference of the. **Anais...2006**

SCHAEFER, A. et al. Assessing the effectiveness of a large database of emotion-eliciting films: A new tool for emotion researchers. **Cognition and Emotion**, v. 24, n. 7, p. 1153–1172, 2010.

SCHERER, K. R. On the nature and function of emotion: A component process approach. **Approaches to emotion**, v. 2293, p. 317, 1984.

SCHERER, K. R. Appraisal considered as a process of multilevel sequential checking. **Appraisal processes in emotion: Theory, methods, research**, v. 92, n. 120, p. 57, 2001.

SCHERER, K. R. What are emotions? And how can they be measured? **Social science information**, v. 44, n. 4, p. 695–729, 2005.

SCOTTI, S. et al. **Automatic Quantitative Evaluation of Emotions in E-learning Applications**. 2006 International Conference of the IEEE Engineering in Medicine and Biology Society. **Anais...2006**

SHIRAHAMA, K.; GRZEGORZEK, M. Emotion Recognition Based on Physiological Sensor Data Using Codebook Approach. In: **Information Technologies in Medicine**. [s.l.] Springer, 2016. p. 27–39.

SOKOLOVA, M. V et al. A Distributed Architecture for Multimodal Emotion Identification. In: BAJO, J. et al. (Eds.). **Trends in Practical Applications of Agents, Multi-Agent Systems and Sustainability: The PAAMS Collection**. Cham: Springer International Publishing, 2015. p. 125–132.

SOLEYMANI, M. et al. A multimodal database for affect recognition and implicit tagging. **IEEE Transactions on Affective Computing**, v. 3, n. 1, p. 42–55, 2012.

SOURINA, O.; LIU, Y. EEG-enabled Affective Human-Computer Interfaces. In: STEPHANIDIS, C.; ANTONA, M. (Eds.). **Universal Access in Human-Computer Interaction. Design and Development Methods for Universal Access: 8th International Conference, UAHCI 2014, Held as Part of HCI International 2014, Heraklion, Crete, Greece, June 22-27, 2014, Proceedings, Part I**. Cham: Springer International Publishing, 2014. p. 536–547.

STEMMLER, G. Methodological considerations in the psychophysiological study of emotion. **Handbook of affective sciences**, v. 37, p. 225–255, 2003.

SUBRAMANIAN, R. et al. ASCERTAIN: Emotion and Personality Recognition Using Commercial Sensors. **IEEE Transactions on Affective Computing**, v. 9, n. 2, p. 147–160, 2016.

SURREL, G. et al. **Design of ultra-low-power smart wearable systems**. 2015 16th Latin-American Test Symposium (LATS). **Anais...2015**

TAYLOR, B. et al. **Using Physiological Sensors to Detect Levels of User**

Frustration Induced by System Delays. Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing. **Anais...: UbiComp '15.**New York, NY, USA: ACM, 2015Disponível em: <<http://doi.acm.org/10.1145/2750858.2805847>>

TREVOR, H.; ROBERT, T.; JH, F. **The elements of statistical learning: data mining, inference, and prediction**New York, NY: Springer, , 2009.

TSAI, H. H.; YI, C. W. **Wearable ECG for Tension Assessment in Movie Watching and Adventure Riding.** 2015 11th International Conference on Mobile Ad-hoc and Sensor Networks (MSN). **Anais...2015**

V, P. T. et al. **Wearable Device for Health Care Applications.** 2013 Texas Instruments India Educators' Conference. **Anais...2013**

VAN SOMEREN, M. W.; BARNARD, Y. F.; SANDBERG, J. A. C. **The think aloud method. A practical guide to modeling cognitive process [El método del pensamiento en voz alta. Una guía práctica para modelar los procesos cognitivos] cognitivos**Londres: Academic Press [versión electrónica], , 1994.

WACHE, J. et al. **Implicit User-centric Personality Recognition Based on Physiological Responses to Emotional Videos.** Proceedings of the 2015 ACM on International Conference on Multimodal Interaction. **Anais...: ICMI '15.**New York, NY, USA: ACM, 2015Disponível em: <<http://doi.acm.org/10.1145/2818346.2820736>>

WIENER, N. **Extrapolation, Interpolation, and Smoothing of Stationary Time Series.** [s.l.] The MIT Press, 1964.

