



**UNIVERSIDADE ESTADUAL DA PARAÍBA
CAMPUS I
PRÓ-REITORIA DE PÓS-GRADUAÇÃO E PESQUISA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA E TECNOLOGIA EM SAÚDE
MESTRADO PROFISSIONAL EM CIÊNCIA E TECNOLOGIA EM SAÚDE**

CAROLINE SOUSA TRUTA RAMALHO

**ESTUDO SOBRE *BIOFEEDBACK* E COMPORTAMENTO EMOCIONAL PARA
USO EM LABORATÓRIO DE USABILIDADE**

CAMPINA GRANDE- PB

2021

CAROLINE SOUSA TRUTA RAMALHO

**ESTUDO SOBRE *BIOFEEDBACK* E COMPORTAMENTO EMOCIONAL PARA
USO EM LABORATÓRIO DE USABILIDADE**

Trabalho de Dissertação apresentada ao Programa de Pós-Graduação em Ciências e Tecnologia em Saúde da Universidade Estadual da Paraíba, como requisito parcial à obtenção do título de mestre em Ciência e Tecnologia em Saúde.

Área de concentração: Usabilidade.

Orientador: Prof.Dr. Daniel Scherer.

CAMPINA GRANDE- PB

2021

É expressamente proibido a comercialização deste documento, tanto na forma impressa como eletrônica. Sua reprodução total ou parcial é permitida exclusivamente para fins acadêmicos e científicos, desde que na reprodução figure a identificação do autor, título, instituição e ano do trabalho.

R165e Ramalho, Caroline Sousa Truta.
Estudo sobre *biofeedback* e comportamento emocional para uso em laboratório de usabilidade [manuscrito] / Caroline Sousa Truta Ramalho. - 2021.
142 p. : il. colorido.

Digitado.
Dissertação (Mestrado em Profissional em Ciência e Tecnologia em Saúde) - Universidade Estadual da Paraíba, Pró-Reitoria de Pós-Graduação e Pesquisa, 2021.
"Orientação : Prof. Dr. Daniel Scherer, Departamento de Computação - CCT."

1. Usabilidade. 2. Biofeedback. 3. Comportamento emocional. I. Título

21. ed. CDD 600

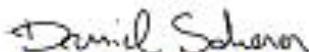
CAROLINE SOUSA TRUTA RAMALHO

**ESTUDO SOBRE BIOFEEDBACK E COMPORTAMENTO
EMOCIONAL PARA USO EM LABORATÓRIO DE USABILIDADE**

Dissertação apresentada ao Programa de Pós-Graduação em Ciência e Tecnologia em Saúde da Universidade Estadual da Paraíba como requisito para obtenção do título de Mestre em Ciência e Tecnologia em Saúde.

Dissertação aprovada em: 29/01/2021

BANCA EXAMINADORA:



Prof. Dr. Daniel Scherer
Universidade Estadual da Paraíba (UEPB)



Prof. Dr. Danilo de Almeida Vasconcelos
Universidade Estadual da Paraíba (UEPB)



Prof. Dr. Ademir Virgolino da Silva Netto
Universidade Federal da Paraíba (UFPB)

Dedico esta monografia à Deus, a Nossa Senhora e a minha mãe Marta, pelo amor incondicional que sempre foi concebido durante toda minha vida e por sempre ser a força, a luz no meu caminho, me proporcionando aparatos e capacidade de nunca desistir dos meus sonhos. *“Quem me oferece sua gratidão como sacrifício honra-me e eu mostrarei a salvação de Deus ao que anda nos meus caminhos”*. Salmos 50:23.

AGRADECIMENTOS

Agradeço a **Deus e a Nossa Senhora**, por ter me abençoado durante toda minha trajetória de vida até aqui, sempre me dando muita luz, amor e me capacitando para sempre ser um ser humano melhor.

A minha mãe **Marta**, um ser humano sem igual que me deu a dádiva da vida, sempre sendo meu maior exemplo e minha guerreira, fazendo o possível e o impossível para que eu pudesse ser a pessoa que me tornei, a minha sincera gratidão, que Deus possa continuar abençoando nosso amor e vida, com muita saúde, amor e felicidade.

A minha família **Truta e Ramalho**, por sempre me proporcionar o apoio emocional e por acreditar que posso ir cada vez mais longe, por todo amor e dedicação para comigo. Em especial na pessoa de **Maria do Socorro e Otaviano (in memoriam) avôs maternos e Zelita e Severino (avôs paternos)**.

Ao meu orientador **Daniel Scherer**, por todo conhecimento repassado durante todos esses anos, por todas as oportunidades que me foram dadas nesse processo, por toda paciência de me entender mesmo quando nem eu acreditava mais em mim e por me fazer amar a usabilidade. Que possamos caminhar e trabalhar ainda mais juntos. Minha sincera gratidão.

Aos meus amigos do mestrado, por estarem sempre juntos e se apoiando durante todo o processo, em especial a: **Felipe Madia, Tuanny, Eduardo, Daniel, Chiquinho, Fábio e Antônio**.

A minha banca (**Professor Ademar e Professor Danilo**), por toda paciência e contribuição no meu trabalho.

Aos meus amigos, por estarem comigo nesse processo, principalmente no ano mais difícil da minha vida (2020), por terem sido todo apoio e sustento que eu precisava, obrigado por acreditaram em mim. Eu amo vocês. Em especial: **Adília Karoline, Gustavo Pereira, Eugênio Samer, Catarina Lima, Joel Guimarães, Huzevelt Guimarães e Lucas Rocha**.

RESUMO

A usabilidade é definida pela *Internacional Organization for Standardization*, segundo a ISO 9241-11:1998 como uma medida para melhorar a facilidade de utilização de um *software* durante o processo de uso, visando alcançar objetivos específicos como: eficácia, eficiência e satisfação. Assim, dentro do contexto da avaliação de IHS, é necessário identificar os estados emocionais dos usuários para entender o impacto que as emoções geram na operação dos sistemas pelos usuários. Uma alternativa para esse mapeamento é o uso de sistemas de *biofeedback*, onde se utilizam instrumentos eletrônicos ou eletromecânicos através de sensores que coletam sinais fisiológicos do corpo, sendo processados e seguindo para um software que realiza o tratamento dos dados, disponibilizando as informações em um *display*. O presente trabalho teve como objetivo identificar equipamentos que mensurem sinais fisiológicos e que auxiliem no reconhecimento emocional de usuários em um ambiente de teste de usabilidade. A pesquisa foi realizada por meio de uma revisão integrativa, em que foi possível identificar os equipamentos para o reconhecimento emocional: **o eletrocardiograma, a termografia, a eletromiografia, a resposta galvânica da pele, a taxa de respiração e o eletroencefalograma**, bem como os algoritmos relacionados a cada sinal e seus locais de aplicação no corpo. Dado o estudo o equipamento que tem o maior expecto para identificar o emocional é o eletrocardiograma, e o que traz menor informação é a taxa de respiração. Considerando uma avaliação de usabilidade em que o usuário está estático e que se possa ter a visão do rosto dele, com controle de temperatura e com iluminação adequada na sala de teste, a termografia é a opção mais interessante para identificar o emocional do usuário, se apresentar limitações de ambiente, temperatura, o eletrocardiograma é a opção mais adequada. Caso o usuário esteja se movimentando, pode se utilizar o eletrocardiograma e a condutância galvânica da pele, que permite ser utilizado em dispositivos vestíveis, apesar de não ser plenamente confiável porque em movimento, existe uma geração de ruídos e problemas inerentes ao movimento que podem interferir no resultado do sinal.

Palavras - chaves: Usabilidade. *Biofeedback*. Emoção. Comportamento emocional.

ABSTRACT

Usability is defined by the International Organization for Standardization, according to ISO 9241-11: 1998 as a measure to improve the ease of use of software during the process of use, aiming to achieve specific objectives such as: effectiveness, efficiency and satisfaction. Thus, within the context of the IHS assessment, it is necessary to identify the emotional states of the users to understand the impact that emotions generate in the operation of the systems by the users. An alternative for this mapping is the use of biofeedback systems, where electronic or electromechanical instruments are used through sensors that collect physiological signals from the body, being processed and going to a software that performs the treatment of the data, making the information available on a display. . The present work had as objective to identify equipments that measure physiological signals and that assist in the emotional recognition of users in a usability test environment. The research was carried out through an integrative review, in which it was possible to identify the equipment for emotional recognition: the electrocardiogram, the thermography, the electromyography, the galvanic skin response, the respiration rate and the electroencephalogram, as well as the algorithms related to each signal and its application sites on the body. Given the study, the equipment that has the greatest expectation to identify the emotional is the electrocardiogram, and what brings less information is the respiration rate. Considering a usability evaluation in which the user is static and that one can have a view of his face, with temperature control and with adequate lighting in the test room, thermography is the most interesting option to identify the user's emotional, if present limitations of environment, temperature, the electrocardiogram is the most appropriate option. If the user is moving, the electrocardiogram and the galvanic conductance of the skin can be used, which allows it to be used in wearable devices, although it is not fully reliable because in motion, there is a generation of noise and problems inherent to the movement that can interfere in the signal result.

Keywords: Usability. *Biofeedback*. Emotion. Emotional behavior.

LISTA DE ILUSTRAÇÕES

Figura 1 - Posicionamento dos eletrodos de EEG.....	51
Figura 2 - Ondas do ECG.....	52
Figura 3 - Biopac 150.....	59
Figura 4 - <i>Shimmer GSR</i>	60
Figura 5 - <i>MindWave Mobile 2</i>	60
Figura 6 - Derivações de ECG.....	65
Figura 7 - Derivações de ECG no tórax.....	65
Figura 8 - Variações no eletrocardiograma.....	66
Figura 9 - Ondas do Ciclo Cardíaco.....	67
Figura 10 - Representação da Onda P.....	68
Figura 11 - PowerLab.....	78
Figura 12 - MP 100.....	78
Figura 13 - Shimmer ECG.....	79
Figura 14 - Eego mylab.....	80
Figura 15 - Pulseira E4.....	80
Figura 16 - Monitor Nexfin HD.....	81
Figura 17 - MP 150.....	81
Figura 18 - MP 36.....	82
Figura 19 - Regiões vasculares afetadas pela temperatura subcutânea na face e captura da imagem térmica infravermelha.....	89
Figura 20 - Câmera Therm App.....	90
Figura 21 - Termovisor Flir E6.....	91
Figura 22 - Termovisor T640.....	91
Figura 23 - Flir A310.....	92
Figura 24 - Sensor de taxa de respiração (RR).....	94
Figura 25 - MP100.....	96
Figura 26 - Pontos de aplicação dos eletrodos de eletromiografia.....	100
Figura 27 - Biosemi ActiveTwo.....	104
Figura 28 - Nexus 32.....	105
Figura 29 - Bionomadix.....	105
Figura 30 - Eletrodos de EEG no couro cabeludo.....	109
Figura 31 - Emotiv Epoc.....	117

Figura 32 - Sensores de condutância galvânica da pele.....	121
Figura 33 - Pulseira E4.....	124
Figura 34 - e- Health Sensor Shield.....	125

LISTA DE TABELAS

Tabela 1 - Artigos sobre equipamentos em geral de <i>biofeedback</i> para identificação do emocional.....	41
Tabela 2 - Valores de frequência cardíaca e temperatura de acordo com as emoções.....	47
Tabela 3 - Sinais fisiológicos e suas correlações com as emoções.....	55
Tabela 4 - Tabela de equipamentos gerais de sinais fisiológicos.....	59
Tabela 5 - Artigos sobre equipamentos de eletrocardiograma para identificação do emocional.....	62
Tabela 6 - Tabela de equipamentos ECG.....	77
Tabela 7 - Vantagens e desvantagens do ECG.....	83
Tabela 8. Artigos de Termografia.....	83
Tabela 9 - Direções das variações de temperatura, de acordo com o estímulo emocional.....	89
Tabela 10 - Tabela de Equipamentos Termografia.....	90
Tabela 11 - Vantagens e desvantagens da Termografia.....	93
Tabela 12 - Artigos RR.....	93
Tabela 13 - Tabela de Equipamentos RR.....	96
Tabela 14 - Vantagens e desvantagens do RR.....	97
Tabela 15 - Artigos de Eletromiografia.....	97
Tabela 16 - Relações entre emoções e expressões faciais.....	99
Tabela 17 - Tabela de Equipamentos de Eletromiografia.....	104
Tabela 18 - Vantagens e desvantagens do EMG.....	107
Tabela 19 - Artigos Eletroencefalograma.....	107
Tabela 20 - Classificação das ondas cerebrais.....	110
Tabela 21 - Tabela de Equipamentos EEG.....	116
Tabela 22 - Vantagens e desvantagens do EEG.....	118
Tabela 23 - Artigos de GSR.....	118
Tabela 24 - Tabela de Equipamentos GSR.....	124
Tabela 25 - Vantagens e desvantagens do GSR.....	126

LISTA DE FLUXOGRAMAS

Fluxograma 1 - Dados da busca da string “physiological signals AND emotion AND sensor”.....	33
Fluxograma 2 - Dados da busca da string “Electrocardiography AND emotion”.....	34
Fluxograma 3 - Dados da busca da string “Thermography AND emotion”.....	35
Fluxograma 4 - Dados da busca da string “Respiration rate analysis AND emotion”.....	36
Fluxograma 5 - Dados da busca da string “electromyography AND emotion”.....	37
Fluxograma 6 - Dados da busca da string “electroencephalogram AND emotion”...	38
Fluxograma 7 - Dados da busca da string "Galvanic Skin response AND emotion”.....	39

LISTA DE ABREVIATURAS E SIGLAS

AAPB - Association for Applied Psychophysiology and Biofeedback

ABPMC - Associação Brasileira de Psicoterapia e Medicina Comportamental

ANN - *Artificial Neural Networks of backpropagation*

ASR - *Method Artefact Subspace Reconstruction*

BCIA- Biofeedback Certification Institute of America

BFE- Biofeedback Foundation of Europe

BPNN - *Neural network of propagation of return*

BVP - Pulso de volume sanguíneo

CASE - Anotações contínuas

CNN - *Convolutional Neural Network*

CNN - Rede neural celular

CPM - *Component Process Model (CPM)*

DAQ - Dispositivo de aquisição de dados

DB4 - *Daubechies 4*

DNN - Rede neural profunda

DWT - *Discrete wavelet transform*

ECG- Eletrocardiograma

EDA - Atividade eletrodérmica

EEG- Eletroencefalograma

EFH- Engenharia de Fatores Humanos

EMD - *Empirical mode decomposition technique (EMD)*

EMG- Eletromiografia

ENN - *Elman neural network classifier*

FBTC- Associação Brasileira de Psicoterapia e Medicina Comportamental da Federação Brasileira de Terapias Cognitivas

GDA - *Generalized discriminant analysis*

GHSOM - *Growing hierarchical self-organizing maps*

HHT - *Transformed Hilbert- Huang*

HR - Frequência cardíaca

HRV - *Heart rate variability*

HS - *Hilbert spectrum*

IAPS - *International Affective Picture System*

IBI - Intervalo entre batidas IBI

ICA - *Independent Component Analysis*

ICA - *Independent component analysis*

IEMG - *Integrated EMG*

IHC- Interação Humano Computador

IHS- Interação Humano Sistema

ISNR- International Society for Neurofeedback and Research

KNN - Algoritmo k-vizinho mais próximo.

LDA - Análise Discriminante Linear

LDA - *Linear Discriminant Analysis*

LOOCV - *Leave-one-out*

LS-SVM - *Square Support Vector Machine*

LSTM - *Rede de Long Short-Term Memory*

LVQ - *Learning Vector Quantization*

MAV - *Mean absolute value*

MFCC - *Mel-Frequency Cepstral Coefficients*

ML - *Machine Learning*

MP - *Algorithm Matching Pursuit (MP)*

NARX - *Nonlinear autoregressive exogenous network*

NCA - *Neighborhood component analysis method*

OFFSET - *Média da série de amplitude*

QDA - *Análise Discriminante Quadrática*

QFFT - *Quick Fast Fourier Transform*

RBF - *Função de base radial*

RF - *Random forest*

RMS - *Root mean square*

RNN - *Recurrent Neural Network*

ROIs - *Regions of interest*

SAM - *Auto avaliação manequim*

SLOPE - *Inclinação média da série de valores de amplitude*

SMO - *Algorithm Sequential Minimal Optimization (SMO)*

SNA- Sistema Nervoso Autônomo

SNC- Sistema Nervoso Central

SNE- Sistema Neuroendócrino

SOMs - *Self-Organizing Maps*

STD - Desvio padrão da série de valores de amplitude

STFT - Short-time Fourier transform

S-Tree - Árvore de Decisão Simples

SVDE - Singular entropia de decomposição de valor

VAS-A - *Visual Analogue Scale for Anxiety*

WT - *Wavelet transforms*

SUMÁRIO

1	INTRODUÇÃO	17
2	OBJETIVO GERAL.....	20
2.1	Objetivos específicos.....	20
3	FUNDAMENTAÇÃO TEÓRICA.....	21
3.1	Usabilidade	21
3.2	Emoções	24
3.3	IHC e emoções.....	25
3.4	Conceito de <i>biofeedback</i>	27
3.4.1	<i>Histórico de biofeedback</i>	28
3.4.2	<i>Treinamento do emocional com biofeedback</i>	29
4	METODOLOGIA DA PESQUISA.....	31
4.1	Caracterização Geral da Pesquisa	31
4.2	Etapas da pesquisa	31
4.2.1	<i>Critério de Inclusão</i>	31
4.2.2	<i>Critério de Exclusão</i>	32
4.3	Levantamento de dados	32
5.0	RESULTADOS E DISCUSSÕES	41
5.1	Equipamentos em geral de <i>biofeedback</i> para identificação do emocional.....	41
5.2	Eletrocardiograma.....	62
5.2.1	<i>Trabalhos envolvendo Eletrocardiograma</i>	69
5.3	Termografia.....	83
5.3.1	<i>Trabalhos relacionados à termografia</i>	87
5.4	Taxa de respiração (RR)	93
5.4.1	<i>Trabalhos relacionados à RR</i>	95
5.5	Eletromiografia	97
5.5.1	<i>Trabalhos relacionados à Eletromiografia</i>	101
5.6	Eletroencefalograma.....	107
5.6.1	<i>Trabalhos relacionados à eletroencefalograma</i>	112
5.7	GSR.....	118
5.7.1	<i>Trabalhos relacionados ao GSR</i>	121
6	CONCLUSÃO	127

7	ESTUDOS FUTUROS	128
	REFERÊNCIAS.....	129

1 INTRODUÇÃO

A Interação Humano Computador (IHC) é uma área responsável pela criação de projetos, desenvolvimento de interfaces e avaliação de sistemas. Dentro da IHC, se insere a usabilidade que é definida pela *Internacional Organization for Standardization* (ISO 9241-11:1998) como uma medida para melhorar a facilidade de utilização de um *software* durante o processo de uso, visando alcançar objetivos específicos como: eficácia, eficiência e satisfação (NIELSEN, 2003).

Nesse contexto, a usabilidade tem relação com a percepção dos usuários durante sua interação com um sistema, sendo utilizada para determinar se o manuseio de um produto é aprendido de forma fácil e rápida, sem erros operacionais e de difícil esquecimento, garantindo assim satisfação do usuário e eficácia nas tarefas para o qual foi projetado (FERREIRA, LEITE, 2003).

Dessa forma, quando os usuários enfrentam dificuldades na realização das tarefas, significa dizer que a interface pode estar apresentando problemas de usabilidade, que levam a redução da produtividade, abandono do sistema e perda de dados (WINCKLER, PIMENTA, 2002).

Uma alternativa para reduzir e/ou eliminar estas dificuldades é utilizar avaliações de usabilidade, visando identificar os possíveis problemas dos produtos. Através dessas avaliações é possível garantir benefícios como funcionalidades mais adequadas ao usuário; interfaces mais intuitivas ao usuário, desempenho do produto mais compatível com as expectativas/necessidades do usuário. Desta forma, pode-se levar a: redução dos erros de uso do sistema, menor necessidade de treinamento para aprendizagem da ferramenta, apoio no uso para indivíduos que apresentem necessidades especiais e tenham poucas aptidões com o uso de tecnologias (MARTINS *et al*; 2012).

Por outro lado, com o avanço tecnológico, os produtos, interfaces e até mesmo os usuários passaram a ser um desafio para a área de IHC. Considerando-se que existem diversos perfis de usuários, com distintas formas de interação e podendo ser em múltiplos contextos de uso, pode-se considerar que não se deve restringir mais apenas a Interface Homem Computador (IHC), podendo também ser chamada de Interface Homem Sistema (IHS). Esta nova perspectiva exige atenção quanto ao contexto de uso, quanto à tarefa a ser executada e quanto as características do usuário. Em particular neste último ponto, deve-se ter uma

atenção especial para os fatores humanos (GONCALVES, NERIS, UEYAMA, 2011; CAMPBELL, CHOUDHURY, 2012; GONCALVES *et al*; 2013; SCHERER, 2000).

Dessa forma, para otimizar o bem estar humano e desempenho geral do sistema, existe uma disciplina científica voltada à compreensão das interações entre seres humanos e outros elementos de um sistema, de maneira que haja elementos de sistema como aplicação de princípios, dados e outros métodos para o design de interfaces de usuário, conhecida como fatores humanos (AAMI, 2010).