XAVIER, R. A. C.; DE ALMEIDA NÉRIS, V. P. **A Hybrid Evaluation Approach for the Emotional State of Information Systems Users.** ICEIS (3). **Anais...2012**

ZHANG, D. et al. A Data-Driven Design for Fault Detection of Wind Turbines Using Random Forests and XGboost. **IEEE Access**, v. 6, p. 21020–21031, 2018.

ZÜGER, M.; FRITZ, T. **Interruptibility of Software Developers and Its Prediction Using Psycho-Physiological Sensors.** Proceedings of the 33rd Annual ACM Conference on Human Factors in Computing Systems. **Anais...: CHI '15.**New York, NY, USA: ACM, 2015Disponível em: <<http://doi.acm.org/10.1145/2702123.2702593>>

Apêndice A

QUESTIONÁRIO PRÉ - SESSÃO

Perfil do participante

1. Gênero:

- Feminino;
- Masculino.

2. Idade: ____ anos.

3. Qual o seu grau de escolaridade:

- Nenhuma escolaridade;
- Ensino Fundamental: 1ª a 4ª série;
- Ensino Fundamental: 5ª a 8ª série;
- Ensino médio;
- Superior;
- Pós-graduação.

4. Você possui algum problema de saúde? Se sim, qual?

- Sim. Qual? _____.
- Não.

5. Com que frequência você assiste a filmes?

- todo dia

- três vezes por semana
- uma vez por semana
- duas vezes por mês
- uma vez por mês
- menos de uma vez por mês

Apêndice B

QUESTIONÁRIO PÓS SESSÃO

Questionário – Pós-sessão

1. Você já participou de algum experimento de análise de emoções?

Sim;

Não.

2. Considerando uma escala de 1 a 5 (em que 1 é menor conforto e 5 é maior conforto), como você avaliaria o seu nível de conforto durante o experimento?

<input type="checkbox"/>				
1	2	3	4	5
Menor conforto				Maior Conforto

Apêndice C

PROTOCOLO DO EXPERIMENTO

Protocolo experimento

Você participará de um experimento em que assistirá alguns trechos de filmes. Esses trechos de filmes foram obtidos de um banco e já foram pré-classificados considerando emoções que eles despertam. Durante a sessão de filme, você poderá sentir as seguintes emoções: raiva, desgosto, depressão, tristeza, empatia, carinho, felicidade, excitação, ódio, melancolia, calma, relaxamento, prazer, felicidade e paixão. Além disso, os trechos a serem assistidos podem conter cenas de nudez. Você pode ficar à vontade para desistir a qualquer momento.

- Você concorda em participar?
- Se a resposta for sim:
- Enquanto assiste, sensores estarão captando informações fisiológicas para posterior análise. Pedimos que você expresse verbalmente o que está sentindo (qual emoção) em relação ao trecho de filme.

- Explicar SAM.

Assinatura de formulários

- TCLE
- Autorização de captação de imagem, som e nome

Preenchimento de questionário pré-sessão

- Idade

- Gênero
- Escolaridade
- Você possui algum problema de saúde?
- Com que frequência você assiste a filmes?
- () todo dia
- () três vezes por semana
- () uma vez por semana
- () duas vezes por mês
- () uma vez por mês
- () menos de uma vez por mês

Experimento

- Antes de cada rodada: mostrar vídeo com emoção neutra
- Intervalo
- Após cada rodada:
- Preencher SAM
- Dar intervalo de 3 minutos

Rodada 1

- Think Aloud (durante)
- SAM

(após)

Rodada 2

- Think Aloud (durante)
- SAM

(após)

Rodada 3

- Think Aloud (durante)
- SAM

(após)

Rodada 4

- Think Aloud (durante)
- SAM (após)

Preenchimento de questionário pós-sessão

- Você já participou de algum experimento de análise de emoções?
- Considerando uma escala de 1 a 5 (em que 1 é menor conforto e 5 é maior conforto), como você avaliaria o seu nível de conforto durante o experimento?