Sendo assim, dentro dos fatores humanos podem-se destacar as emoções, que apresentam relação com a tomada de decisões, devido a sua relação com as experiências vividas pelos indivíduos, no âmbito pessoal e na interação com os sistemas, sendo fundamental para o entendimento do comportamento emocional de um usuário de acordo com a situação que ele possa estar exposto (SCHERER; CESCHI, 2000).

Assim, dentro do contexto da avaliação de IHS, é necessário identificar os estados emocionais dos usuários para entender o impacto que as emoções geram na operação dos sistemas pelos usuários (GONÇALVES *et al*; 2015; RODRIGUES *et al*; 2015; GONÇALVES *et al*; 2016).

Portanto, é necessário definir abordagens consistentes de análise dessas respostas emocionais, visto que dentro do ambiente de usabilidade o emocional do usuário, normalmente, é identificado apenas por observação. Isto pode levar a um resultado não fidedigno, devido às diversas conclusões que se podem chegar apenas observando como o indivíduo atua diante de uma tarefa. Por esse motivo, o aprofundamento no estudo dos sinais biológicos e como eles atuam através da captação por sensores são necessários na identificação do comportamento emocional. (GONÇALVES *et al*; 2016).

Uma alternativa para esse mapeamento pode ser o uso de sistemas de *biofeedback*, que são procedimentos terapêuticos onde se utilizam instrumentos eletrônicos ou eletromecânicos através de sensores que coletam sinais fisiológicos do corpo, sendo processados e seguindo para um *software* que realiza o tratamento dos dados, disponibilizando as informações em um *display* (LANTYER, 2013).

Ribeiro (2012) descreve que existem tipos de *biofeedback* capazes de mensurar, através de sensores, alguns sinais biológicos, tais como: frequência cardíaca, pressão arterial, frequência respiratória, frequência de ondas cerebrais, temperatura e condutância da pele.

Portanto, diante do exposto, é notório observar que a satisfação de profissionais, pacientes e agentes responsáveis pela operação de procedimentos médico hospitalar é um tema bastante relevante e variável, visto que existe um aumento da quantidade de dispositivos, tipologias de parâmetros e sua variedade de uso e interfaces.

Dessa forma, para identificar a satisfação dos usuários, são utilizadas avaliações, que podem ser realizadas a partir de duas metodologias distintas, a primeira considerando como premissa uma referência observacional levando em consideração a posição subjetiva do avaliador e, portanto, seu parecer de acordo com a observação deste, sob o comportamento humano do indivíduo a ser avaliado e a segunda fazendo referência ao mapeamento eletrônico do comportamento humano, possibilitando uma análise sistemática destes comportamentos.

Atualmente estes comportamentos têm sido algo discutido mais frequentemente, haja vista que, a satisfação do operador do sistema pode afetar na saúde de outros indivíduos, colocar em risco o procedimento a ser realizado e conseqüentemente a integridade do paciente (SOUZA, 2019). Deste modo, faz-se necessário uma aplicação correta na avaliação da satisfação do usuário de sistemas eletromédicos de qualquer natureza.

A análise a partir de parâmetros eletrônicos tem objetivo de validar, através de sensores, reações fisiológicas em seres humanos e com isso, identificar a iminência de parâmetros que traduzem diversos sentimentos diferentes, tais como o estresse, insatisfação, irritação e falta de interesse com o sistema em questão. A partir da análise fisiológica do comportamento humano, é possível desenvolver um modelo de referência para consultas, e assim mapear e analisar a satisfação do indivíduo na compreensão, operação e manutenção destes equipamentos.

Diante do exposto, se pode questionar: quais são os equipamentos de *biofeedback* que mensuram sinais fisiológicos para identificar o emocional, e se esses dispositivos podem auxiliar na avaliação do comportamento emocional do usuário dentro de um ambiente de usabilidade.

2 OBJETIVO GERAL

Investigar quais os dispositivos de *biofeedback* que mensuram sinais fisiológicos que são utilizados para identificar o estado emocional. E se esses dispositivos podem ser utilizados para avaliar o comportamento emocional dos usuários dentro de um ambiente de usabilidade.

2.1 Objetivos específicos

- ✓ Descrever quais os tipos de sensores que são utilizados para capturar sinais fisiológicos do usuário.
- ✓ Apresentar quais os pontos anatômicos de aplicação dos sensores fisiológicos nesse contexto.
- ✓ Identificar quais são os algoritmos e banco de dados utilizados no processamento dos dados emitidos pelos equipamentos.

3 FUNDAMENTAÇÃO TEÓRICA

A fundamentação teórica foi estruturada em quatro tópicos: usabilidade, emoções, IHC e emoções, conceito de *biofeedback* e dois subtópicos: histórico do *biofeedback* e treinamento do emocional com *biofeedback*.

3.1 Usabilidade

A Interação Humano-Computador (IHC) surgiu em meados dos anos 80, visando implementar sistemas computacionais, bem como avaliar e projetar *designs* adequados para o uso humano (HEWETT et al., 1992).

Portanto, para um melhor entendimento de IHC, é necessário explicar dois conceitos fundamentais: a interação e a interface, que respectivamente pode ser considerada como “a comunicação entre o sistema e o usuário” e “o recurso que torna possível a comunicação entre o usuário e o sistema, garantindo assim suas ações e resultados desejados” (PREECE, 2005).

Desse modo, dentro da IHC existe a usabilidade que é definida segundo a norma ISO 9241:11 (ABNT NBR 9241:11, 2011), como sendo uma exigência na qual o usuário deve desempenhar determinadas tarefas com eficiência, eficácia e satisfação em um determinado contexto de uso. A eficiência pode ser entendida como a capacidade de um indivíduo realizar uma tarefa com rendimento e com um mínimo de erros, enquanto a eficácia é a qualidade de se atingir determinados objetivos e a satisfação está relacionada ao prazer de utilizar determinada ferramenta (FROKJAER et al., 2010).

A Engenharia de Usabilidade também pode ser definida segundo a norma ABNT NBR IEC 62366:2016 como:

“Engenharia da Usabilidade (EU) é a aplicação dos conhecimentos sobre o comportamento humano, habilidades, limitações e outras características humanas relacionadas ao projeto de ferramentas, produtos, sistemas, tarefas, trabalho e ambientes para atingir USABILIDADE adequada.” (ABNT, 2016).

Assim, o termo Engenharia da Usabilidade conforme a norma ABNT NBR IEC 62366:2016, também se deriva da Engenharia de Fatores Humanos (EFH), podendo ser definido como *Design* Centrado no Usuário (GOMES FILHO, 2012).

Dessa forma, fatores ambientais, técnicos, organizacionais, físicos e de características do usuário, são pontos determinantes para o desenvolvimento de um sistema com usabilidade e não apenas as características do produto isoladamente (THOMAS, BEVAN, 1996).

Portanto, Shackel *et al* (1991), afirma que é importante realizar avaliações de usabilidade, pois os produtos podem apresentar problemas de usabilidade durante a interação do usuário com o sistema, o que leva a perda de tempo durante a execução da tarefa, comprometendo a mesma ou tornando ela inviável. Assim, as avaliações são maneiras de minimizar esses eventos.

Dessa forma, Prates *et al* (2007) afirma que elas são realizadas de acordo com modelos, sendo nomeadas como: avaliações analíticas e testes de usabilidade com usuários representativos. Dentro das avaliações analíticas estão as heurísticas, que são caracterizadas como princípios ou regras que permitem investigar quais os possíveis problemas de usabilidade. Nielsen (1994), afirma que dentro da Engenharia da Usabilidade, as heurísticas são técnicas utilizadas no processo de design interativo, para identificar problemas de interface dos sistemas, tendo como base conhecimentos computacionais, sociológicos e psicológicos do problema.

Por outro lado, existem os testes de usabilidade que avaliam como uma tecnologia, dispositivo ou processos funcionam. São realizados com usuários representativos em um contexto real ou em um ambiente simulado, visando avaliar de que forma os usuários interagem com o sistema (AAMI, 2009., ABNT, 2010).

Segundo Martin *et al* (2008), a aplicação do teste pode ser realizada desde o período de criação do produto até a fase de validação antes da comercialização, podendo ser realizados ainda em fase de prototipagem. Dessa forma, para um teste eficaz é necessário:

- ✓ Usuários representativos (usuários reais, executando tarefas reais).
- ✓ Amostra contendo de 5 a 8 participantes em testes de fases iniciais (formativo) e 15-25 para testes de validação (somativo).
- ✓ Lista de tarefas para o usuário realizar de acordo com o cenário.
- ✓ Protótipo, produto real ou interface simulada.
- ✓ Medidas de desempenho.

Assim, os testes de usabilidade se diferenciam de acordo com a etapa de desenvolvimento do produto, sendo eles: testes formativos e somativos. Os formativos são realizados no processo inicial de desenvolvimento, se aplicam a interfaces simuladas e protótipos, tendo como objetivos a extração de informações dos usuários, bem como a identificação de uma boa usabilidade (AAMI, 2009).

Testes formativos podem ser ainda classificados em:

- Exploratórios: o teste é realizado com usuários na fase inicial do processo de desenvolvimento (já a partir do período de concepção). Executa-se a partir dos usuários desempenhando tarefas macros e manuseando produtos em simulação de baixa fidelidade (exemplo: um protótipo ou esboço de tela).
- Comparativos: Esses testes podem ser utilizados como levantamento de requisitos de um projeto, visando comparar mais de uma alternativa para um design de interface de um produto que está em desenvolvimento e que apresentem funções similares com os concorrentes.
- Avaliativos: São realizadas atividades reais em protótipos funcionais ou em simuladores, testados com usuários reais visando a verificação da usabilidade para aquele produto planejado.

Os testes também podem ser somativos, ou seja, são realizados ao final da etapa de desenvolvimento do produto como forma de validar se a interface atende aos critérios de usabilidade. São executados em ambientes simulados ao ambiente real para que seja mantida uma alta fidelidade ao indivíduo no momento da realização das tarefas. Apresentam como objetivo a garantia de que o produto apresenta eficiência, eficácia e satisfação no contexto da usabilidade (AAMI, 2009).

Diante desse contexto, avaliar as emoções e satisfação dos usuários durante a interação com os sistemas pode garantir que os objetivos e expectativas dos usuários sejam satisfeitas. Esta análise pode ajudar a fornecer melhorias para evoluir sistemas, definir interfaces mais flexíveis e até mesmo propor novas funcionalidades (TULLIS., ALBERT, 2013).

3.2 Emoções

A emoção é um processo em que o corpo responde a estímulos externos ou internos, desencadeando eventos fisiológicos específicos, ativando o sistema autônomo simpático e parassimpático, os aspectos comportamentais e cognitivos de controle do organismo (SACHARIN, SCHLEGEL, SCHERER, 2012).

Segundo Pinto (2001), a emoção é considerada uma vivência subjetiva de relação: mente, organismo e corpo; que ocorre devido a um pensamento ou estímulo e repercutem em eventos fisiológicos, motores e cognitivos. Damásio (2003), afirma que as emoções são formas naturais de adaptação a determinadas reações, bem como de avaliação do ambiente em que se está inserido.

Diante disso, Scherer (2005) afirma que existem diferenças entre os termos **episódio emocional** e **estado emocional**. O episódio emocional tem ligação com a recordação de uma experiência quando o indivíduo passa por algum questionamento (exemplo: um sentimento de medo, ansiedade, alegria diante de alguma situação vivenciada).

Enquanto o estado emocional, se refere ao conjunto dos componentes da emoção em um determinado momento (SCHERER, 2005). Esses componentes podem ser classificados como: reações fisiológicas, expressões motoras, tendências comportamentais e avaliações cognitivas que são conhecidas como Teoria Componential das Emoções (ELLSWORTH., SCHERER, 2003., NIEDENTHAL., KRAUTH-GRUBER., RIC, 2006., SCHERER, 2005).

Dessa maneira, as reações fisiológicas podem ser conhecidas através de outros termos, tais como: ativação fisiológica (LAURANS., DESMET., HEKKERT, 2009), reação neurofisiológicas (HAYASHI., BARANAUSKAS, 2011) e mudanças psicofisiológicas (FONTAINE *et al.*, 2007).

Assim, através das emoções o indivíduo é capaz de manifestar de forma espontânea e inconsciente o que ocorre internamente, ou seja, atua no Sistema Nervoso Central (SNC), que recebe dados dos cinco sentidos e envia ao Sistema Motor; ao Sistema Nervoso Autônomo (SNA) que é responsável pelo controle da circulação, respiração, digestão entre outros; e também para o Sistema Neuroendócrino (SNE) (STEMMLER, 2003., SCHERER, 2005., MAHLKE., MINGE, 2008)

As expressões motoras podem também ser chamadas de reações expressivas, tendo relação com as características da fala, tal como o som, intensidade, melodia e velocidade. Assim, diante de uma experiência emocional vivenciada pelo usuário, suas expressões de face, gesto e voz podem sofrer alterações (MAHLKE., MINGE, 2008., SCHERER, 2005., LANG et al., 1993., LEVENTHAL, 1984).

As tendências comportamentais tornam o organismo preparado e orientado para agir diante de determinadas situações, garantindo direcionamento e energia no controle emocional quando o indivíduo realiza determinadas tarefas que necessitam de adaptação (FONTAINE et al., 2002., EKMAN; FRIESEN, 1969., FONTAINE et al., 2002., MAHLKE; MINGE, 2008).

Já as Avaliações Cognitivas, estão relacionadas a percepção e interpretação das situações em que o indivíduo se insere, em que ele avalia recursos, objetos e eventos; por meio de informações sensoriais, cognitivas e perceptivas (FONTAINE et al., 2002).

Dessa forma, Picard (1995) afirma que estudiosos da neurociência identificaram algumas regiões do cérebro e suas respectivas funções, sendo elas o córtex cerebral que tem como função a tomada de decisão e o sistema límbico ligado às emoções, atenção e memória. Assim, Cristescu (2008) elucida que esses sistemas estão interligados e se influenciam, sendo as emoções componentes essenciais para conhecer e explicar o comportamento humano.

De acordo com Beale e Peter (2008) e Norman (2004) o estado emocional pode afetar na tomada de decisão do indivíduo, bem como em sua memória, percepção e atenção. Assim, a interface de um produto pode influenciar na percepção da qualidade e da experiência do produto.

3.3 IHC e emoções

Diante do supracitado, Cristescu (2008) discorre que as pesquisas relacionadas às emoções e a IHC têm crescido, devido à necessidade de reconhecer o emocional do usuário através de sistemas inteligentes, durante o processo de interação com as ferramentas de uso, bem como explicar de que forma as emoções interferem nessa experiência. Possibilitando assim a criação e aperfeiçoamento de interfaces de fácil utilização e entendimento.

Norman (2004), afirma que as emoções estão presentes em todas as relações humanas, e que através delas é possível detectar se um ambiente apresenta perigo ou segurança. Podendo assim, afetar diretamente nas tomadas de decisões dos indivíduos, na sua atenção, percepção, memória, aprendizagem e nos seus comportamentos (BEALE., PETER, 2008).

De acordo com Desmet *et al* (2003, p. 112), a descoberta das emoções pode dar uma contribuição na compreensão da qualidade de um determinado produto, podendo assim encontrar soluções que sejam mais desejáveis e atrativas de utilização. Essa necessidade ocorre, pois, existem poucas informações a respeito de como as reações emocionais são ativadas diante da interação do usuário com o produto.

Sabendo disso, Moritz, Meinel (2010) e Hoppmann (2009) afirmam que a percepção de emoções positivas pode estar ligada a interfaces agradáveis e desejáveis, enquanto as emoções negativas podem ter referência a erros, problemas de execução e interfaces de difícil utilização. Isso ocorre através da avaliação de um produto, de uma situação ou objeto que podem apresentar benefícios ou malefícios ao organismo (DESMET; HEKKERT, 2007).

Dessa forma, identificações do estado cognitivo de seres humanos em tempo real estão sendo utilizadas por empresas e pesquisadores para determinar, por exemplo, se um motorista está distraído ou engajado na tarefa de dirigir, se ele apresenta dificuldades na execução da tarefa ou realiza com facilidade, se apresenta sinais de nervosismo, ansiedade ou estresse (BANICH., COMPTON, 2018).

Dessa forma, atualmente existem tecnologias que são capazes de analisar o comportamento humano do ponto de vista físico e fisiológico, identificando o estado cognitivo em tempo real de um indivíduo, por meio de recursos da ciência da computação, engenharia e neurociência (TULLIS., ALBERT, 2013., BANICH., COMPTON, 2018).

Assim, essas tecnologias podem ser utilizadas para capturar e identificar sinais bioelétricos e biométricos, podendo auxiliar os profissionais responsáveis na criação de um produto a compreender o estado cognitivo do usuário, visando prevenção de erros e aprimoramento dos sistemas (TRUMBO *et al.*, 2016). Dentre esses recursos de identificação do estado emocional, se insere o *biofeedback*.

3.4 Conceito de *biofeedback*

Em meados de 1969, o termo *biofeedback* foi descrito por estudiosos da Califórnia após a criação da *Biofeedback Reseach Society*. Etimologicamente, *biofeedback* representa a junção de três palavras: *bio* (vida), *feed* (alimentar), *back* (retorno/volta). Sendo assim, sua tradução literal tem o significado de bioretroalimentação. Podendo ser entendido como a captura de um sinal fisiológico, representado em forma de *feedback* (DANUCALOV, 2010).

Segundo Basmajian (1989) e Schwartz (1995) o domínio das funções fisiológicas, nas quais não se tem controle voluntário, pode ser aprendido através de técnicas de *biofeedback*. Assim, é possível que através do treinamento o indivíduo consiga comandar a interação entre o corpo e a mente, modificando comportamentos e otimizando funções corporais, sendo capaz de se autorregular.

Essas informações são potencializadas através de equipamentos eletrônicos e eletromecânicos em tempo real, sendo capturadas, processadas e interpretadas por meio de *hardwares* e *softwares* e fornecidas ao usuário por meio de interfaces gráficas e auditivas. Apresentando como finalidade, a recuperação, manutenção e melhora da saúde; estimulando um processo de neuroplasticidade cerebral que causam efeitos a longo prazo (CASTELNUOVO *et al.*, 2016., STREHL *et al.*, 2014., GRAZZI, 2007).

Fuller (1977), afirma que o *biofeedback* atua como um rádio, emitindo apenas a informação e não realizando o controle sobre os sistemas fisiológicos, pois essa tarefa é realizada pelo usuário através da visualização do que está acontecendo internamente.

Sabendo disso, Ribeiro (2012) afirma que existem vários tipos de equipamentos de *biofeedback*, eles apresentam sensores responsáveis por detectar sinais fisiológicos como pressão arterial, frequência cardíaca, frequência respiratória, tensão muscular, temperatura, condutância da pele e atividade cerebral. Após detecção desses sinais eles são disponibilizados de forma gráfica ou sonora, ou seja, o usuário pode interagir com imagens ou jogos em monitores e/ou escutar sons de acordo com o ritmo e a variação de frequência que ele apresenta.

Assim sendo, a terapia com *biofeedback* apresenta como principal objetivo a autorregulação psicofisiológica que se caracterizam como a capacidade do indivíduo regular as funções fisiológicas internas. Esse processo é possível devido a relação

que a mente e o corpo apresentam, visto que o cérebro coordena as respostas fisiológicas do organismo (YUCHA, GILBERT, 2004).

Portanto, o uso de equipamentos da terapêutica com *biofeedback* é um tratamento não farmacológico que auxilia o indivíduo a ter controle dos processos psicofisiológicos e mentais maximizando o funcionamento do organismo, desenvolvendo confiança, consciência, além de auxiliar o terapeuta no tratamento, pois através do fornecimento das informações é possível identificar a presença de estresse, ansiedade, falta de concentração, tensão muscular, pela combinação de sinais fisiológicos (NOVELLETTO *et al.*, 2016).

3.4.1 Histórico do biofeedback

Antes do advento do biofeedback, as funções biológicas do Sistema Nervoso Autônomo (SNA) eram entendidas como um processo involuntário, inconsciente e com processos de autorregulação imutáveis (BASMAJIAN, 1989., BASFORD, 1992., LATASH., NICHOLAS, 1996). Foi a partir desse pensamento que Miller e Bunuazizi (1969), começaram a manifestar seus posicionamentos a respeito da manipulação das funções biológicas do SNA. Eles acreditavam que a partir da aprendizagem instrumental, onde houvesse um indicador que apresentasse o estado das funções do SNA, o indivíduo poderia ter consciência desses processos, conseguindo assim condicioná-los como é feito no sistema nervoso somático.

Dessa forma, Miller (1969) teve um papel importante na descoberta do *biofeedback*, quando publicou na revista *Science* a respeito de “*Learning of visceral and glandular responses*”, que também pode ser entendido como “Aprendizagem de respostas viscerais e glandulares”, o mesmo mostrou que as funções do sistema nervoso autônomo poderiam ser aprendidas e controladas, como por exemplo o controle da pressão arterial, através dessas descobertas o biofeedback passou a ser um recurso utilizado na prática clínica (BASMAJIAN, 1989., BASFORD, 1992., LATASH., NICHOLAS, 1996).

Além disso, Miller (1987) através de experimentos com animais evidenciou que eles conseguiam condicionar a salivação, controlando seu aumento ou diminuição. Dessa forma, a partir da experimentação em laboratórios foi possível o desenvolvimento de diversas pesquisas na área de psicofisiologia aplicada juntamente com o biofeedback. Dentre elas estão: o estudo de *neurofeedback* de

Joe Kamiya; O padrão de atividade eletrodérmica de pacientes esquizofrênicos de Quirk e Von Hilsheimer; A frequência cerebral sensório-motora de pilotos de aviões de guerra por Stermán, que foram importantes para tratamentos de déficit de atenção e hiperatividade (TDAH), distúrbios de sono e epilepsia (GREEN, SHELLENBERGER, 2001).

O Penniston utilizou as descobertas de Joe Kamiya para motivar os comportamentos nos tratamentos de dependência química; Brucker utilizou a eletromiografia para restabelecer a função dos membros paralisados em pacientes com lesões nervosas. Perry criou um eletrodo que mensurava a atividade eletromiográfica dos músculos do assoalho pélvico para incontinência fecal e urinária (GREEN, SHELLENBERGER, 2001).

Dessa forma, Basmajian (1989) após estudar o eletromiógrafo (EMG) para identificar a atividade muscular, conceituou o biofeedback como sendo um recurso que garantia aos indivíduos a visualização de processos fisiológicos internos normais e com anormalidades, através de sinais sonoros e visuais explanados por equipamentos, que garantiam ao usuário a capacidade de autorregulação interna, por meio da manipulação desses sinais.

Assim, com o surgimento de novos estudos sobre biofeedback e suas aplicações, foram criadas associações institucionais para fiscalizar e incentivar a utilização desse recurso bem como as novas descobertas a respeito, sendo elas a: *Association for Applied Psychophysiology and Biofeedback (AAPB)*, *Biofeedback Certification Institute of America (BCIA)*, *Biofeedback Foundation of Europe (BFE)* e *International Society for Neurofeedback and Research (ISNR)*. Enquanto no Brasil, o assunto é tratado em congressos da Associação Brasileira de Psicoterapia e Medicina Comportamental (ABPMC), da Federação Brasileira de Terapias Cognitivas (FBTC) e do Congresso Brasileiro de Psicologia: Ciência e Profissão (NEVES NETO, 2006A, 2006B, 2008).

3.4.2 Treinamento do emocional com biofeedback

O biofeedback é um recurso utilizado em ambientes empresariais e educacionais, visando promover relaxamento e controle de estresse, como forma de prevenir doenças. Clinicamente é operado para desenvolvimento de autorregulação, através de treinamento, gerando redução e eliminação de desordens emocionais e

orgânicas, recuperação de funções musculares e diminuição de dores em geral (CRISWELL, 1995., SCHWARTZ, 1995).

Sendo assim, o treinamento acontece mediante o auxílio de equipamentos que emitem sinais visuais e sonoros, como forma de retroalimentação fisiológica, assim o terapeuta ensina ao paciente de que maneira a tarefa deve ser realizada visando alterar o estado atual de acordo com a necessidade desejada para cada tipo de tratamento específico (STRUNGARU, 1991., REDDY., GUPTA, 1999).

Dessa forma, o treinamento segue etapas em que o terapeuta auxilia o paciente, inicialmente é realizada uma avaliação para identificar o problema do indivíduo, que é efetuado através de relatos da vida pessoal, familiar, social e profissional do mesmo, entrevistas, observação pessoal e registros psicofisiológicos bem como a expectativa a respeito do tratamento, traçando assim o protocolo adequado mediante fatores que pode causar melhorias na patologia existente (GAARDER., MONTGOMERY, 1977).

Logo após, o paciente entra no processo de adaptação com a ferramenta, sem realizar registro sobre a atividade, onde será informado sobre o papel do aparelho e a tarefa que deve ser realizada, em seguida é catalogada a primeira experiência de treinamento, para ser utilizada como parâmetro do progresso ao longo do tempo de tratamento (BASMAJIAN, 1979).

Assim, as sessões podem ser realizadas duas a três vezes por semana de acordo com o problema de cada paciente, a finalização ocorre gradativamente, ou seja, é retirado o sinal de biofeedback pouco a pouco, visando a produção de mudanças sem o auxílio de recursos. Dessa forma, o ápice do tratamento será quando o paciente conseguir se autorregular com ou sem equipamento, na clínica ou fora dela (LABRADOR., ENCINAS, 1984).

4 METODOLOGIA DA PESQUISA

Nessa seção será exposta a caracterização geral da pesquisa, etapas da pesquisa, critérios de inclusão, critérios de exclusão e levantamento de dados.

4.1 Caracterização Geral da Pesquisa

Para a realização deste estudo, optou-se pela revisão integrativa da literatura. Trata-se de um método de pesquisa que permite buscar, avaliar criticamente e sintetizar as evidências disponíveis sobre o assunto pesquisado. O produto final é o nível atual de conhecimento do assunto pesquisado e pode identificar lacunas que levem ao desenvolvimento de pesquisas futuras (MENDES, 2008).

4.2 Etapas da pesquisa

A pesquisa seguiu os seguintes passos:

- ✓ Identificação da questão norteadora;
- ✓ Busca na literatura;
- ✓ Coleta dos dados;
- ✓ Análise dos dados obtidos.

Inicialmente para guiar a presente revisão integrativa, elaborou-se a seguinte questão norteadora: quais são os equipamentos de *biofeedback* que mensuram sinais fisiológicos para identificar o emocional, e se esses dispositivos podem auxiliar na avaliação do comportamento emocional do usuário dentro de um ambiente de avaliação de usabilidade.

Após a escolha da questão norteadora, foram traçados os critérios de inclusão e exclusão, sendo eles:

4.2.1 Critério de Inclusão:

- ✓ Artigos publicados em Inglês.
- ✓ Artigos publicados no período de (2015-2020).

- ✓ Artigos que contemplem o escopo de *biofeedback* (sinais fisiológicos) e emoção.

4.2.2 Critério de Exclusão:

- ✓ Artigos que não exibam as palavras-chaves no título, resumo e/ou texto da publicação.
- ✓ Artigos com idioma diferentes do proposto no critério de inclusão.
- ✓ Publicações que constem tutoriais, folhetos de cursos e vídeos.
- ✓ Artigos duplicados.
- ✓ Artigos não encontrados na íntegra por meio da busca.

4.3 Levantamentos de dados

Para o levantamento dos artigos na literatura, realizaram-se as buscas nas seguintes bases de dados: *Pubmed, IEEE Xplore Digital Library, Sciencedirect*. No período de **julho de 2019 a julho de 2020**.

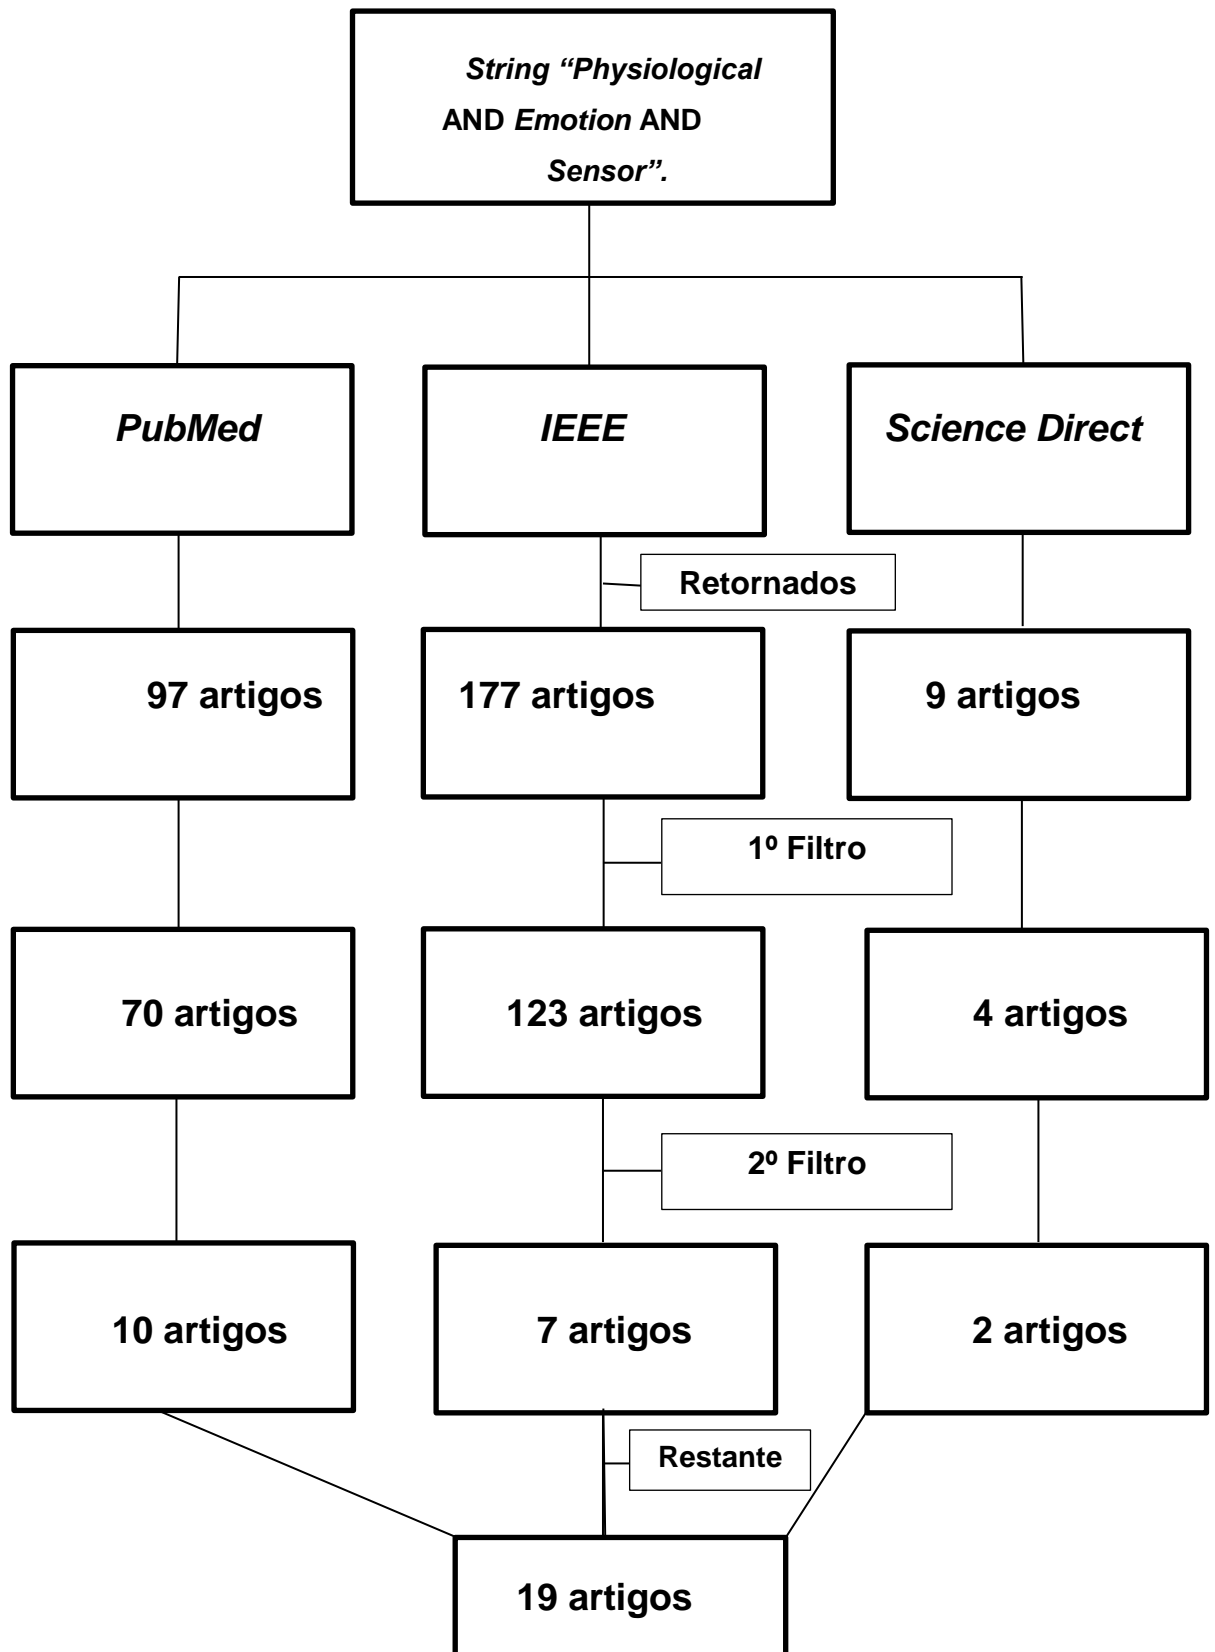
As palavras chaves utilizadas foram: “*physiological signals AND emotion AND sensors*”., “*Electrocardiography AND emotion*”., “ *Thermography AND emotion*”., “*Respiration rate analysis AND emotion*”., “*electromyography AND emotion*”., “*electroencephalogram AND emotion*”.

Dessa forma, a coleta dos dados seguiu alguns passos: inicialmente foram realizadas as leituras dos títulos dos artigos, seguido pela aplicação do 1º filtro (seleção dos artigos que apresentassem as palavras chaves no título e os anos de publicação entre 2015 a 2020).

Assim, após a primeira filtragem, os artigos foram submetidos ao 2º filtro (leitura do resumo e do texto na íntegra), levando em consideração as informações como: conter informações técnicas, que sejam suficientes para demonstrar que o aparelho auxilia na identificação do estado emocional.

A análise e síntese dos dados foram realizadas após tradução e leitura dos artigos. Portanto, nessa pesquisa inicialmente as buscas foram realizadas com uma *string* genérica: “*physiological signals AND emotion AND sensors*”, nas bases de dados citadas anteriormente. E foram obtidos os resultados a seguir:

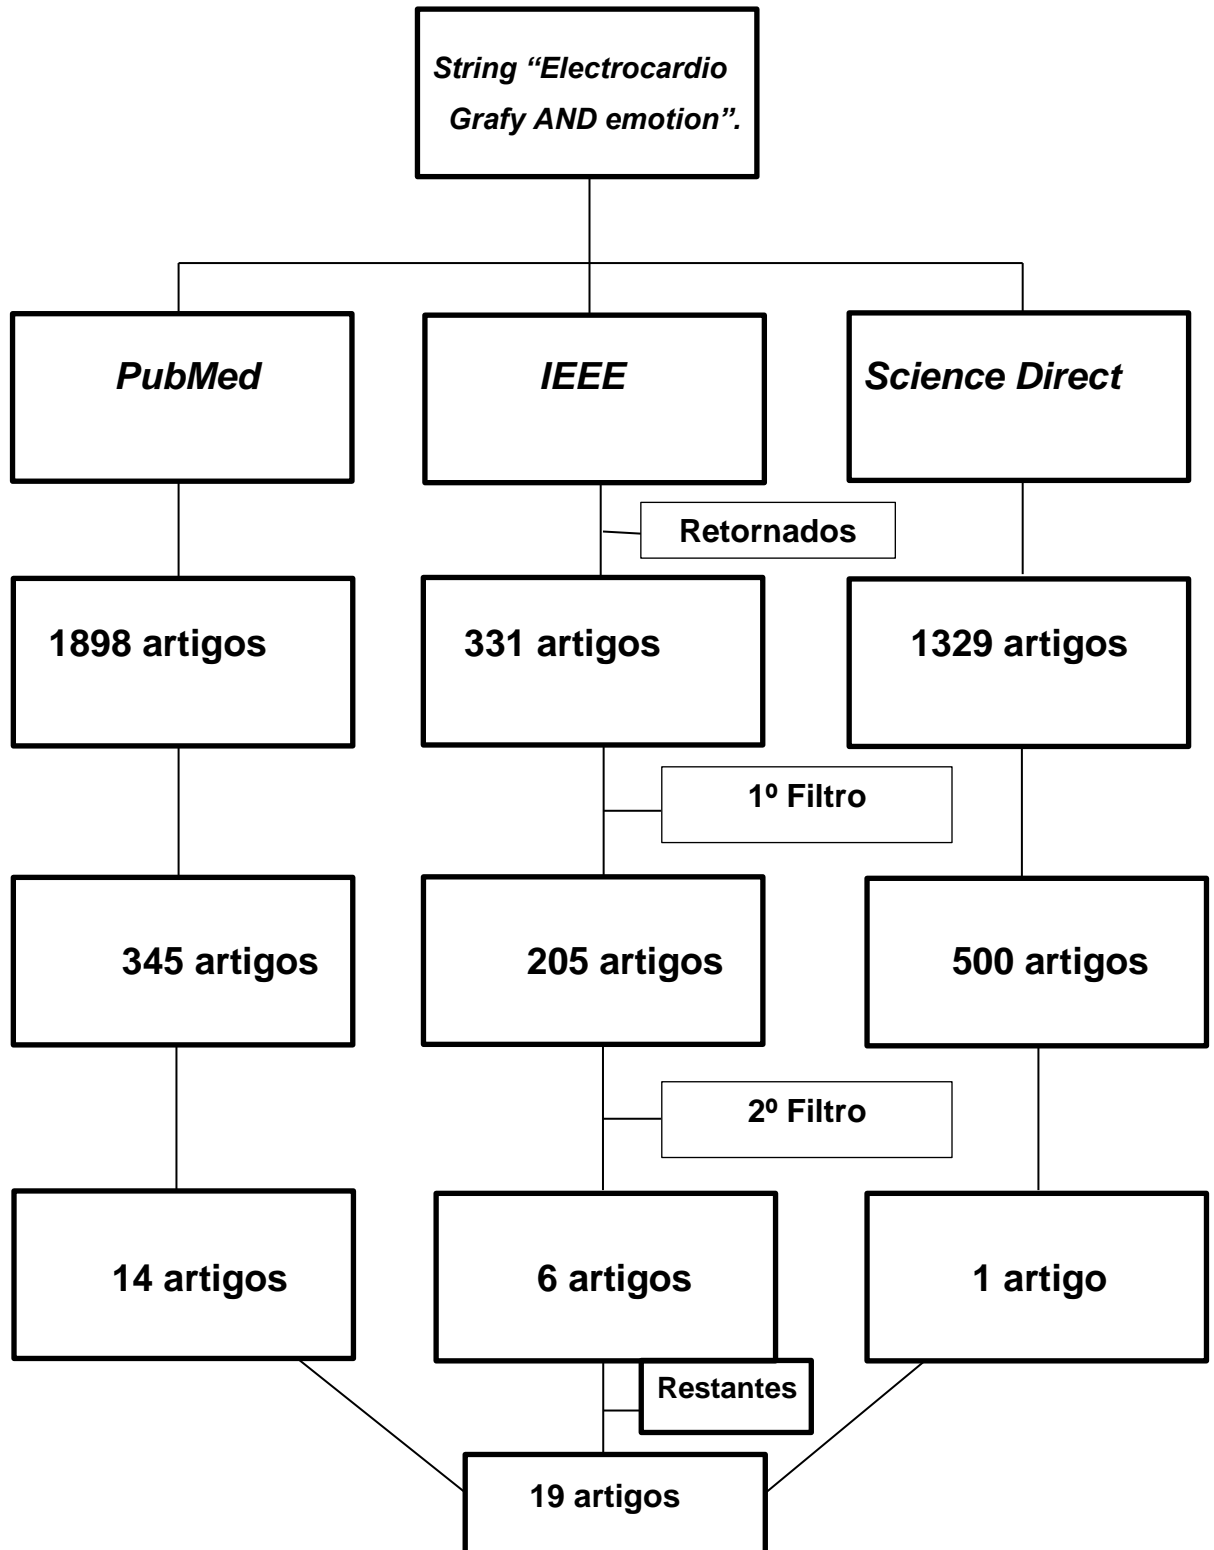
Fluxograma 1 - Dados da busca da *string* “*physiological signals AND emotion AND sensor*”.



Fonte: Dados da pesquisa (2020).