Apêndice D

TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO

Termo de Consentimento Livre e Esclarecido

1. Você está sendo convidado para participar da pesquisa “Avaliação da resposta emocional ao assistir trechos de filmes e vídeos”.
2. Você foi selecionado para ser voluntário e sua participação não é obrigatória.
3. A qualquer momento você pode desistir de participar e retirar seu consentimento.
4. Sua recusa não trará nenhum prejuízo em sua relação com o pesquisador, com a instituição.
5. Essa pesquisa tem por objetivo construir um dataset com respostas emocionais provenientes de sensores fisiológicos, usando como estímulo trechos de filmes comerciais e de vídeos.
6. Sua participação nesta pesquisa consistirá em assistir a um conjunto de trechos de filmes e vídeos musicais e indicar, por meio de um questionário e por meio da voz, qual foi a sua resposta emocional ao conteúdo assistido.
7. A sua participação na pesquisa pode envolver algum desconforto relacionado ao tempo despendido com a realização da sessão e do preenchimento de questionários, sendo que faremos o possível para minimizar possíveis desconfortos. Os vídeos selecionados podem provocar alguma alteração no seu estado emocional e algum desconforto devido ao conteúdo audiovisual exibido. Ao assistir aos trechos de filmes e vídeos, você pode sentir as seguintes emoções: raiva, desgosto, depressão, tristeza, empatia, carinho, felicidade e excitação. O conteúdo do material a ser assistido pode conter cenas de nudez. Em relação ao conteúdo dos questionários, os mesmos serão planejados de modo a evitar possíveis constrangimentos ou desconfortos, e caso ocorram você pode se recusar a responder ou mesmo interromper a sua participação a qualquer momento, sem qualquer prejuízo em sua relação com a instituição ou com o pesquisador.
8. Os benefícios relacionados com a sua participação são os descritos no item 5 deste termo e você terá acesso aos resultados da pesquisa por meio de artigos científicos publicados em congressos e pelo site do laboratório LIFES: <http://lifes.dc.ufscar.br>.
9. As informações obtidas através dessa pesquisa serão confidenciais e asseguramos o sigilo sobre sua participação.

10. Os dados não serão divulgados de forma a possibilitar sua identificação.

11. Você receberá uma cópia deste termo onde consta o telefone e o endereço do pesquisador principal, podendo tirar suas dúvidas sobre o projeto e sua participação, agora ou a qualquer momento.

Tatiana Silva de Alencar
Departamento de Computação (DC)
Universidade Federal de São Carlos (UFSCar)
Caixa Postal 676
13565-905 São Carlos-SP
Tel.: 16-33518626
Endereço e telefone da
Pesquisadora
Rua Antonio Rossete, 206,
Jd. Nova São Carlos
CEP: 13570-212 –
São Carlos-SP Tel.:
(11) 997030885

Declaro que entendi os objetivos, riscos e benefícios de minha participação na pesquisa e concordo em participar.

São Carlos, ___/___/18_

Assinatura do Sujeito da pesquisa ou do seu Responsável

Apêndice E

AUTORIZAÇÃO DE CAPTAÇÃO E EXIBIÇÃO DE IMAGEM

AUTORIZAÇÃO DE CAPTAÇÃO E EXIBIÇÃO DE IMAGEM, SOM E NOME

Eu, _____, (nacionalidade)
_____, (estado _____ civil)
_____ portador da Cédula de Identidade RG nº ____ (ou Registro Nacional de
Estrangeiro _____), inscrito no CPF/MF sob o
número ____ autorizo a captação, utilização e exibição de minha voz e imagem pela
UNIVERSIDADE FEDERAL DE SÃO CARLOS – UFSCar, diretamente ou através do
Departamento de Computação – DC ou outra entidade vinculada ou contratada, a serem
utilizadas em obras audiovisuais a serem produzidas para fins institucionais, didáticos e/ou
científicos, sejam essas destinadas à divulgação ao público em geral e/ou apenas para uso
interno desta instituição.