Assim, após a primeira busca restaram 19 artigos. Chegando a conclusão da necessidade de utilizar mais combinações de palavras e novas rodadas, portanto foram realizadas as seguintes buscas:

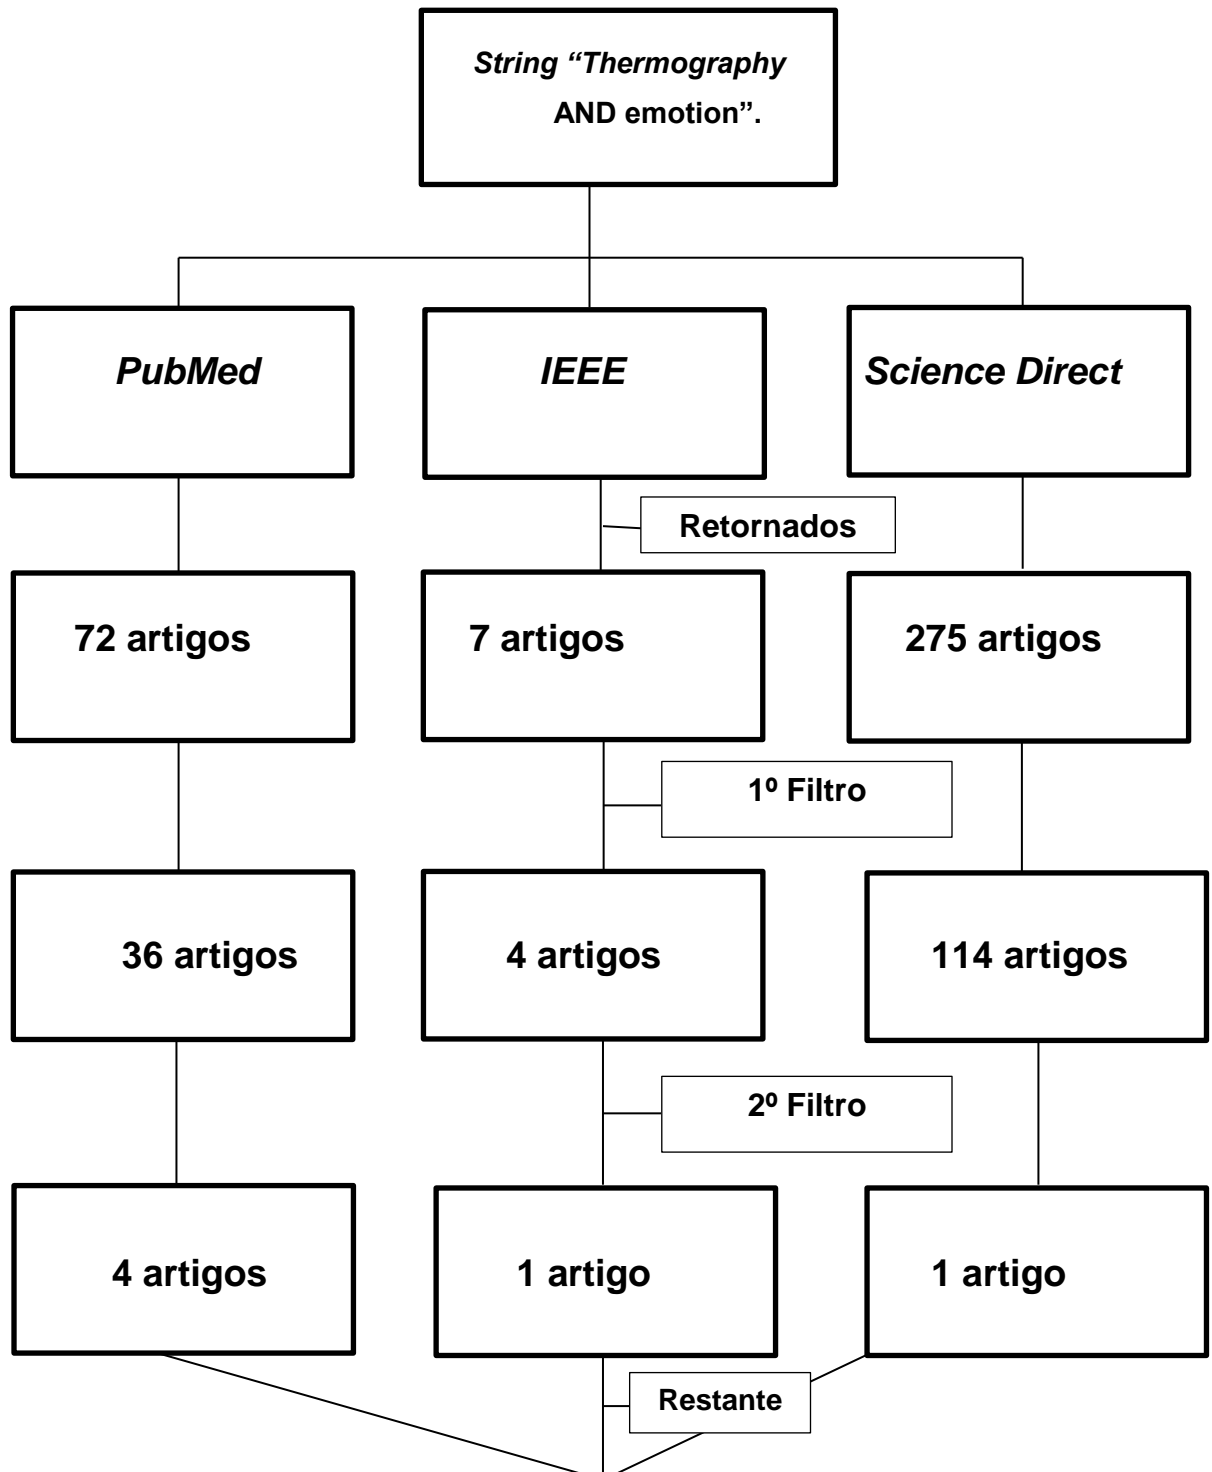
Fluxograma 2 - Dados da busca da string “*Electrocardiography AND emotion*”.



Fonte: Dados da pesquisa (2020).

Apesar de restarem 21 artigos, dois estavam duplicados, portanto sobraram 19 artigos de ECG.

Fluxograma 3 - Dados da busca da string “*Thermography AND emotion*”.

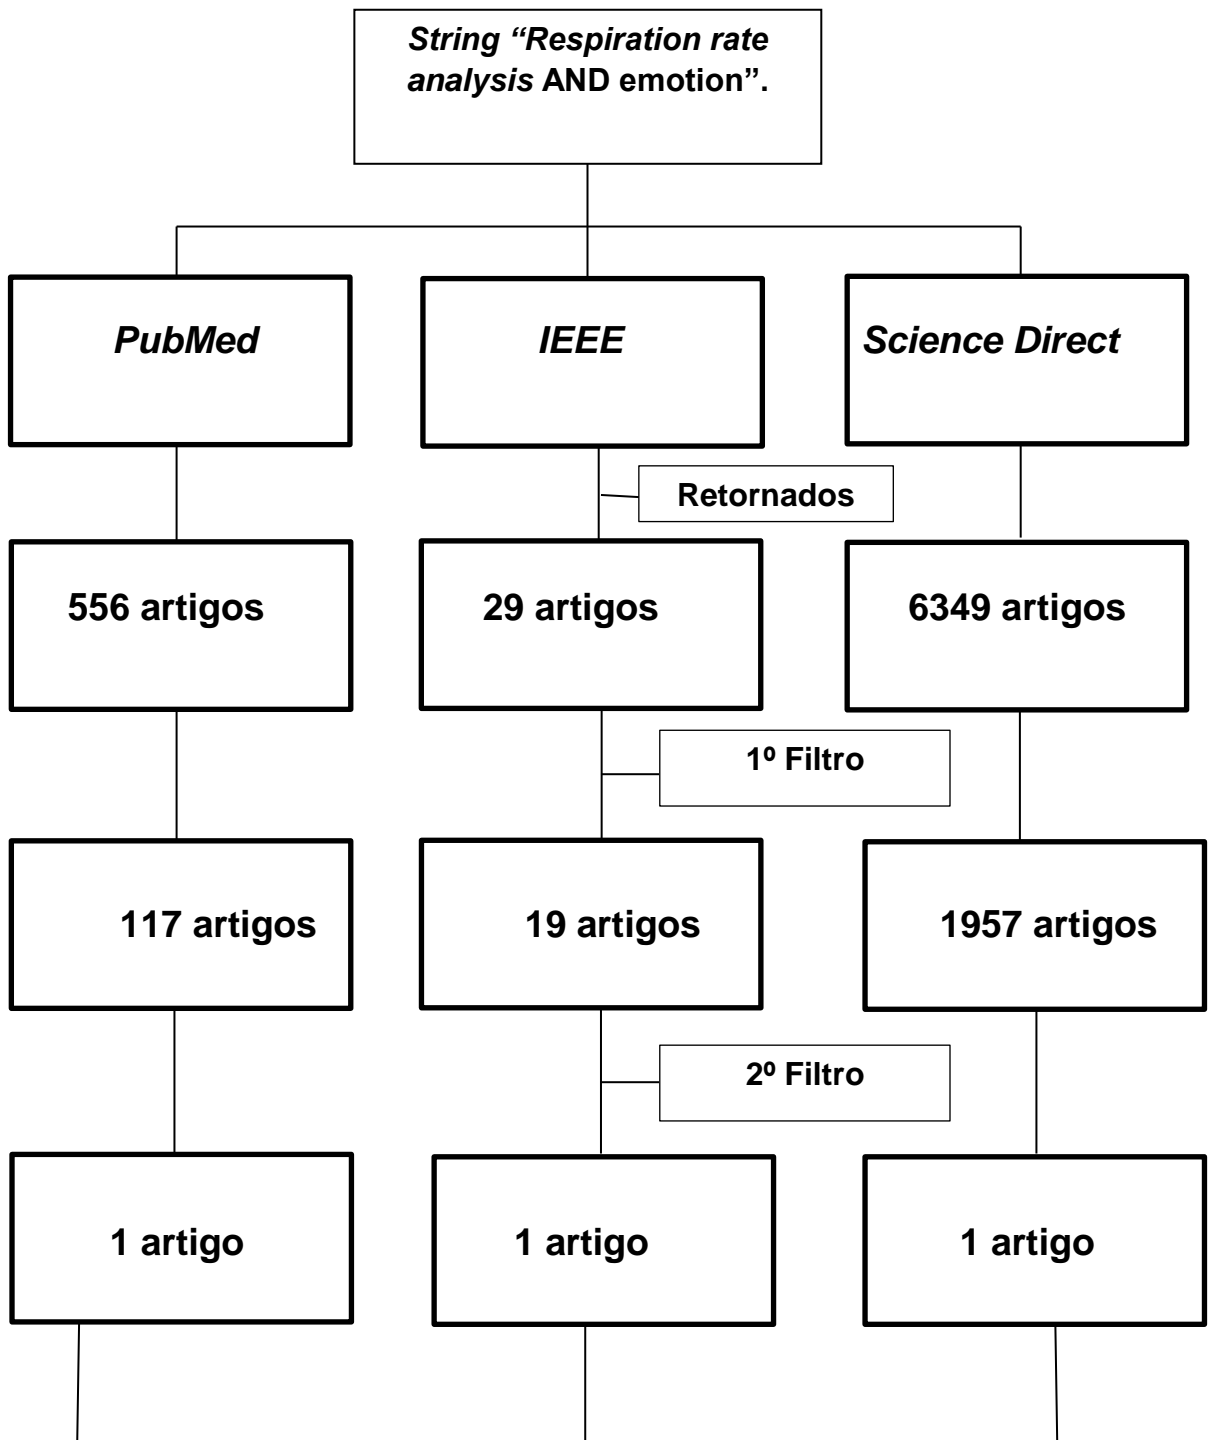


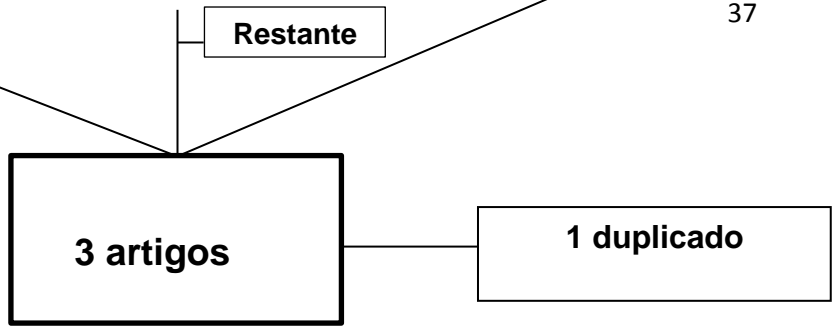


Fonte: Dados da pesquisa (2020).

Restando 6 artigos de termografia.

Fluxograma 4 - Dados da busca da *string* "Respiration rate analysis AND emotion".

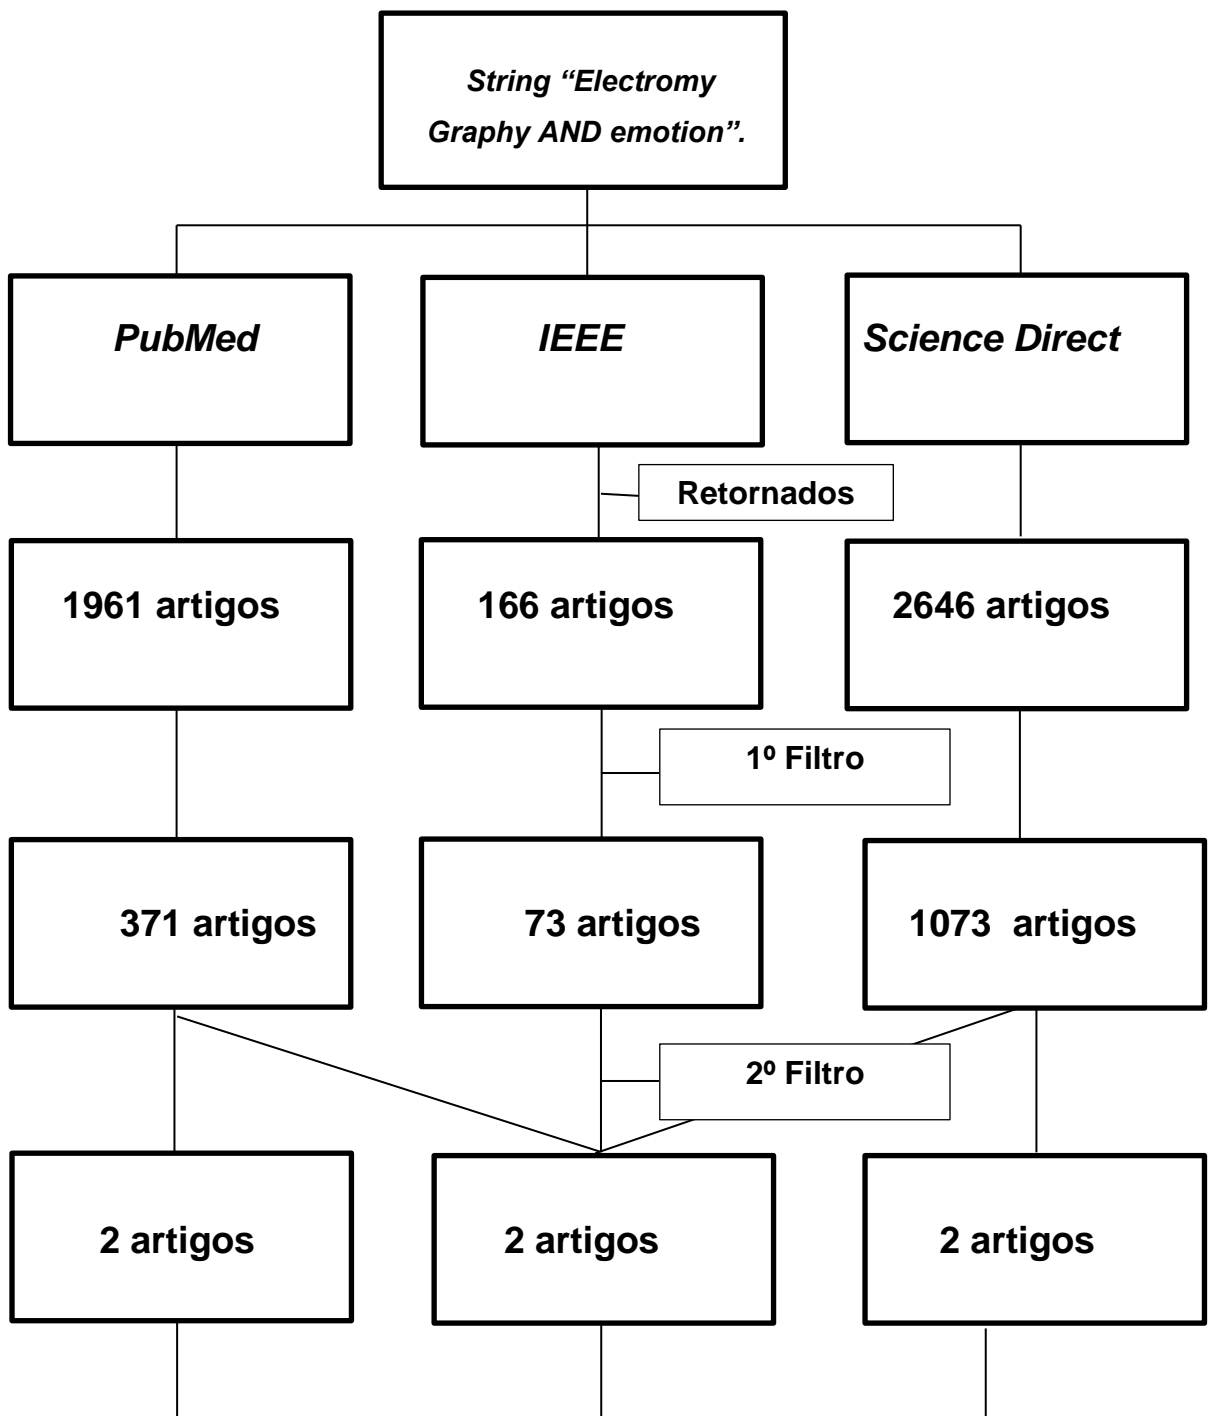


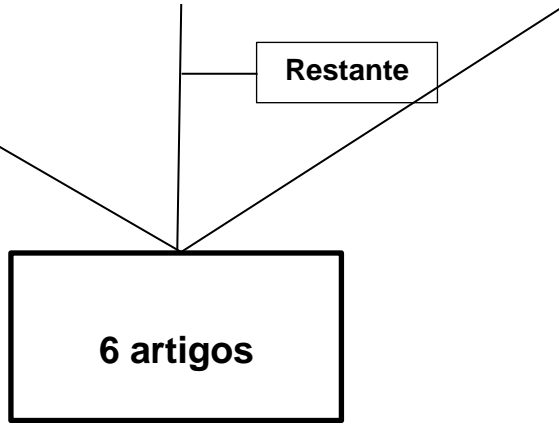


Fonte: Dados da pesquisa (2020).

Restaram 2 artigos de RR, pois havia 1 duplicado.

Fluxograma 5 - Dados da busca da string "electromyography AND emotion".

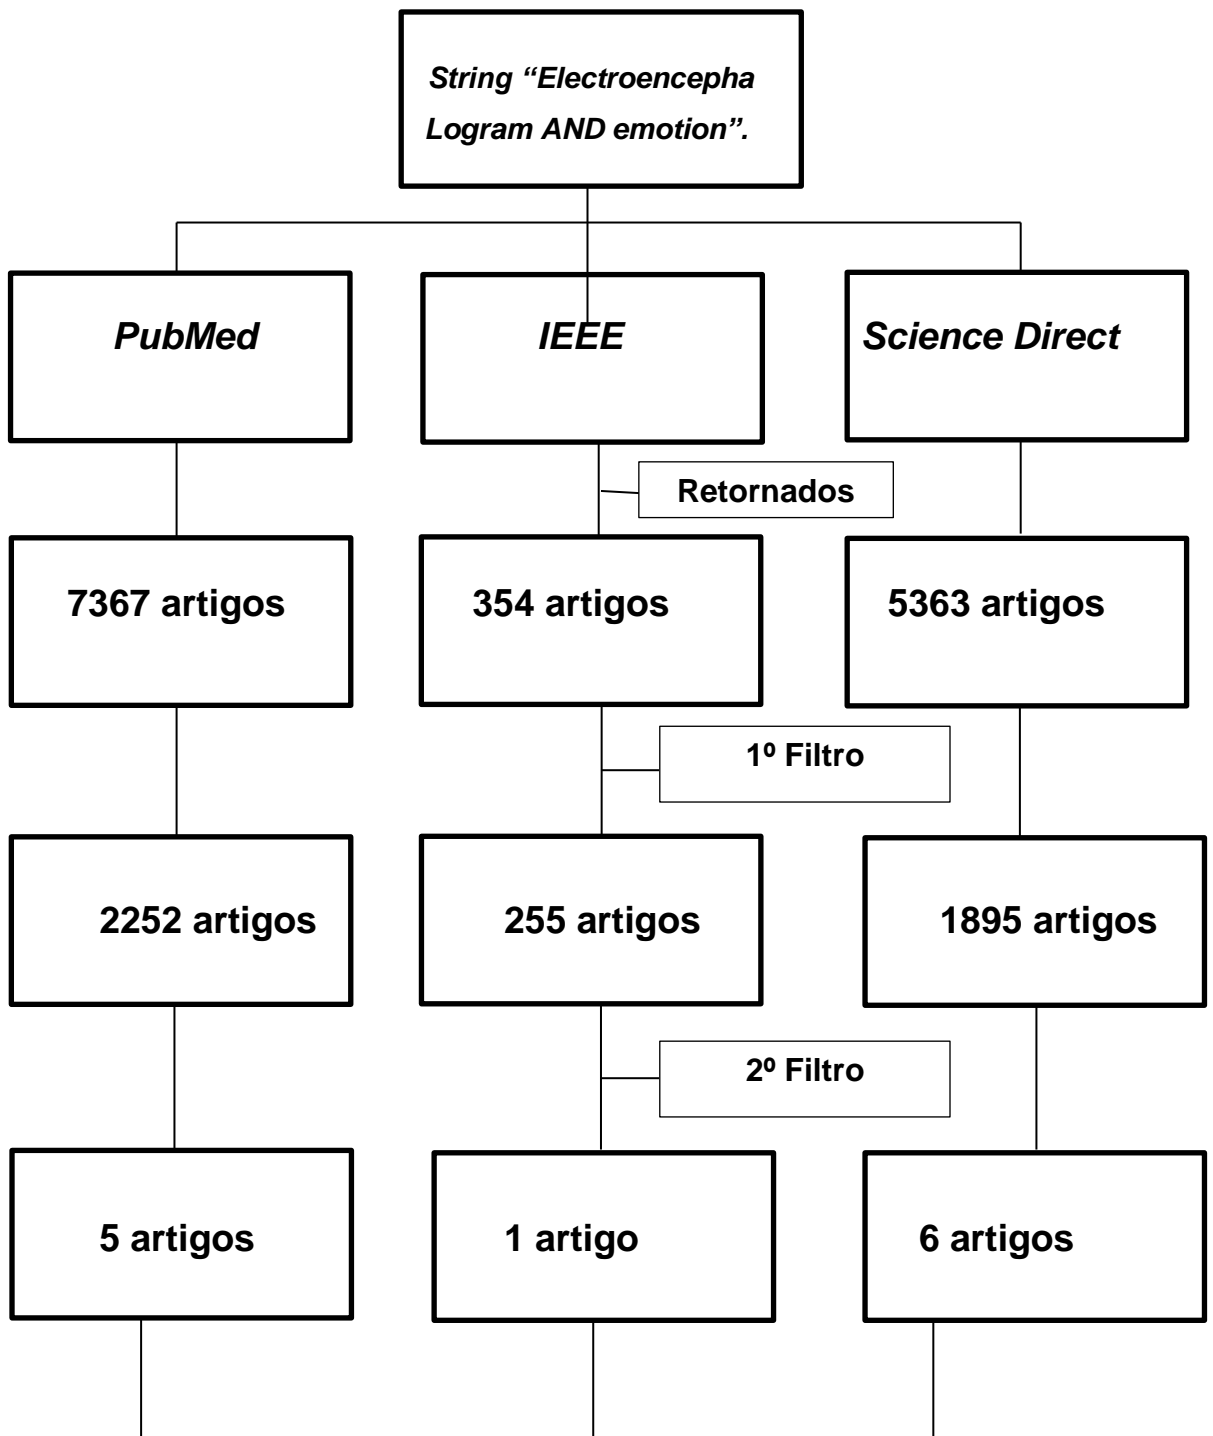


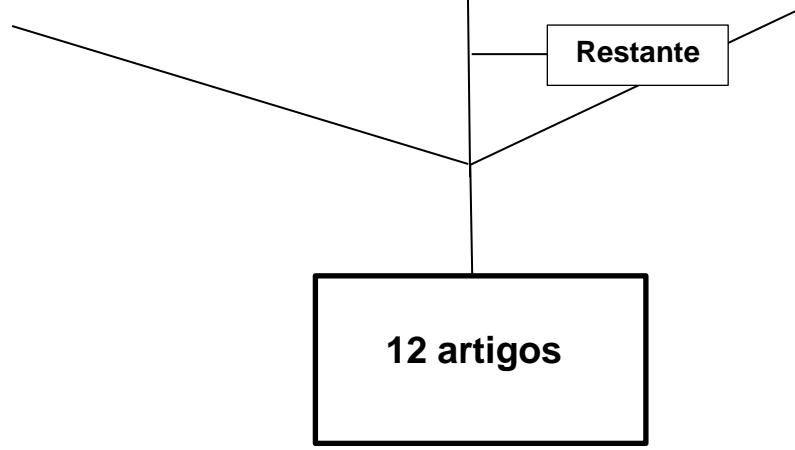


Fonte: Dados da pesquisa (2020).

Restando 6 artigos de EMG.

Fluxograma 6 - Dados da busca da string “*electroencephalogram AND emotion*”.

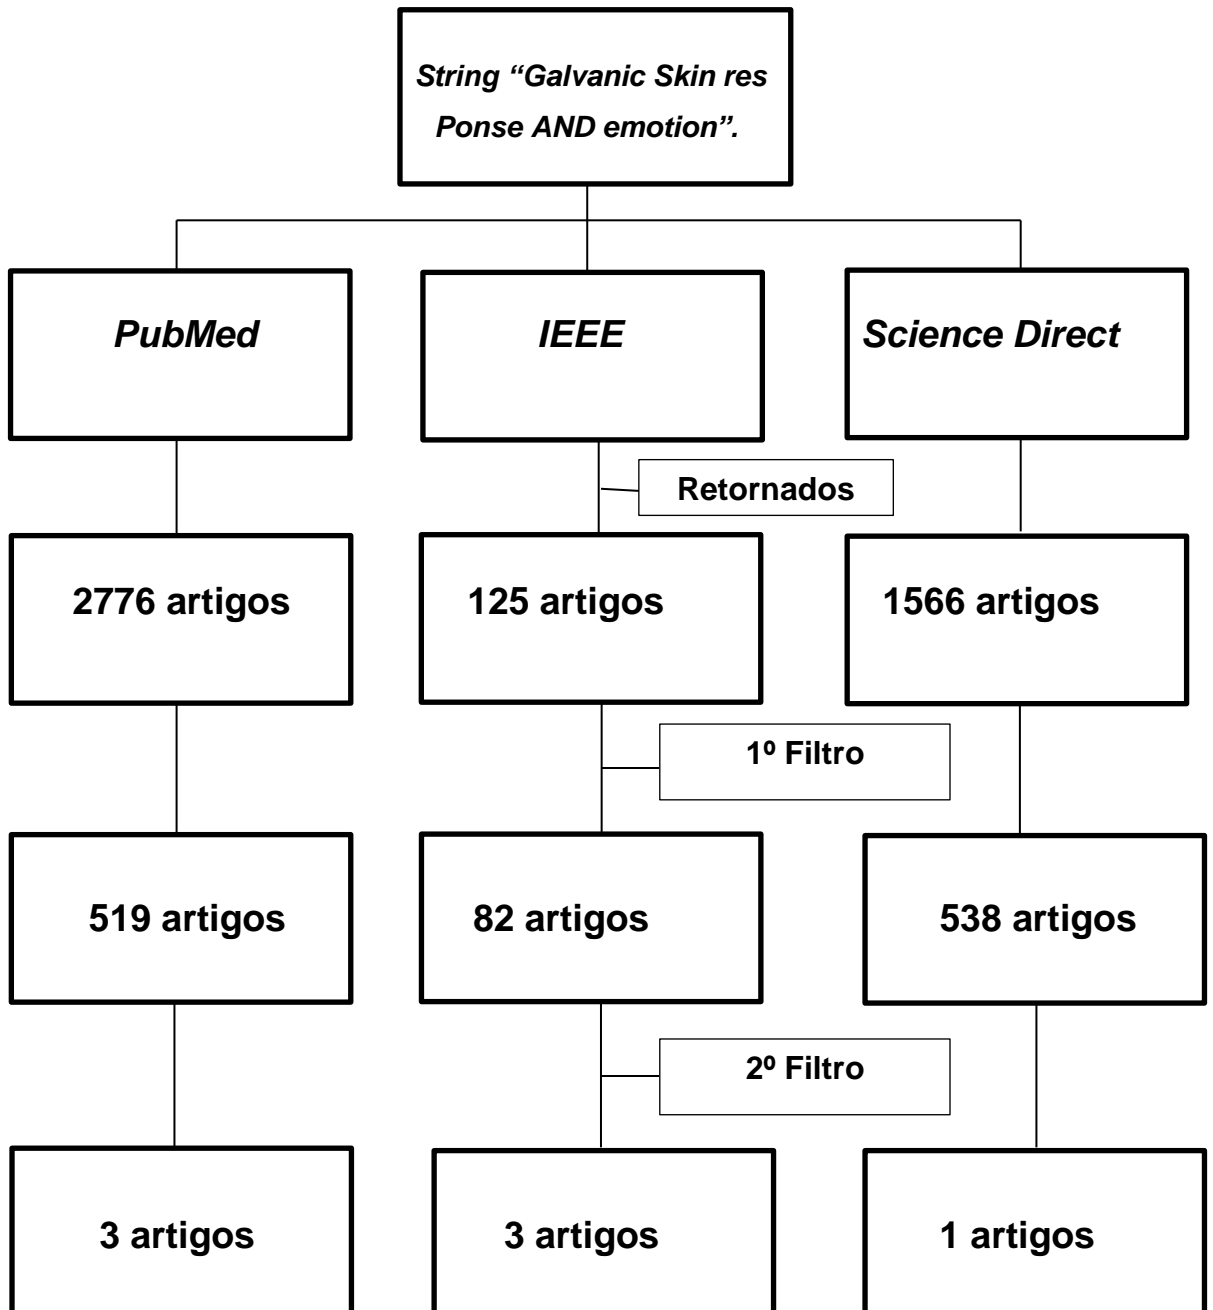


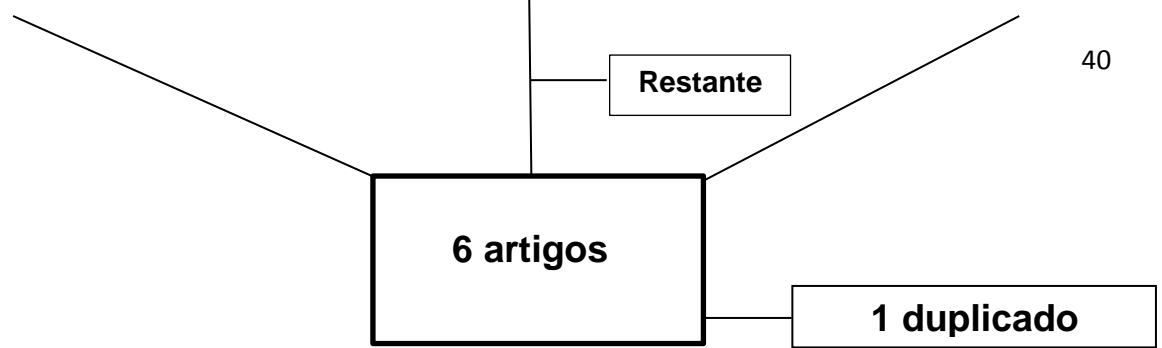


Fonte: Dados da pesquisa (2020).

Restando 12 artigos de EEG.

Fluxograma 7 - Dados da busca da *string* "Galvanic Skin response AND emotion".





Fonte: Dados da pesquisa (2020).

Restaram 6 artigos de GSR, pois 1 estava duplicado.

5.0 RESULTADOS E DISCUSSÕES

Nessa seção serão explanados os resultados e discussões através dos tópicos: equipamentos em geral de biofeedback para identificação do emocional, eletrocardiograma, trabalhos envolvendo eletrocardiograma, termografia, trabalhos envolvendo termografia, taxa de respiração, trabalhos envolvendo a taxa de respiração, eletromiografia, trabalhos envolvendo eletromiografia, eletroencefalograma, trabalhos envolvendo eletroencefalograma, condutância galvânica da pele, trabalhos envolvendo condutância da pele.

Após a filtragem do material e utilização de todas as palavras chaves restaram 71 artigos. Inicialmente como resultados obtivemos que os equipamentos que mensuravam sinais fisiológicos são capazes de identificar o emocional, sendo eles o:

- ✓ Eletrocardiograma (ECG);
- ✓ Termografia;
- ✓ Taxa de respiração (RR);
- ✓ Eletromiografia (EMG);
- ✓ Eletroencefalograma (EEG);
- ✓ Resposta galvânica da pele (GSR).

5.1 Equipamentos em geral de *biofeedback* para identificação do emocional

Foram utilizadas as seguintes palavras chaves: “*physiological signals AND emotion AND sensors*”. E foram retornados 19 artigos, explanados na tabela 1.

Tabela 1 - Artigos sobre equipamentos em geral de *biofeedback* para identificação do emocional

TÍTULO	AUTORES	ANO
A Deep Learning Approach for Classifying Emotions from Physiological Data.	ALZOUBI <i>et al.</i>	2020

Discriminating affective state intensity using physiological responses.	GASPARINI; GILTRI; BANDINI.	2020
Human Emotion Recognition using Bio Signals.	GANTI <i>et al.</i>	2020
Physiological Sensors Based Emotion Recognition While Experiencing Tactile Enhanced Multimedia.	RAHEEL <i>et al.</i>	2020
Reconstructing Compound Affective States using Physiological Sensor Data.	SAXENA <i>et al.</i>	2020
A dataset of continuous affect annotations and physiological signals for emotion analysis.	SHARMA <i>et al.</i>	2019
Physiological signals anticipatory computing for individual emotional state and creativity thinking.	LAI <i>et al.</i>	2019
Human emotion classification based on multiple physiological signals by wearable system.	LIU <i>et al.</i>	2018
A globally generalized emotion recognition system involving different physiological signals.	ALI <i>et al.</i>	2018
Emotion recognition based on weighted fusion strategy of multichannel physiological signals.	WEI <i>et al.</i>	2018

Design of user-customized negative emotion classifier based on feature selection using physiological signal sensors.	LEE., YOO.	2018
Stress detection using wearable physiological and sociometric sensors. .	MOZOS <i>et al.</i>	2017
Recognition of emotion independent of the subject based on physiological signals: a three-stage decision method.	CHEN <i>et al.</i>	2017
A simple algorithm for emotion recognition, using physiological signals of a smart watch	POLLREISZ., TAHERINEJAD,	2017
A wearable device for emotional recognition using facial expression and physiological response.	KWON <i>et al.</i>	2016
Classification of human state emotion from physiological signal pattern using pulse sensor based on learning vector quantization.	MARZUKI <i>et al.</i>	2016
Emotion recognition based on the multiple physiological signals.	GONG., MA., WANG.	2016
Analysis of physiological for emotion recognition with the IRS model.	LI., XU; FENG,	2016
Demonstration of the influence of human emotions in physiological signals.	PATRÃO <i>et al.</i>	2015

Fonte: Dados da pesquisa (2020).

No restante desta seção, serão apresentadas as análises dos artigos, focando quais equipamentos foram utilizados, seus respectivos sensores, locais de aplicação no corpo, os bancos de dados e algoritmos usados nas pesquisas.

Azoulbi et al. (2020) estudaram uma abordagem de aprendizagem profunda visando classificar as emoções por meio de dados fisiológicos, dessa forma, foi utilizado um modelo de rede neural profunda (DNN), com a finalidade de testar a confiabilidade e o desempenho de canais fisiológicos individuais, por meio da detecção das dimensões afetivas alcançadas sobre valência e excitação de gravações de sujeitos ao longo dos dias.

Assim, a pesquisa foi realizada com quatro participantes e os dados foram coletados por meio do equipamento **BIOPAC MP150** e o software **AcqKnowledge**. O sinal de **ECG** foi coletado por meio de dois eletrodos posicionados em ambos os pulsos, o **EMG** foi colocado sobre os músculos faciais (orbicular- sobrelha e zigomático – bochecha) em cada lado, a **condutância galvânica da pele** foi medida acoplado um sensor no dedo indicador e no dedo médio da mão dominante e a taxa de respiração foi mensurada fixando um cinto de respiração ao redor do peito. Dessa forma, a coleta dos dados aconteceu no momento em que os participantes visualizavam um conjunto de imagens da **International Affective Picture System (IAPS)**.

Desse modo, foram realizados 5 sessões de gravações, com visualizações diferentes das imagens e classificação delas em excitação e valência após cada sessão. Para evitar presença de ruídos ambientais, foram aplicados filtros em cada sinal, o sinal de **ECG** foi filtrado com passa baixa em 35HZ e passa alta em 0,05Hz, juntamente com um filtro de entalhe aplicado por meio do dispositivo de gravação. O sinal de **EMG**, filtrada com passa alta com frequência corte de 10 Hz (piscadas, movimentos oculares e potenciais movimentos) e baixa passagem com filtro em 500 HZ. Os sinais de **condutância galvânica e o de respiração** foram filtrados em altas frequências a 0,05 HZ para remover desvios lentos e passa baixa filtrada a 1 Hz para remoção de ruídos de alta frequência.

Portanto, foram extraídos 214 recursos estatísticos de todos os canais utilizando o Augsburg Biosignal Toolbox, sendo 84 do **ECG**, 21 de **condutância galvânica da pele**, 21 de cada canal do **EMG**, 67 da **taxa de respiração e 4**

rótulos de classe, que incluem auto-valência, valência teórica, excitação teórica e auto- excitação.

Dessa forma, foi observado no estudo que a rede neural profunda, conseguiu alcançar uma precisão de 61,12%, 67,14%, 61,41% e 56,38% de detecção (excitação e valência) para auto-relato e classificação IAPS. Também foi observado que o canal **EMG** é mais eficaz em comparação aos demais, e que a fusão de todos os canais teria uma maior precisão para identificar emoções, tanto de valência como de excitação, em relação aos canais isolados.

Gasparini, Giltri e Bandini (2020) obtiveram como objetivo no seu estudo, identificar estados afetivos utilizando sinais fisiológicos. Dessa forma, consideraram dois estados afetivos na pesquisa: relaxamento e estresse, em que o relaxamento foi conduzido por faixas de áudios de sons da natureza e sons do dia a dia, enquanto que o estresse foi induzido por uma carga cognitiva relacionada a cálculos matemáticos. O experimento foi realizado em um ambiente controlado e silencioso, em que os participantes foram colocados em decúbito dorsal durante todo o experimento e utilizaram dois reprodutores de áudio diferentes e suas propriedades imersivas.

O primeiro reprodutor foi o par de fones de ouvido Sony MDR-ZX110 e o segundo reprodutor de áudio foi o travesseiro Spherison Sound6D ©, os sons reproduzidos foram (pássaros, broca de dentista, ondas, cigarras). O estudo foi realizados com 18 estudantes de ciências de computação, sendo 9 mulheres e possuíam faixa etária de 25 anos.

Assim, foram escolhidos dois sinais fisiológicos principais no estudo: a **resposta galvânica da pele (GSR) e fotoplestimografia (PPG)**, utilizando o equipamento **Unidade Shimmer3 GSR +**, a escolha desses dois sinais pelos autores, foi pela sua aparição em outros trabalhos científicos e pela acessibilidade.

Dessa forma, cada sessão realizada tinha uma duração de 20 minutos, dispostos da seguinte forma: 3 minutos de linha de base, com realização de questionários para coletar informações pessoais e estado emocional atual do participante, utilizando a *Visual Analogue Scale for Anxiety (VAS-A)*, 3 minutos de estimulação com os áudios, e a cada estímulo no próximo 1 minuto, era solicitado aos participantes que avaliassem o nível de relaxamento que foi induzido por cada áudio, por meio da escala Likert (1: não relaxante., 5: muito relaxante), seguido por um cálculo aritmético mental.

Assim, os 18 participantes ouvindo as faixas de sons de natureza e de dia a dia, conseguiram induzir diferentes níveis de relaxamento, de acordo com os questionários de auto-avaliação, assim com os mesmos participantes e os cálculos matemáticos, foram induzidos um estado estressante.

Portanto, os autores chegaram à conclusão que os sinais fisiológicos são capazes de identificar o emocional, porém é necessário que se tenha um protocolo experimental capaz de induzir os estados afetivos em um ambiente controlado, demonstraram que, com os dados adquiridos no experimento apresentam diferenças estatísticas significantes e são evidentes em quase todos os recursos adotados para analisar os sinais GSR e PPG, no momento da diferenciação entre relaxamento e estados estressantes. Além disso, os mesmos sinais fisiológicos podem discriminar a intensidade do estado afetivo, especialmente quando o relaxamento é induzido adotando a tecnologia Sound6D.

Ganti et al. (2020) apresentaram como proposta nesse estudo a criação de um sistema de reconhecimento emocional, utilizando sinais fisiológicos. Inicialmente foi realizada uma revisão de literatura, voltada ao estudo das técnicas e métodos que são usados para identificar o emocional (sistemas vestíveis utilizando sinais fisiológicos).

Logo após, o sistema foi desenvolvido com a finalidade de determinar as emoções humanas e exibir a emoção em que o indivíduo se encontra em um dado momento. O sistema utilizou uma placa de Arduino UNO Board, em uma placa de microcontrolador baseada no microcontrolador **ATmega328P de 8 bits**, **sensor de taxa de pulso** responsável por fornecer a saída digital do batimento cardíaco, o led pisca a cada batimento, **sensor de temperatura DS18B20** para mensurar a temperatura corporal e a ferramenta matemática **MATLAB** e o **algoritmo KNN** (K vizinhos mais próximos).

Após a criação do sistema foram realizados testes com indivíduos de 20 e 21 anos, e observaram que o sexo da pessoa não afeta com a emoção. Na Tabela 9 é demonstrada a frequência cardíaca (batimentos por minuto- BPM) e a temperatura medida em graus Celsius, para cada emoção, mediante a idade de 20 a 21 anos:

Tabela 2- Valores de frequência cardíaca e temperatura de acordo com as emoções

Emoções	Taxa de Pulso (BPM)	Temperatura (° C)
Neutra	70 – 90	36,5 – 37,5
Feliz	90 – 110	37,0 – 38,0
Raiva	110 – 130	36,5 – 37,5
Medo	110 – 150	36,0 – 37,0

Fonte: (Ganti *et al.* 2020).

Raheel *et al.* (2020) estudaram os sensores fisiológicos com base no reconhecimento de emoções ao experimentar multimídia aprimorada tátil. No estudo foram selecionados videoclipes diferentes para estímulo das emoções. Dessa forma, utilizaram sensores de sinais fisiológicos para identificação dessas emoções, sendo elas: uma faixa de cabeça EEG disponível comercialmente (Muse) foi usada para registrar os sinais de EEG, enquanto um **módulo *Shimmer GSR*** e PPG foram usados para registrar os sinais GSR e PPG. A faixa de cabeça do Muse tem dois eletrodos temporais (TP9 e TP10) e dois frontais (AF7 e AF8), que são projetados para serem colocados de acordo com o sistema internacional de posicionamento de eletrodos 10-20. Os eletrodos GSR foram colocados no dedo da mão e o eletrodo PPG foi colocado no lóbulo da orelha. Os dados de EEG, GSR e PPG foram adquiridos a uma taxa de amostragem de 256 Hz.