1. A presente autorização, concedida a título gratuito, confere à UFSCar, diretamente ou através do Laboratório LIFeS – DC ou outra entidade vinculada ou contratada, o direito de utilizar minhas imagens e voz, nas obras para veiculação interna na UFSCar, bem como em eventos externos, no Brasil e no exterior, por mídia escrita, eletrônica ou digital, tais como Revistas, Manuais, Portais de Internet, folders, atividades de caráter didático ou científico, trabalhos científicos, programas de Rádio e TV, publicações em geral, entre outros, a critério exclusivo da UFSCar, desde que não haja desvirtuamento da sua finalidade.
2. As obras poderão ser distribuídas pelo Laboratório LIFeS – DC – UFSCar ou por outra entidade vinculada ou contratada, de forma gratuita ou comercial, sendo certo que nada será devido pelo uso das imagens ou voz objetos da presente autorização, mesmo nas hipóteses de comercialização das obras, em parceria ou não com outras pessoas jurídicas.
3. Declaro estar ciente de que as imagens e voz captadas nesta ocasião farão parte de um “banco de imagens” pertencente ao Laboratório LIFeS – DC – UFSCar e que poderão ser utilizadas a qualquer tempo e de acordo com os critérios da mesma.

4. Por esta ser a expressão da minha vontade declaro que autorizo o uso acima descrito sem que nada haja a ser reclamado a título de direitos conexos à minha imagem ou a qualquer outro título, e assino a presente autorização em 02 (duas) vias de igual teor e forma.

São Carlos, de _____ de
2018.

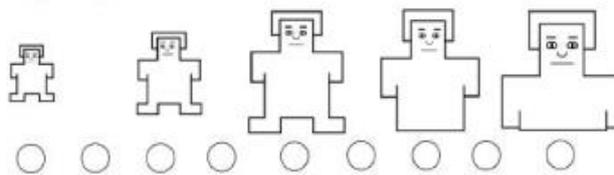
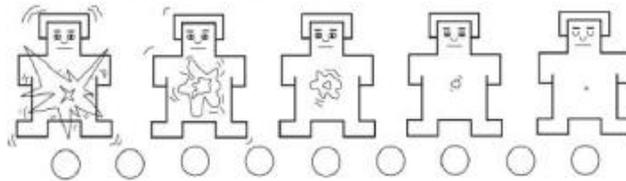
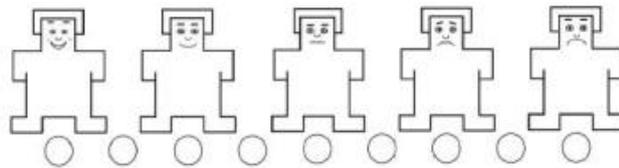
(Assinatura)

(Nome por extenso)

Anexo A

SAM

Id: _____



ANEXO B

PARECER CONSUBSTANCIADO DO CEP



PARECER CONSUBSTANCIADO DO CEP

DADOS DO PROJETO DE PESQUISA

Título da Pesquisa: INVESTIGANDO EMOÇÕES NA INTERAÇÃO HUMANO-COMPUTADOR: COLETA E ARMAZENAGEM DE SINAIS FISIOLÓGICOS

Pesquisador: ISAQUE ELCIO DE SOUZA

Área Temática:

Versão: 2

CAAE: 92229318.9.0000.5504

Instituição Proponente: Centro de Ciências Exatas e de Tecnologia

Patrocinador Principal: FUNDAÇÃO DE AMPARO A PESQUISA DO ESTADO DE SÃO PAULO

DADOS DO PARECER

Número do Parecer: 2.789.819

Apresentação do Projeto:

Estudo transversal, experimental, com análise quantiqualitativa. Trinta e cinco voluntários entre maiores de 16 anos serão convidados a participarem da pesquisa. Eles deverão assistir a trechos de filmes e estarão monitorizados através de seguintes sensores fisiológicos que avaliarão: 1) eletrocardiograma (batimentos cardíacos) e contém 3 eletrodos que são colocados no corpo do participante; 2) resposta galvânica(GSR) coleta eletro condutividade da pele, dois anéis elástico colocado nos dedos; e 3) Eletroencefalografia (EEG) coleta atividade elétrica no cérebro, acoplado na cabeça do usuário em formato de fone de ouvido. Além disso, uma webcam coletará as expressões faciais e será inferido estado emocional. Um sistema computacional coleta dados de ambos os sensores e salva em uma base de dados. Outra câmera posicionada ao lado do participante para gravar expressões e relatos do mesmo. Durante o experimento, o participante é orientado a relatar o que está sentindo (método "Think aloud" – em português, "pensamento em voz alta") e o relato é anotado pelo pesquisador presente. Em cada trecho assistido, o voluntário também irá responder um questionário. No início do experimento participante responde questionário para coleta de dados demográficos pré-sessão. Já no final de cada sessão que será apresentado posteriormente, o participante responderá questionário pós-sessão relacionado ao conforto durante experimento.