Assim, o modelo Circumplex de Russell foi usado para classificar as emoções em quatro grupos com base em suas pontuações de excitação de valência. A classificação de quatro emoções em resposta ao conteúdo TEM foi realizada usando o algoritmo k-vizinho mais próximo (KNN). As Pontuações positivas de excitação e valência foram rotuladas como um estado feliz, enquanto a excitação negativa e valência foram classificadas como um estado relaxado. Da mesma forma, valência positiva, mas excitação negativa foi rotulada como emoção de raiva, enquanto valência negativa, mas excitação positiva foi rotulada como um estado triste. O número total de ocorrências rotuladas como emoções felizes, com raiva, tristes e

relaxadas foram 40, 13, 22 e 9, respectivamente. Desempenho do reconhecimento de emoções foi avaliado para reconhecer quatro emoções usando o classificador KNN com base nas características de cada modalidade e sua fusão 79,76 % com alta sensibilidade e especificidade em comparação às modalidades individuais.

Saxena et al. (2020) reconstruíram os estados afetivos compostos usando dados fisiológicos do sensor. O experimento teve como objetivo coletar dados do sensor fisiológico e pontuações de autorrelato de um indivíduo para um vídeo pertencente a uma classe alvo.

Assim, esses dados foram usados para gerar dois modelos, o primeiro mapeava o dado fisiológico para um estado emocional dominante. O segundo mapeava os dados fisiológicos para as pontuações de autorrelato (indicando os níveis de ativação de todos os estados emocionais). Os dados fisiológicos do sensor E4, incluindo frequência cardíaca (HR), atividade eletrodérmica (EDA), pulso de volume sanguíneo (BVP) e intervalo entre batidas (IBI), são coletados para um participante durante a duração do videoclipe.

Assim, foram criados um mapa entre os dados fisiológicos e o estado emocional dominante e também entre os dados fisiológicos e as pontuações de autorrelato. Além disso, identificaram características frequentemente negligenciadas da emoção humana, como variabilidade na percepção e sobreposição de estados emocionais e, finalmente, criamos um mapa topológico de estados emocionais com base na fisiológicos.

Sharma et al. (2019) construíram um conjunto de dados de anotações de afeto contínuas e sinais fisiológicos para análise de emoção. Os participantes da pesquisa foram instruídos a anotar sua experiência emocional decorrentes dos vídeos assistidos e não o conteúdo emocional dos vídeos. Foram utilizados sinais de ECG (Dois eletrodos posicionados sobre o processo coracóide direito e esquerdo e o terceiro sobre o processo xifóide), RR (Cinto sensor de respiração aplicado no alto do tronco, sob as axilas, acima dos seios), PPG (Sensor colocado no dedo médio da mão dominante), GSR (Sensor colocado no dedo indicador e anular da mão não dominante), Temperatura (Sensor colocado no dedo mínimo da mão não dominante), EMG (Sensor aplicado no zigomático maior e corrugador supercílio na face e o musculo trapézio na parte superior das costas).

Foram utilizados o modelo circunplex 2D e auto avaliação manequim (SAM). Dessa forma, os autores concluíram que o conjunto de dados de sinais emocionais

com anotações contínuas (CASE) fornecem uma solução porque se concentram nas anotações emocionais contínuas em tempo real experimentadas pelos participantes enquanto assistem a vários vídeos. Para este fim, foi desenvolvida uma nova interface de anotação intuitiva baseada em joystick que permite relatórios simultâneos de preços e de excitação, e esses relatórios são geralmente anotados de forma independente.

Lai et al. (2019) estudaram os sinais fisiológicos, computação antecipada para o estado emocional individual e pensamento criativo. Este estudo usou quatro tipos de instrumentos fisiológicos: sensor de pulso, sensor Grove GSR, sensor Grove EMG e NeuroSky MindWave. Os registros de dados fisiológicos, pulso, GSR e EMG são registrados a cada 20 ms, cada dado foi gravado no tempo de registro e, em seguida, o valor do sinal fisiológico foi gravado .

Neste estudo foi utilizado o *Support Vector Machine* (SVM) para a classificação das emoções e considera o “kernel” linear, o “kernel” polinomial e o “kernel” da função de base radial (RBF) na seleção da função central. Foram exibidas 70 fotos selecionadas do *International Affective Picture System* (IAPS), que contêm quatro imagens emocionais de valência e excitação que incluem alta intensidade emocional, baixa intensidade emocional, emoções positivas e emoções negativas da imagem. Os resultados mostram que as emoções mudam com o pensamento criativo, além de proporcionar o pensamento criativo que ajuda a fortalecer a criatividade dos alunos.

Liu et al. (2018) classificaram as emoções humanas com base em vários sinais fisiológicos por sistema vestível, por meio da criação de um sistema sem fio vestível com a finalidade de adquirir um sinal de eletroencefalograma de canal único, sinal de eletrocardiograma, respiração e posturas corporais para identificar a relação entre esses sinais e as emoções humanas. Dessa forma, os sensores foram distribuídos colocando um nó sensor na faixa de cabeça para identificar o sinal de EEG de canal único e rastrear a postura da cabeça, localizado próximo à testa pelos eletrodos médicos, o lóbulo da orelha direita foi utilizado para reduzir a interferência de ECG e o nó fixado na bolsa torácica para identificar o ECG e a aquisição do sinal de impedância respiratória por um par de eletrodos comuns.

Desse modo, as informações coletadas por esses sensores foram comparadas com os métodos tradicionais de classificação baseados em EEG multicanal por meio do **equipamento EEG comercial (V- Amp, Alemanha)**, as

emoções foram estimuladas por meio de filmes. E como recurso utilizou-se o *Machine Support Vector linear (SVM)* e a *transformed Hilbert- Huang (HHT)*.


Assim, comparado com os métodos tradicionais de classificação de emoções, este método pode extrair um pequeno número de características-chave relacionadas às emoções humanas de vários sinais fisiológicos e incorporá-los na classificação de máquinas de vetores, o que reduz bastante a complexidade do algoritmo. O método proposto pode oferecer suporte à análise online embutida e pode melhorar a usabilidade da classificação de sentimento.

Ali et al. (2018) criaram um sistema de reconhecimento de emoções globalmente generalizado envolvendo diferentes sinais fisiológicos. Neste artigo, foi explorado um sistema de reconhecimento de emoções humanas que é independente do sujeito e consiste em dois modelos principais. O primeiro é um modelo de calibração automática de recursos e o segundo é um modelo de classificação baseado em uma rede neural celular (CNN). Foram utilizados os sinais de ECG (eletrocardiograma), EDA (atividade eletrodérmica) e ST (temperatura da pele). Dessa forma, o sistema proposto produziu resultados com uma taxa de precisão entre 80% e 89% ao usar os mesmos materiais de elicitación e marcas de sensores fisiológicos para treinamento e teste e uma taxa de precisão de 71,05% quando os materiais de elicitación e fisiológicos foram usados em treinamento.

Wei et al. (2018), apresentaram como proposta no estudo uma estratégia de fusão de multicanais de sinais fisiológicos para reconhecimento de emoções. Assim, foram utilizados domínios de análise na extração das características fisiológicas como: frequência, tempo e análise estatística.

Dessa forma, os presentes autores afirmam que o EEG é considerado um método para monitoramento e registro da atividade elétrica do cérebro, e evidenciam a base de dados MAHNOB-HCI, que disponibiliza informações de EEG de 32 canais, sendo 14 do hemisfério esquerdo e 14 do hemisfério direito, com 4 na linha média. Assim, é possível por meio desses dados reconhecerem que os principais lobos envolvidos com a emoção incluem os lobos frontais, parietais e temporais. Diante disso, os pesquisadores do presente estudo, selecionaram 12 canais, sendo eles: Fp1, FC5, T7, P7 e O1 do hemisfério esquerdo e Fp2, AF4, F8, T8, P4 e PO4 do hemisfério direito e Oz da linha de média. (Figura 1).

Figura 1 - Posicionamento dos eletrodos de EEG




Fonte: (Wei *et al.*, 2018).

Além disso, o EEG apresenta bandas de frequência: delta (0 – 4 Hz), teta (4 – 7 Hz), alfa (8 -15 Hz) e beta (16 – 31 Hz), em que delta e teta são presentes em bebês e crianças (normalmente), alfa leva ao fechamento dos olhos e beta pode ser visto dos dois lados, apresentando simetria e sendo mais evidente na parte frontal, sendo utilizado nesse estudo a banda beta, com densidade espectral média, padrão e máxima potencial para o vetor de EEG ser visualizado em 36 dimensões.

Dessa forma, também foi utilizado o sinal de eletrocardiografia (ECG), que mensura a atividade elétrica do coração, apresentando no MAHNOB-HIC, três canais gravados, o ECG produz quatro principais ondas: onda P, complexo QRS, onda T e onda U (Figura 2). Dessa forma, os autores utilizaram para o reconhecimento de emoções por meio do ECG, os recursos de: frequência e tempo, e média e padrão de amplitude da onda P, T e variabilidade de frequência cardíaca no domínio de tempo. E obtiveram um vetor de 33 dimensões.

Figura 2 - Ondas do ECG



Fonte: (Wei *et al.*, 2018).

Além disso, a amplitude da respiração também é mensurada por meio de um cinto elástico ao redor do tórax. Assim, segundo os dados do MAHNOB-HCI o relaxamento causa diminuição da amplitude respiratória, situações de estresse e tensão pode levar a cessação momentânea da respiração e as emoções negativas causam irregularidade no padrão respiratório. O vetor analisado para a amplitude respiratória foi de 28 dimensões.

Em relação à resposta galvânica da pele (GSR), ela mede as alterações das propriedades elásticas da pele, como resposta as alterações do SNA. Quando a atividade simpática aumenta, as glândulas sudoríparas levam a uma diminuição da resistência da pele. O vetor analisado no GSR foi de 28 dimensões.

Assim, após os dados serem extraídos desses equipamentos, foi treinado um classificador para o reconhecimento das emoções o SVM, um modelo de aprendizado supervisionado com algoritmo de aprendizagem. Portanto, após os experimentos no banco de dados MAHNOB-HCI foi mostrado a eficácia do método proposto no estudo.

O registro dos sinais nesse banco de dados se deu pelas modalidades: EEG de 32 canais (256 Hz), ECG de 3 canais (256 Hz), AR de 1 canal (256 HZ), GSR de 1 canal (256 Hz), temperatura da pele de 1 canal (256 Hz), vídeo de rosto e corpo (6 câmeras, 60f/s), olhar nos olhos (60Hz) e áudio (44,1 kHz). Assim, foram registradas

as seguintes emoções: tristeza, alegria, felicidade, nojo, neutro, diversão, raiva, medo, surpresa e ansiedade.

Lee e Yoo (2018) projetaram um classificador de emoções negativas personalizado para o usuário com base na seleção de recursos usando sensores de sinais fisiológicos. Foram utilizados estímulos visuais para conduzir as emoções, inicialmente foi utilizado o filme de terror “**Saw 3**” para induzir as emoções negativas e o filme “**Two Faces of Humans**” para conduzir emoções básicas nos participantes do estudo, cada sessão com 60 minutos de duração.

Desse modo, os sinais fisiológicos foram amostrados a 1kHz, utilizando o equipamento **BIOPAC MP 150 TM** com ECG-100C, SKT-100C e EDA-100C, os sinais fisiológicos que foram medidos: ECG, temperatura da pele e atividade eletrodérmica. Os posicionamentos dos sensores foram: sétima costela esquerda (+), sob a clavícula direita (-) e na parte de trás do pescoço (como terra) para medição do **ECG**. O SKT foi medido acoplado o sensor no braço direito. E a EDA os sensores foram acoplados nos dedos médio e anelar da mão direita.

Portanto, como resultados do estudo obtiveram que as emoções foram induzidas em todos os sujeitos, os recursos da EDA são importantes para distinguir emoções negativas em todos os assuntos. Além disso, o algoritmo de seleção de recurso proposto mostrou uma precisão média de 92 % para identificar emoções negativas.

Mozos et al. (2017) estudaram a detecção de estresse usando sensores fisiológicos e sociométricos vestíveis. Dessa forma, para a medição dos sinais fisiológicos, foi utilizado um sensor sem fio em formato de uma pulseira, na mão não dominante de um sujeito, a mesma possui um conjunto de eletrodos situados entre os dedos. Os sensores foram utilizados visando à identificação de três medições: EDA, PPG e O HRV. E um segundo usado foi um sensor sociométrico, dispositivo pequeno acoplado ao redor do pescoço como um crachá de conferência, ele é equipado com um gravador de voz e um acelerômetro que mensura o grau e a direção dos movimentos dos sujeitos. Utilizaram classificadores para diferenciar o desempenho diferente dos sensores, sendo os classificadores:

- ✓ *Machine Support Vector (SVM).*,
- ✓ *AdaBoost.*,
- ✓ *Algorithm KNN.*,

Assim, conseguiram obter como resultados da pesquisa que o método e a análise desenvolvida, podem fornecer uma ferramenta útil para detectar o estresse em tempo real. E que em estudos futuros seja possível se aprofundar nos efeitos do *feedback* em tempo real e identificar gatilhos específicos que levam a níveis altos prejudiciais do estresse.

Chen et al. (2017) propuseram em seu estudo um novo método de decisão em três etapas para reconhecer emoções com sujeitos diferentes, por meio de sinais fisiológicos. A extração de recursos foi realizada pelo banco de dados (DEAP), para análise de emoções utilizando sinais fisiológicos. Esse banco contém sinais de EEG gravados a partir de 32 eletrodos ativos e 32 canais, usando o sistema internacional 10-20 e os demais sinais GSR, ECG, EMG, RSP de 8 canais. Dessa forma, os sinais foram gravados no momento que era transmitido 40 clipes de música de um minuto.

Assim, foram utilizadas no estudo duas dimensões básicas: valência e excitação. O processo foi realizado em três etapas, na primeira os indivíduos do treinamento misto são transformados em grupos separados, eliminando os efeitos das diferenças individuais. Na segunda etapa foram categorizadas quatro emoções em dois conjuntos emocionais, para a redução da complexidade do reconhecimento. E na terceira etapa foi realizado um treinamento de um classificador baseado nas emoções em cada pool de emoções.

Dessa forma, como resultados obtiveram precisão média de reconhecimento de 77, 57% em quatro emoções, com 86, 67% para o reconhecimento de emoções positivas e excitadas. Também concluíram que utilizando maneiras distintas para alocar quatro emoções em dois grupos emocionais, existe uma diferença na eficácia do classificador para aprender cada emoção. E que em relação aos outros métodos de reconhecimento, o proposto nesse estudo demonstra uma melhora significativa no reconhecimento de quatro emoções no contexto de diferentes sujeitos.

Pollreisz e Taherinejad (2017) estudaram sobre um algoritmo para reconhecimento de emoções, utilizando sinais fisiológicos. Dessa forma, utilizaram para coletar dados dos relógios inteligentes Empáticos que mensurava valores de EDA, SKT e HR. Logo após foi solicitado aos participantes da pesquisa que assistissem a um vídeo estimulador de emoções (os autores não especificaram o nome do filme), e em seguida preenchessem um questionário de auto avaliação para relatar as emoções sentidas durante o experimento.

Após coleta desses dados, na etapa pré processamento do algoritmo, foram calculados os valores de linha de base dos sujeitos, em seguida após extração dos recursos, com base na linha de base, os sinais de HR, EDA, SKT foram analisados em relação ao aumento e diminuição das alterações, e o sinal de EDA também foram analisados em relação aos picos. Assim, as características de vários sinais fisiológicos e suas correlações com as emoções são demonstradas na tabela 3:

Tabela 3 - Sinais fisiológicos e suas correlações com as emoções

EMOÇÃO	HR	EDA	PICOS DE EDA	SKT
Felicidade	Pequeno aumento	Aumenta	Pequeno e poucos	Ligeira diminuição
Tristeza	Diminuição	Aumenta	Pequenos e muitos	Ligeira diminuição
Raiva	Ligeira diminuição	Aumenta	Grande e alguns	Ligeira diminuição
Dor	Nenhuma mudança	Aumenta	1 grande	Nenhuma mudança

Fonte: (Pollreisz., Taherinejad, 2017).

O algoritmo utilizado nesse experimento foi definido por meio da análise estatística dos picos, nas mudanças de nível do sinal e de um sistema de contador ponderado para reconhecimento de emoções. Assim, o sistema criado possibilitou o reconhecimento de emoções em um sistema pequeno (dispositivos portáteis), encontrado como resultado uma taxa de sucesso de identificação de emoções de 65% e um valor de confiança em média de 57%.

Know et al. (2016) projetaram um dispositivo vestível para reconhecimento emocional usando a expressão facial e resposta fisiológica. O dispositivo utiliza dois modos de medição. Um dos canais é a resposta fisiológica. O dispositivo pode obter a condutância da pele e a pressão sanguínea dos sensores conectados. Na parte de contato do nariz e da orelha direita, existe um sensor que pode medir a atividade elétrica da pele (EDA) e um sensor de fotopletismografia (PPG) na orelha esquerda, a localização do sensor foi determinada para minimizar o ruído gerado pelos

movimentos faciais. O outro canal são as expressões faciais, que podem ser capturadas pela câmera. Na frente do olho esquerdo, há um módulo de câmera embutido que pode capturar parte das expressões faciais. As respostas fisiológicas foram adquiridas do dispositivo e transferidas por Bluetooth, sendo coletada durante o tempo de observação, ao final da observação a extração de características era processada a partir do sinal coletado.

Assim utilizaram o método *ReliefF* para seleção de recursos que avaliava de forma iterativa do grau de agrupamento de cada recurso e o modelo Naive Bayes para classificação das emoções e a validação cruzada *leave-one-out (LOOCV)* foi usada para os dados fisiológicos. Dessa forma, a precisão das expressões faciais apareceu em mais de 98% para todos os tipos de emoções.

Portanto, os resultados do caso dependente mostraram que as expressões faciais são consideráveis e de alta precisão, independentemente do tipo de emoções. O que indica que as câmeras vestíveis podem ser um canal para o reconhecimento de emoções, apesar de usar apenas a parte de expressão lateral. Em relação às limitações, o resultado do caso independente do assunto mostra que o modelo não poderia ser robusto para diferenças entre usuários, e que uma sessão de treinamento para cada pessoa deve ser necessária. Pois, embora a abordagem baseada em câmera tenha vantagem da medição sem contato, ela ainda apresenta desvantagem na variação de iluminação.

Markuzi et al. (2016) estudaram a classificação da emoção do estado humano a partir do padrão de sinal fisiológico usando sensor de pulso com base na quantização do vetor de aprendizagem. Aplicaram um sensor de pulso do ***E-Health Platform v2.0 Sensor*** para registrar os dados fisiológicos de cada estado emocional. Este sensor é um sensor não invasivo, prático para monitorar o pulso e os níveis de oxigênio no corpo humano, sendo conectados a um módulo de sensor do sistema de e-health, esse módulo é usado para ler os sinais dos sensores e processá-los e depois transmitidos ao Arduino. Dessa forma, depois de assistir aos estímulos de vídeo, os participantes preencheram um questionário sobre o que sentiram.

Neste estudo, o algoritmo básico de *Learning Vector Quantization (LVQ)* foi usado e os parâmetros de LVQ que é usado principalmente para o sistema de reconhecimento em sistema biométrico e biomédico. Assim, dez parâmetros foram analisados por meio do sensor de pulso, como valor médio dos dados em relação ao

limite da linha de base, valor mínimo e máximo, desvio padrão, número de Onset e Offset, número e total do valor de amplitude, total de tempo de subida, e hora de chegada. Parâmetros ideais para classificação de dados usando *Learning Vector Quantization* foram apresentados neste estudo. A precisão do LVQ em prever emoções de acordo com os dados fisiológicos foi de 68,52% com porcentagem de 70%. Este estudo preliminar mostrou que algumas melhorias são necessárias para que cada estado de emoção possa ser reconhecido de forma única usando dados fisiológicos do sensor de pulso.

Gong, Wang e Feng (2016) estudaram o reconhecimento de emoções com base nos múltiplos sinais fisiológicos. Este artigo apresentou um estudo para o reconhecimento de emoções por fusão de características de múltiplos sinais fisiológicos. Os sujeitos foram convidados a ouvir músicas diferentes para induzir as diferentes emoções, tais como: alegria, raiva, tristeza e prazer. Quatro tipos de sinais fisiológicos foram considerados: eletrocardiograma (ECG), eletromiografia (EMG), alterações respiratórias (RSP) e condutividade cutânea (SC). Para cada sinal, quatro tipos de recursos foram extraídos: recursos de domínio de tempo, recursos de frequência de tempo, recursos não lineares e recursos de função de modo intrínseco (IMFs).

Por fim, este estudo também testou vários conjuntos de recursos para reconhecer emoções. Os resultados experimentais mostraram que os recursos baseados no FMI superam outros e um pequeno conjunto de recursos que consiste nos recursos selecionados pode detectar emoções com muito mais precisão do que usar um conjunto de recursos maior. A alegria e a raiva podem ser reconhecidas facilmente com a precisão acima de 80%, os melhores desempenhos de classificação acontecem em classificar alegria usando o conjunto de recursos de transformação wavelet e classificar raiva usando o conjunto de recursos de domínio do tempo ou usando o conjunto de recursos IMFs. Isso pode ser devido à alegria e à raiva terem uma alta excitação que pode resultar em mudanças de sinais fisiológicos mais fortes, enquanto a tristeza e o prazer com uma baixa excitação que são mais difíceis de classificar. Por outro lado, em comparação com o conjunto de recursos do IMFs, o desempenho do conjunto de recursos do IMF é melhor do que o conjunto de recursos no domínio do tempo e o conjunto de recursos de transformação wavelet, que contêm mais recursos. Portanto, a decomposição EEMD pode obter mais informações dos sinais fisiológicos sob as diferentes emoções, como esperado.

Li e Xu (2016) analisaram o reconhecimento de emoções por meio de um modelo IRS (Especificidade de Resposta Individual). Neste artigo, sinais fisiológicos foram utilizados para inferir a emoção do usuário. No entanto, os resultados do reconhecimento de emoção com base fisiológica ainda são imprecisos no cenário independente do usuário, uma vez que a maioria dos métodos existentes ignora a diferença no padrão de resposta individual. Para tanto, propuseram um modelo de IRS baseado em grupo para melhorar o desempenho do reconhecimento de emoções com base fisiológica, levando em consideração o IRS do usuário. As principais contribuições deste artigo são duas: (1) um banco de dados fisiológico afetivo é coletado para analisar o padrão de resposta emocional humana. Os sinais fisiológicos são registrados de 30 sujeitos em quatro emoções induzidas (neutro, tristeza, medo e prazer). Biossensores de três canais são usados para medir o eletrocardiograma (ECG) dos usuários, resposta galvânica da pele (GSR) e fotopletismografia (PPG). (2) No experimento, o modelo de IRS baseado em Grupo é proposto para o reconhecimento de emoções em um cenário independente do usuário, cuja eficácia foi validada em nosso banco de dados. Os resultados mostram que o modelo de IRS baseado em Grupo pode atingir maior precisão de reconhecimento do que o modelo geral.

Patrão et al. (2015) investigaram a influência das emoções humanas nos sinais fisiológicos. Os autores propuseram um aplicativo para ser utilizado em um experimento de laboratório, este aplicativo possui duas partes, uma imersiva e estimulante para orientar o aluno na realização do experimento e a segunda dedicada à aquisição, pré-processamento e entrega de bio-sinais. Os alunos foram estimulados por meio de vídeos emocionais.

Assim, a configuração necessária para este experimento requer três dispositivos diferentes: um laptop, um *Oculus Rift* e um *BITalino*. O kit padrão vem com a maioria dos sensores necessários para este experimento (EDA, ECG e acelerômetro). O único sensor que foi adquirido separadamente é o de medição da temperatura corporal.

Dessa forma, os eletrodos da eletrocardiografia foram colocados no espaço intercostal na linha hemiclavicular; a atividade eletrodérmica está ligada uma ao dedo indicador e a outra ao anular; o sensor de temperatura foi preso a uma faixa ao redor do peito da pessoa e o acelerômetro foi fixado na parte inferior das costas do sujeito, pois este é o local mais próximo do centro de massa do corpo.

O resultado da pesquisa foi inconclusivo e os autores esperam que os alunos consigam estabelecer uma nova relação desses parâmetros e compreender melhor suas manifestações em seu próprio corpo.

Diante do exposto anteriormente, os recursos tecnológicos para identificar emoções foram: (Tabela 4).

Tabela 4 - Tabela de equipamentos gerais de sinais fisiológicos

Recurso Tecnológico	Empresa Responsável
<i>Biopac System MP150</i>	<i>Biopac</i>
Unidade <i>Shimmer 3 GSR+</i>	<i>Shimmer</i>
<i>Neurosky MindWave</i>	<i>NeuroSky</i>

Fonte: Dados da pesquisa (2020)

Dentre os equipamentos identificados na presente pesquisa, os que apareceram com mais frequência são: ***Biopac System MP150, Unidade Shimmer 3 GSR+, Neurosky MindWave.***

O *Biopac MP150* é um sistema de aquisição de dados que funciona como um gravador gráfico na tela, osciloscópio e plotter X / Y, permitindo registrar, visualizar, salvar e imprimir dados (BIOPAC, 2020) (Figura 3).

Figura 3 - Biopac 150



Fonte: (BIOPAC, 2020).

O **Shimmer GSR +** é usado para *GSR Biofeedback* em tempo real. O sensor Shimmer GSR + monitora a condutividade da pele entre dois eletrodos reutilizáveis ligados a dois dedos de uma mão, causado por um estímulo, as glândulas sudoríparas tornam-se mais ativas, aumentando a umidade da pele e permitindo que a corrente flua mais prontamente, alterando o equilíbrio entre positivo e negativo íons no fluido secretado (aumentando a condutância da pele)(SHIMMER, 2020) (Figura 4).

Figura 4 - Shimmer GSR



Fonte: (SHIMMER, 2020).

MindWave Mobile 2 da NeuroSky é um fone de ouvido EEG que pode medir e transmitir o espectro de energia (onda α , onda β , etc.) de dados por Bluetooth de baixa energia ou Bluetooth clássico sem comunicação e utilizando computador, iOS ou dispositivo Android (SPARKFUN, 2020) (Figura 5).

Figura 5 - MindWave Mobile 2



Fonte: (SPARKFUN, 2020).

Os estudos evidenciaram que as emoções no momento dos experimentos são estimuladas por meio de imagens, sons e vídeos. Utilizaram a IAPS (*International Emotion Picture System*) que é um banco de dados de imagens cujo objetivo é fornecer uma coleção padronizada de imagens para o estudo da emoção e da atenção, que tem sido amplamente utilizada na pesquisa psicológica (LANG.; BRADLEY, 2007).

Os principais algoritmos presentes nas pesquisas foram: **Algoritmo KNN, Naives Bayes e Support Vector Machine.**

O **algoritmo KNN** é um dos mais simples algoritmos de aprendizado de máquina, baseado em distância aprimorada e foi formalmente proposto por Fukunaga em 1975. Neste algoritmo, o conjunto de dados é formado por vetores n-dimensionais e cada amostra no conjunto de dados representa um ponto no espaço n-dimensional. Portanto, a distância entre dois pontos pode ser calculada. O KNN treinado não gera um modelo, ele apenas armazena dados, ao adicionar uma nova amostra de teste, a distância entre o elemento e outras amostras armazenadas pode ser calculada. O parâmetro K pode ser alterado, o que indica quantos vizinhos e suas categorias serão analisados (SOUZA, 2019).

O **algoritmo de classificação de Naive Bayes** é baseado no teorema de Bayes e no método de probabilidade de Bayes. O modelo gerado pelo algoritmo de classificação gera uma tabela de probabilidade com base nos dados de treinamento fornecidos. A principal característica desse algoritmo é ignorar a correlação entre atributos (SOUZA, 2019).

O **SVM** é um algoritmo de otimização matemática que implementa as restrições derivadas da teoria de aprendizagem estatística. Além de bioinformática, processamento de texto e outras tarefas de reconhecimento de padrão, a tecnologia também tem um bom desempenho em uma variedade de ambientes de aprendizado de máquina. Os resultados desse algoritmo são comparáveis e, em muitos casos, melhores do que outros métodos populares de aprendizado de máquina (SOUZA, 2019).

O objetivo do SVM é determinar as linhas que separam as categorias e minimizar os erros. Portanto, a margem do classificador é definida como a distância mais curta entre os exemplos do conjunto de treinamento e o hiperplano usado para classificar esses dados em várias categorias (SOUZA, 2019).

5.2 Eletrocardiograma

Foram utilizadas as seguintes palavras-chaves: “**Electrocardiography AND emotion**”. E foram retornados 19 artigos, explanados na tabela 5.

Tabela 5 - Artigos sobre equipamentos de eletrocardiograma para identificação do emocional.

Biometric and emotion identification: An ECG compression based method.	BRÁS <i>et al.</i>	2018
An accurate emotion recognition system using ECG and GSR signals and matching pursuit method.	GOSHVARPOUR,; ABBASI; GOSHVARPOUR.	2017
DREAMER: A database for emotion recognition through EEG and ECG signals from wireless low-cost off-the-shelf devices.	KATSIGIANNIS; RAMZAN.	2017
Mutual information between heart rate variability and respiration for emotion characterization.	VALDERAS <i>et al.</i>	2019
Fusion of heart rate variability and pulse rate variability for emotion recognition using lagged poincare plots.	GOSHVARPOUR, ABBASI., GOSHVARPOUR.	2017
Electrocardiographic and electrooculographic responses to external emotions and their transitions in bipolar i and ii disorders.	MA <i>et al.</i>	2018

An ensemble learning approach for electrocardiogram sensor based human emotion recognition.	DISSANAYAKE <i>et al.</i>	2019
How do amusement, anger and fear influence heart rate and heart rate variability?.	WU <i>et al.</i>	2019
Effects of emotions on heart rate asymmetry.	KACZMAREK <i>et al.</i>	2019
A comparative study of stress and anxiety estimation in ecological settings using a smart-shirt and a smart-bracelet.	TIWARI <i>et al.</i>	2019
An automatic classifier of emotions built from entropy of noise.	FERREIRA <i>et al.</i>	2017
Assessment of ultra-short heart variability indices derived by smartphone accelerometers for stress detection.	LANDREANI <i>et al.</i>	2019
Stressing the accuracy: Wrist-worn wearable sensor validation over different conditions.	MENGHINI <i>et al.</i>	2019
A novel method to monitor human stress states using ultra-short-term ECG spectral feature.	HWANG <i>et al.</i>	2017
Happy-anger emotions classifications from electrocardiogram signal for automobile driving safety and awareness.	MINHAD; ALI, REAZ.	2017


Embedded Emotion Recognition System Based on Electrocardiogram Attributes.	HENIA., LACHIRI.	2018
Automatic ecg-based emotion recognition in music listening.	HSU <i>et al.</i>	2017
Heart rate variability signal features for emotion recognition by using principal component analysis and support vectors machine.	GUO <i>et al.</i>	2016
Emotion recognition employing ECG and GSR signals as markers of ANS.	DAS; KHASNOBISH; TIBAREWALA.	2016

Fonte: Dados da pesquisa (2020).

Dessa forma, o ECG é conhecido como um método convencional utilizado para a interpretação da atividade elétrica do coração em tempo real, de forma não invasiva. Dessa forma, o ECG apresenta utilidade não apenas para analisar a atividade cardíaca, mas também para o reconhecimento de emoções, visto que o coração apresenta ligação com o sistema nervoso central (GOSHVARPOUR, ABBAS, 2017).

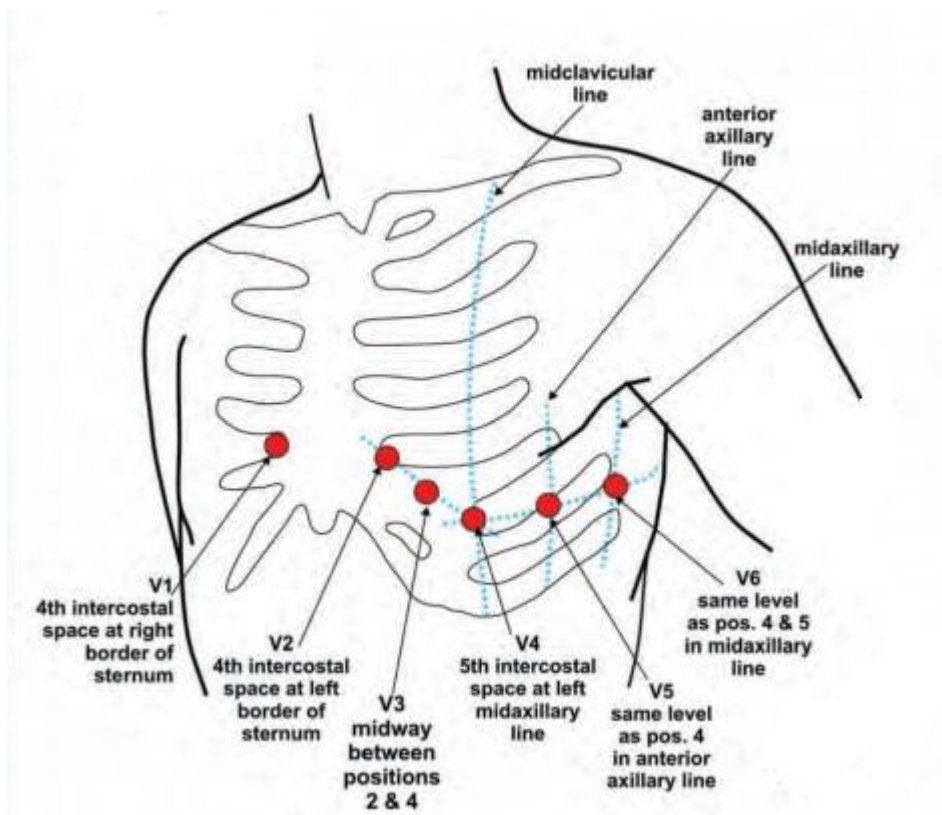
Assim, a técnica mais comum utilizada é do ECG de 12 derivações, são aplicados nove sensores no corpo, distribuídos em três sensores principais: no braço esquerdo (LA), no braço direito (RA) e na perna esquerda (LL). Sendo a perna direita (RL) utilizada como terra para os demais sensores que estão interconectados, conectada apenas com um fio (DZEDZICKIS, KAKLAUSKAS, BUCINSKAS, 2020). (Figura 6), (Figura 7).

Figura 6 - Derivações de ECG



Fonte: (DZEDZICKIS, KAKLAUSKAS, BUCINSKAS, 2020).

Figura 7 - Derivações de ECG no tórax



Fonte: (BAROLD, STROOBANDT, SINNAEVE, 2010).

Deste modo, na área médica esse método é conhecido como ECG de três derivações, apresentando utilidade em casos de emergência que necessitam que a análise seja realizada com mais rapidez, porém apresenta desvantagem pela falta de informação em relação às outras partes do coração. Por isso, para obtenção de uma resolução mais alta é necessário à utilização de seis sensores (V1-V6), adicionados ao peito. Esses sensores também servem para aterrar (G) na perna direita (RL). Dessa forma, a interconexão para o ECG de 12 derivações juntamente com os nove sensores, fornece doze sinais, que são conhecidos em termos biomédicos como: derivação (I, II, III, aVR, aVL, aVF, V1, V2, V3, V4, V5 e V6) (DZEDZICKIS, KAKLAUSKAS, BUCINSKAS, 2020) (Figura 5).

Figura 8 - Variações no eletrocardiograma



Fonte: (DZEDZICKIS, KAKLAUSKAS, BUCINSKAS, 2020).


Assim, os pontos considerados mais importante no sinal de ECG, são os picos (P, Q, R, S, T e U), devido a sua relação com a atividade cardíaca e suas características próprias (KHATIB *et al.* , 2007). Comumente, esses parâmetros de pico são utilizados com finalidade médica, para identificar parâmetros de desvio e atividade cardíaca anormal. Dessa forma, quando se trata de identificação do emocional, o complexo QRS é o mais utilizado, pois ele define a ativação do coração na relação com o estado emocional humano, sendo considerado um indicador no reconhecimento das principais emoções. Por outro lado, esse indicador apresenta dificuldades por possuir uma sensibilidade variante de acordo com emoções específicas (DZEDZICKIS, KAKLAUSKAS, BUCINSKAS, 2020).

Desse modo, para a aplicação de ECG no reconhecimento das emoções, são necessárias técnicas sofisticadas para o processamento de sinais, que permitam a detecção e a extração dos parâmetros do sinal bruto. Assim, para a grande maioria das técnicas de extração do complexo QRS, é necessário que inicialmente seja definido o pico de P ou R, para que o sinal seja estimado por esses picos, visto que o sinal é estável (DZEDZICKIS, KAKLAUSKAS, BUCINSKAS, 2020).

De acordo com (KHATIB *et al.*, 2007), o método mais utilizado pela área médica é o ECG de 12 derivações, pois o coração pode ser visualizado de forma tridimensional, que permite a identificação de qualquer anormalidade que possa não aparecer nas técnicas de ECG de 3 ou 6 derivações. Porém, o ECG de 12 derivações apresenta desvantagem, por produzir grandes quantidades de dados, principalmente quando utilizados por longas horas, o que dificulta na análise dos resultados que se tornam muito extenso.

Dessa forma, os eventos elétricos que acontecem durante os batimentos cardíacos, são caracterizados por ondas (figura 6), sendo elas:


Figura 9 - Ondas do Ciclo Cardíaco



Fonte: (JUNQUEIRA, 2015).

- **Onda P:** é a onda que primeiro é registrada em qualquer derivação do ECG, representa a despolarização dos átrios, ocorre de forma dupla, pois registra a atividade de cada átrio em uma onda única (REIS *et al.*, 2013). (Figura 7).

Figura 10 - Representação da Onda P



Fonte: (REIS *et al.*, 2013).

A duração dessa onda é mais bem obtida na derivação II (DII) e tem relação mais direta com a idade. Em crianças (**0,06 – 0,09s**), em adultos (**0,08 – 0,11s**) e são consideradas patológicas quando apresentarem os seguintes valores (> 0,09 para menores de 10 anos de idade, > 0,10s entre indivíduos de 10 a 15 anos e 0,11 s em adultos) (REIS *et al.*, 2013).

Assim, temos que em relação a amplitude da onda P, ela apresenta voltagem normal quando atingir valores entre **0,25 mV e 0,30 mV** (avaliada em DII). E a polaridade das ondas P na superfície corporal, podem ser registradas de forma positiva ou negativa, depende da forma que o eletrodo explorador está disposto, podendo ser positiva nas derivações (DI, DII e DIII) e negativa em aVR, enquanto que as demais vão depender da idade de cada indivíduo (REIS *et al.*, 2013).

Intervalo PR: Ocorre no início da onda P até o início do complexo QRS, que se caracteriza pelo tempo da condução no nó AV. Esse intervalo tem sua variação de acordo com a idade e a FC do indivíduo, sendo mais curto em crianças e maior em idosos. Os valores referências são 0,20 s para adultos como valor máximo e mínimo de 0,12s, e as crianças o valor mínimo é de 0,09 s (REIS *et al.*, 2013).

Complexo QRS: Caracteriza-se por despolarização ventricular, apresentando morfologia pontiaguda, com duração normal entre 0,05 e 0,11s, e uma média de 0,7 s. A amplitude desse complexo é variável e depende das condições cardíacas e

extracardíacas do indivíduo, podendo sofrer influência de patologias como obesidade, enfisema pulmonar, miocardiopatia dilatada, derrames pericárdicos, essas situações podem levar ao registro de baixa voltagem desse complexo. A polaridade se apresenta positiva em regiões ântero esquerdas e pósteras esquerdas do tórax, e negativa à direita do precórdio e em regiões que se aproximam do ombro direito (REIS *et al.*, 2013).

Segmento ST: Esse seguimento é observado no final do complexo QRS e ao iniciar a onda T, apresentando caráter isoelétrico, com um desnivelamento máximo de 1 mm (REIS *et al.*, 2013).

Onda T: Nessa onda ocorre a repolarização dos ventrículos, no mesmo sentido da ativação ventricular. Em relação a duração da onda T, está embutida no cálculo do intervalo QT. Apresenta morfologia arredondada e assimétrica, com a primeira porção mais lenta que a segunda. Com amplitude menor que o complexo QRS, com valores abaixo de 6 mm nas derivações inferiores. A polaridade positiva em grande parte das derivações, porém em algumas situações especiais adotam um caráter não patológico e diferente (REIS *et al.*, 2013).

5.2.1 Trabalhos envolvendo Eletrocardiograma

Brás *et al.* (2018) estudaram a identificação biométrica e das emoções por meio de um método baseado em compressão de ECG, utilizando o equipamento **Biopac Systems MP100**. Visando investigar emoções de medo, nojo e emoções neutras. Utilizaram como recursos:

- ✓ *Understanding methods (Kolmogorov Complexity);*
- ✓ *Data mining techniques without parameters;*
- ✓ *NRC measurement;*
- ✓ *Algorithm KNN*

Os participantes da pesquisa foram estimulados com filmes e o equipamento foi aplicado no **braço direito, perna esquerda e na perna direita**. Foram obtidos como resultados 98% de precisão na identificação biométrica e 90% no reconhecimento de emoções (BRÁS *et al.*, 2018).

Goshvarpour, Abbasi e Goshvarpour (2017) obtiveram na pesquisa um sistema de reconhecimento de emoção que utilizava sinais de ECG, GSR e o método de busca de correspondência. Foi utilizado o equipamento **PowerLab de 16 canais**. Como recursos:

- ✓ *Feature extraction;*
- ✓ *Probabilistic neural network (PNN);*
- ✓ *Algorithm Matching Pursuit (MP);*
- ✓ *Traditional linear techniques;*
- ✓ *Global non-linear approach;*
- ✓ *Wavelet coiflets (Coif5) at level 14;*
- ✓ *Wavelet Daubechies (db4) at level 8.*

Os participantes do estudo foram estimulados com música com a finalidade de identificar emoções como: tranquilidade (baixa excitação e valência positiva), felicidade (alta excitação e valência positiva), tristeza (baixa excitação e valência negativa) e assustadora (alta excitação e valência negativa). Obtiveram como resposta 100% de reconhecimento para todos os dicionários (ECG) e 94,48% para 3 A (dimensão de excitação, que inclui excitação positiva, excitação negativa e condição de repouso), 94,55% de 3V (dimensão de valência, incluindo agradável, desagradável e doença) e 92,52% de 5C (dimensão excitação- valência: felicidade, tristeza, medo, paz e descanso) que foram alcançadas usando Coif5 (Goshvarpour, Abbasi, Goshvarpour, 2017).