Endereço: WASHINGTON LUIZ KM 235
Bairro: JARDIM GUANABARA CEP: 13.565-905
UF: SP Município: SÃO CARLOS
Telefone: (16)3351-9683 E-mail: cephumanos@ufscar.br



Continuação do Parecer: 2.789.819

Objetivo da Pesquisa:

O pesquisador aponta que o presente projeto de pesquisa apresenta como objetivo a definição, desenvolvimento e a validação de uma base de dados de sinais fisiológicos e expressão facial para criação de um dataset classificada de acordo com o estado emocional.

Avaliação dos Riscos e Benefícios:

O pesquisador aponta como riscos: estresse, cansaço e tédio, seja pelos conteúdos, tempo de duração os trechos ou cliques, tempo de intervalo ou resposta de questionários. Também informa que o sujeito de pesquisa pode, ainda, sentir as seguintes emoções: raiva, desgosto, depressão, tristeza, empatia, carinho, felicidade, excitação, ódio, melancolia, calma, relaxado, prazer, felicidade e paixão. Há também trechos a serem assistidos que poderão conter cenas parciais de nudez. E por fim, o voluntário poderá se sentir desconfortável com sensores no corpo ou por estar sendo avaliado. Quanto aos benefícios, informa ausência de benefício direto, mas esta informação não está descrita no TCLE.

Comentários e Considerações sobre a Pesquisa:

O projeto de pesquisa possui relevância à área em questão. O novo cronograma aponta que o início da coleta será em outubro.

Considerações sobre os Termos de apresentação obrigatória:

A folha de rosto foi anexada. Representou TCLE, porém não está presente a informação da ausência de benefício direto ao participante, conforme determina a Resolução CNS 466/12. As demais correções apontadas foram realizadas nesta versão. O pesquisador alterou os critérios de inclusão e, agora, a idade mínima é de 18 anos.

Conclusões ou Pendências e Lista de Inadequações:

Projeto aprovado com a seguinte recomendação: "Acrescentar no TCLE a informação de que não haverá benefício direto ao voluntário da pesquisa, conforme determina a Resolução CNS 466/12.

Considerações Finais a critério do CEP:

Projeto aprovado com recomendação.

Este parecer foi elaborado baseado nos documentos abaixo relacionados:

Tipo Documento	Arquivo	Postagem	Autor	Situação
Informações Básicas do Projeto	PB_INFORMAÇÕES_BÁSICAS_DO_PROJETO_1147543.pdf	18/07/2018 00:00:35		Aceito

Endereço: WASHINGTON LUIZ KM 235

Bairro: JARDIM GUANABARA

CEP: 13.565-905

UF: SP

Município: SÃO CARLOS

Telefone: (16)3351-9683

E-mail: cephumanos@ufscar.br



UFSCAR - UNIVERSIDADE
FEDERAL DE SÃO CARLOS



Continuação do Parecer: 2.789.819

Projeto Detalhado / Brochura Investigador	projeto_detalhado01.pdf	17/07/2018 23:57:37	ISAQUE ELCIO DE SOUZA	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLE.pdf	17/07/2018 23:55:49	ISAQUE ELCIO DE SOUZA	Aceito
Folha de Rosto	folha_de_rosto.pdf	06/06/2018 01:11:18	ISAQUE ELCIO DE SOUZA	Aceito

Situação do Parecer:

Aprovado

Necessita Apreciação da CONEP:

Não

SAO CARLOS, 30 de Julho de 2018

Assinado por:
Priscilla Hortense
(Coordenador)

Endereço: WASHINGTON LUIZ KM 235

Bairro: JARDIM GUANABARA

CEP: 13.565-905

UF: SP

Município: SAO CARLOS

Telefone: (16)3351-9683

E-mail: ceohumanos@ufscar.br