Katsigiannis e Ramzan (2017) utilizaram um banco de dados para reconhecer as emoções por meio de sinais de ECG e EEG de dispositivos sem fio e de baixo custo, sendo eles o **Emotiv Epoc Systems (aplicação de eletrodos/ Sistema 10 - 20)** e o **Shimmer3 ECG**.

Os bancos de dados utilizados foram: **DREAMER, DEAP, MAHNOB-HCI, DECAF**.

Os principais recursos foram:

- ✓ *Method Artefact Subspace Reconstruction (ASR);*
- ✓ *Algorithm de detection QRS Pan-Tompkins;*
- ✓ *Support Classificador Vector Machine (SVM);*
- ✓ *Kernel.*

Visando reconhecer as emoções: diversão, excitação, felicidade, calma, raiva, nojo, medo, tristeza, surpresa, por meio do estímulo com filmes. Assim, os

resultados evidenciaram o reconhecimento de 61,84% de precisão, 62,32% de excitação e 62,49% de valência (Katsigiannis, Ramzan, 2017).

Valderas et al. (2019) estudaram as informações sobre a variabilidade da frequência cardíaca e a respiração para caracterizar as emoções. Utilizaram o equipamento **Biopac Systems MP100** e os **algoritmos AMIF e CMIF**, para identificar as emoções de alegria, medo, raiva, tristeza que foram estimulados por meio de vídeos. Dessa forma, obtiveram como resultados uma especificidade e uma precisão de 70% e um reconhecimento das emoções com um uma significância de $p \leq 0,05$, que significa estatisticamente uma probabilidade de apenas 5% de que a diferença encontrada no estudo não seja verdadeira.

Goshvarpour, Abbasi e Goshvarpour (2017) estudaram a fusão de variabilidade de frequência cardíaca e a variabilidade de frequência de pulso para reconhecimento de emoção usando gráficos de Poincaré defasados. Os participantes foram avaliados por meio do equipamento **PowerLab** e os recursos utilizados foram:

- ✓ *Poincaré indexes;*
- ✓ *Suporte Classificador Vector Machine (SVM);*
- ✓ *Time series HRV (Heart rate variability);*

As emoções de felicidade, tristeza e medo, foram estimuladas com músicas. Dessa forma, foi possível obter precisões médias de:

- ✓ 84,1% obtidos para medições de variabilidade de taxa de pulso;
- ✓ 82,9% obtidos para medições de nível de decisão;
- ✓ 79,68% obtidos para medições de fusão de nível de recurso;
- ✓ 76,05% obtidos para medições de variabilidade de frequência cardíaca;

Dessa forma, as taxas de transmissão melhoraram em até 92% (com sensibilidade de 95% e especificidade de 83,33%).

MA et al. (2018) estudaram as respostas eletrocardiográficas e eletrooculográficas às emoções externas e suas transições nos transtornos bipolares I e II. Utilizaram o **Biopac Systems MP150** (ECG: Dois eletrodos foram afixados no braço direito e na perna esquerda, e o eletrodo terra foi colocado na perna direita. EOG: Canto de cada olho) e o **Software AcqKnowledge** e como estímulos as imagens (*International Affective Picture System - IAPS*) e sons no *International Affective Digitized Sounds*, para alcançar emoções como: nojo, erótica.

Dessa forma, apresentaram como resposta o movimento do globo ocular mais rápido em BD I (transtorno bipolar I) sob a felicidade do alvo após a aversão ao fundo; em BD I sob o alvo de tristeza após nojo de fundo; e em BD I sob aversão de fundo após alvo neutro. Algumas alterações eletrocardiográficas e eletrooculográficas foram correlacionadas com estados afetivos nos pacientes. BD I e BD II (transtorno bipolar II) tiveram diferentes respostas fisiológicas às emoções externas e suas transições, indicando diferentes fisiopatias e sugerindo diferentes terapias emocionais para BD I e BD II.

Dissanayake et al. (2019) propuseram uma abordagem de aprendizagem em conjunto para o reconhecimento de emoções humanas com base no sensor de eletrocardiograma. Para o estudo foi utilizado um **sensor de coração e cérebro Spiker-Shield**. E como recursos:

- ✓ *PQRST detection algorithm;*
- ✓ *Poincaré plots;*
- ✓ *Welch method;*
- ✓ *Random Forest Classifier;*
- ✓ *Extra tree classifier;*
- ✓ *Gradient increase classifier;*
- ✓ *ADABOOST classifier;*
- ✓ *SVM (Support Vector Machine);*
- ✓ *ADABOOST classifier with decision tree;*
- ✓ *ADABOOST classifier with Naive Bayes;*
- ✓ *Recursive Elimination of Resources;*
- ✓ *Selection of resources by random forest classifier;*
- ✓ *Selection of resources by extra tree classifier;*
- ✓ *Selection of resources by random SVM;*
- ✓ *Selection of resources by random SVM;*
- ✓ *Grid Search algorithm;*

Os participantes da pesquisa foram estimulados com vídeos, visando reconhecer as emoções de alegria, tristeza, prazer, raiva, medo e neutro. Dessa forma, obtiveram como resultados 75,11% no reconhecimento da raiva, medo e tristeza e 56,7% no reconhecimento de alegria e prazer.

Wu et al. (2019) estudaram como a diversão, raiva e o medo podem influenciar na frequência cardíaca e na variabilidade da frequência cardíaca,

utilizaram o equipamento **eego MyLab** (eletrodos aplicados no pulso esquerdo e tornozelo esquerdo) e o **Software E- prime**, e os participantes foram estimulados por meio de vídeos, com o objetivo de identificar as emoções irritadas, medrosas, divertidas e neutras. Dessa forma, como resultado o estado de entretenimento, a frequência cardíaca é significativamente mais baixa do que a frequência cardíaca em caso de raiva, medo e neutralidade. Não há diferenças significativas entre as três últimas condições. A raiz quadrada da média da diferença de continuidade é um indicador da variabilidade da frequência cardíaca (VFC), que é muito maior em condições de entretenimento do que em medo, neutralidade e raiva. A situação de raiva é muito maior do que a situação de medo. Não há diferença significativa entre medo e neutralidade e raiva e neutralidade. Esses resultados indicam que: (1) o prazer ativa o sistema nervoso parassimpático e (2) a raiva tem mais probabilidade de estar relacionada à ativação parassimpática do que o medo. Sugerindo que a VFC seja considerada um indicador potencial para distinguir emoções relacionadas à aproximação ou evitação da motivação, ao invés da dimensão de valência (ou seja, positiva ou negativa).

Kaczmarek et al. (2019) investigaram os efeitos das emoções na assimetria da frequência cardíaca. As emoções estudadas foram à felicidade, medo, tristeza, raiva, nojo, surpresa, por meio de estímulos de vídeo. Utilizando o equipamento **PowerLab** (aplicação de eletrodos de superfície Ag / AgCl no tórax) e como recurso a modelagem multinível. Assim, as emoções positivas produziram um maior número de desacelerações na variabilidade em curto prazo, à variabilidade total em curto prazo em comparação com as emoções negativas.

Tiwari et al. (2019) proporam um estudo comparativo de estimativa de estresse e ansiedade em ambientes ecológicos usando uma camisa inteligente e uma pulseira inteligente. Assim, foram utilizadas a camiseta inteligente **OMsignal** e uma pulseira inteligente **Fitbit Charge 2** e como recursos o classificador de árvores extra, classificador SVM. Dessa forma, conclui-se que os recursos calculados a partir de dados OMsignal foi mais eficaz para prever ansiedade e estresse, porém, ao combinar recursos de OMsignal e Fitbit observou-se melhorias na previsão de ansiedade, o que sugeriu que são equipamentos úteis para caracterizar o comportamento da atividade cardíaca.

Ferreira et al. (2017) construíram um classificador automático de emoções a partir da entropia do ruído, utilizando o equipamento **Biopac Systems MP100**

(aplicação dos eletrodos braço direito, perna esquerda e na perna direita) e os recursos:

- ✓ *Entropy measurement;*
- ✓ *Decision tree;*
- ✓ *Gini diversity index.*

Os participantes da pesquisa foram estimulados por meio de filmes para o surgimento de emoções como nojo, medo e neutro. Dessa forma, o classificador obteve 73,40% de sensibilidade e 86,70% de especificidade para o reconhecimento das emoções.

Landreani et al. (2019) avaliaram os índices de variabilidade cardíaca ultracurtos que são derivados de acelerômetros de smartphones para detecção de estresse. Assim, foi utilizado o monitor Nexfin HD ECG e algoritmos Pan-Tompkins, SDNN (Desvio Padrão de Normal para Normal de intervalos R-R), RMSSD (raiz quadrada média de sucessivas diferentes dos intervalos R-R), para estimar variabilidade de frequência cardíaca e frequência cardíaca.

Os participantes foram colocados em situação de estresse. Dessa forma, foram obtidos como resultados que a viabilidade de extração da série de batimentos cardíacos foi de 93,8% e a sensibilidade do algoritmo de 98,3% e 98%, respectivamente, com alta precisão (98%) alcançada (ANDREANI *et al.*, 2019).

Menghini et al. (2019) validaram um sensor vestível usado no pulso em diferentes condições, para isso utilizaram a pulseira **E4 Empatica** e como recursos FlexComp, software Biograph Infiniti, IBI séries temporais, **algoritmo KNN**. Os participantes realizaram os testes para validação: descansando, sentado, respiração com ritmo, posição ortostática, caminhada lenta, digitação de teclado, tarefa stroop, tarefa de fala. Dessa forma, foi concluída que o dispositivo E4 fornece média precisa de medidas de frequência cardíaca em condições estáticas e dinâmicas e medidas de VFC em repouso, respiração estimulada e em condições de recuperação.

Hwang et al. (2017) propõem um novo método para monitorar os estados de estresse humano usando o recurso espectral de ECG de ultracurto prazo. Foi utilizado o equipamento **Biopac MP36** e os recursos foram:

- ✓ *Kneighbors;*
- ✓ *SVM Linear;*
- ✓ *Naive Bayes;*
- ✓ *SVM;*

- ✓ *Gaussian Process;*
- ✓ *Decision tree;*
- ✓ *Forest Random Forest;*
- ✓ *Neural network;*
- ✓ *AdaBoost;*

Obtendo uma precisão média de 81,16% utilizando o classificador Naïve Bayes, para identificação do estresse.

Minhad, Ali e Reaz (2017) estudaram a classificação de emoções de raiva e felicidade por meio do sinal de eletrocardiograma para segurança e consciência na direção de automóveis, foi utilizado como recursos:

- ✓ *Schachter and Singer factors;*
- ✓ *Circum Russell's circumplex model;*
- ✓ *SVM;*
- ✓ *Algorithm KNN;*
- ✓ *Gaussian Classifier;.*

Para estímulo foi usando músicas, vídeos e imagens (IAPS). Dessa forma, a máquina de vetor de suporte apresentou sucesso para classificar emoções de raiva e felicidade com precisão de 83,33% quando ocorreu estímulo audiovisual e recuperação de raiva e felicidade de 90,91%. Os resultados deste trabalho mostram que o ECG pode ser usado como uma alternativa para procedimentos de teste auto-reflexivos automáticos ou fonte adicional com a qual valida o estado emocional de um motorista enquanto estava em um automóvel.

Henia e Lachirl (2018) criaram um sistema integrado de reconhecimento de emoções baseados em atributos de eletrocardiograma, para isso utilizaram os recursos:

- ✓ SVM;
- ✓ Raspberry Pi 3;
- ✓ DiscretWavelet Transform (DWT);
- ✓ Tool Pylint;
- ✓ Database MAHNOB-HCI;

Apresentaram como resultados: 75,51% de excitação e 72,91% de valência.

Hsu et al. (2017) estudaram o reconhecimento automático de emoção baseado em ECG na audição de música. Dessa forma utilizaram o equipamento NeXus-10 com Biotrace e os recursos:

- ✓ *Generalized discriminant analysis (GDA);*
- ✓ *Resource reduction and least squares method of door vector machine (LS-SVM) sup-classifiers;*
- ✓ *SDNN;*
- ✓ *RMSSD;*
- ✓ *Quick Fast Fourier Transform (QFFT);*
- ✓ *Poincaré.*

Visando o reconhecimento de emoções como: Maravilha, transcendência, poder, ternura-saudade, nostalgia, paz, alegria, tristeza e tensão por meio de estímulos com música. Desse modo, foram obtidas taxas de classificação corretas de 82,78% de valência (positivo / negativo), 72,91% de excitação (alta / baixa) e 61,52% para quatro tipos de tarefas de classificação de emoção.

Guo et al. (2016) estudaram os recursos de sinal de variabilidade de frequência cardíaca para reconhecimento de emoção usando análise de componentes principais e máquina de vetores de suporte. Com o uso de recursos como:

- ✓ *Medium average RRI;*
- ✓ *CVRR: coefficient of variation (CV) of RR intervals;*
- ✓ *SDRR: standard deviation of RR intervals;*
- ✓ *SDSD: standard deviation of successive differences in RR intervals;*
- ✓ *Fast Fourier transformation (FFT) methods;*
- ✓ *SVM*

As emoções de raiva, medo, tristeza, felicidade e relaxamento foram estimulados por meio de vídeos. As emoções positivas foram classificadas com uma precisão de 71,4% positiva e negativa de 56,9 %.

Das, Khasnobish, Tibarewala (2016) investigaram o reconhecimento de emoções empregando sinais de ECG e GSR como marcadores de ANS, utilizando os recursos:

- ✓ *Frequency domain;*
- ✓ *Welch's Power;*
- ✓ *Spectral density;*
- ✓ *Time domain resource;*
- ✓ *Happy Happy-Sad (HS) instances;*
- ✓ *Happy-Neutral (HN);*

- ✓ *Sad-Neutral (SN) instances;*
- ✓ *SVM classifiers;*
- ✓ *Naive Bayes;*
- ✓ *K-Nearest Neighbor,*
- ✓ *KNN algorithm.*

Dessa forma, as emoções feliz, triste e neutro foram estimuladas por meio de vídeos. Os resultados indicam que classificar a emoção de valência oposta (feliz e triste) por meio do GSR apenas é capaz de reconhecer emoções com maior precisão com uma precisão mínima de 99,44%. No entanto, ao classificar estado emocionalmente ativo (feliz ou triste) em referência ao estado neutro, conjunto de recursos combinados de ECG e GSR é mais eficaz.

Assim, a busca por recursos tecnológicos para identificar emoções por meio do eletrocardiograma na presente pesquisa, retornou 10 produtos (Tabela 6).

Tabela 6 - Tabela de equipamentos ECG

Recurso Tecnológico	Empresa Responsável
<i>PowerLab</i>	<i>ADInstruments</i>
<i>Shimmer3 ECG</i>	<i>Shimmer Discovery in emotion</i>
<i>Biopac System MP100</i>	<i>Biopac</i>
<i>Biopac System MP150</i>	<i>Biopac</i>
<i>Biopac System MP36</i>	<i>Biopac</i>
<i>eego MyLab</i>	<i>Ant Neuro</i>
Camiseta inteligente <i>OMsignal</i>	<i>OMsignal</i>
Pulseira inteligente <i>Fitbit Charge 2</i>	<i>Fitbit</i>
Pulseira E4 Empatica	<i>Empatica</i>
(ECG, monitor Nexfin HD, BMEYE)	<i>Nexfin</i>

Fonte: Dados da pesquisa (2020).

Dentre os equipamentos mais apresentados nos estudos estão o **PowerLab** e o **Biopac MP100**. O **PowerLab** é um dispositivo de aquisição de dados (DAQ), que detecta sinais simultaneamente por meio de vários dispositivos e transdutores, em frequências de amostragem ajustáveis (ADINSTRUMENTS, 2020).

Figura 11 - PowerLab



Fonte: (ADINSTRUMENTS, 2020).

O **MP100** apresenta um microprocessador interno que controla a aquisição de dados e a comunicação com o computador. Dessa forma, existem 16 canais de entrada analógica, nos quais dois canais são de saída analógica, e 16 canais digitais que são utilizados para qualquer entrada ou saída e uma entrada de acionamento externo (BIOPAC, 2020).

Figura 12 - MP100



Fonte: (BIOPAC, 2020)

Os demais equipamentos apresentados são (**Shimmer 3 ECG**, **Biopac MP150**, **MP36**, **eego MyLab**, **Camiseta inteligente OMsignal**, **pulseira inteligente Fitbit Charge 2**, **Pulseira E4 Empatica**, **ECG monitor Nexfin HD**). A seguir estão as informações sobre os equipamentos:

O recurso **Shimmer 3 ECG**, apresenta um *front-end* digital configurável para medir sinais fisiológicos de ECG. O sensor desse equipamento faz o registro do caminho percorrido pelos impulsos elétricos por meio do músculo cardíaco, capaz de ser registrado na posição de repouso, durante o exercício e em pacientes ambulatoriais (SHIMMER, 2020).

Os benefícios desse recurso são: ECG com cinco fios e quatro derivações, que mede derivações de membros bipolares e V1-V6. A interface digital possui uma geração de sinal de teste para fins de validação. Possui a capacidade de detectar movimentos inerciais de 10 DoF. Além disso, apresenta uma plataforma Consnesys, em que todos os sinais podem ser mensurados em tempo real e simultaneamente, os dados podem ser transmitidos ao vivo, e os dados brutos são registrados em um cartão SD para serem processados posteriormente (SHIMMER, 2020).

Figura 13 - Shimmer ECG



Fonte: (Shimmer, 2020).

O **eego mylab** foi projetado com recursos de softwares fáceis de usar para experimentos simples e complexos, contando com fluxo de trabalho de gravação passo a passo, gerenciamento de entrada de assunto, verificação de impedâncias,

revisão de dados online, gravação de vídeo sincronizada e muito mais (ANTNEURO, 2020).

Figura 14 - Eego mylab



Fonte: (ANTNEURO, 2020).

A **pulseira E4** é um dispositivo vestível que oferece aquisição de dados fisiológicos em tempo real, que permite a condução de análises e visualizações aprofundadas. Apresenta uma memória interna que grava até 36 horas com resolução de sincronização de 5s (EMPATICA, 2020).

Figura 15 - Pulseira E4



FONTE: (EMPATICA, 2020).

O **monitor Nexfin HD** é um dispositivo que mensura o débito cardíaco (DC) continuamente, de forma não invasiva aplicados no punho (EARLE, 2015).

Figura 16 - Monitor Nexfin HD



FONTE: (SPRINGER, 2020).

O **MP150** e o **MP36** são sistemas de aquisição de dados completo que permite registrar, visualizar, salvar e imprimir dados (BIOPAC, 2020).

Figura 17 - MP150



Fonte: (BIOPAC, 2020).

Figura 18 - MP36



Fonte: (BIOPAC, 2020).

O estudo também mostrou que os principais locais de aplicação do ECG são feitos no **braço direito, perna esquerda e perna direita**. Em relação aos algoritmos principais estão: ***algorithm KNN, algorithm Matching Pursuit, SMV e algorithm Pan Tompkins***.

O ***algorithm KNN*** foi criado por meio de inteligência artificial de agrupamento, em que classifica ou agrupa itens semelhantes utilizando a distância euclidiana (SOUZA, 2019).

O ***algorithm Matching Pursuit (MP)*** se caracteriza por ser um algoritmo de aproximação esparsa para encontrar a melhor correspondência de dados multidimensionais (SOUZA, 2019).

O ***SVM*** são modelos de aprendizagem de máquina, que são supervisionados por algoritmos de aprendizagem que analisam os dados utilizados (SOUZA, 2019).

O ***algorithm Pan - Tompkins*** é utilizado para detectar o complexo QRS em sinais eletrocardiográficos. Uma série de filtros é aplicada para destacar o conteúdo da frequência dessa rápida despolarização cardíaca e eliminar o ruído de fundo. Em seguida, ele alinha os sinais para amplificar a contribuição do QRS. E por fim, aplica limites adaptativos para detectar picos no sinal filtrado (PAN, TOMPKINS, 1985).

E os bancos de dados mais relevantes são: **Dreamer, Deap, Mahnob-HCI, Decaf**.

O **Dreamer** é um banco de dados multimodal que é constituído por sinais de eletroencefalograma (EEG) e eletrocardiograma (ECG), que são registrados durante a elicitacão de afeto por meio de estímulos audiovisuais (KATSIGIANNIS, RAMZAN, 2017).

O **Deap** é um conjunto de dados multimodal para a análise dos estados afetivos humanos (KOELSTRA, 2012). O **MAHNOB-HCI** é um banco de dados multimodal registrado em resposta a estímulos afetivos com o objetivo de reconhecimento de emoção e pesquisa de marcação implícita (SOLEYMANI *et al.*, 2011).

O **Decaf** é um conjunto de dados multimodais decodificados para respostas fisiológicas do usuário utilizando conteúdo multimídia afetivo (ABADI *et al.*, 2015).

Dessa forma, a utilização do eletrocardiograma apresenta algumas vantagens e desvantagens para identificar o emocional (Tabela 7).

Tabela 7 - Vantagens e desvantagens do ECG

Eletrocardiograma (ECG)		
Vantagens	Desvantagens	Possibilidade de uso em Teste de Usabilidade
<ul style="list-style-type: none"> • Amplitude mais alta que outros sensores. • Sinais capturados em várias partes do corpo. • Podem ser utilizados em dispositivos vestíveis. 	<ul style="list-style-type: none"> • O ECG de 12 derivações apresenta grandes quantidades de dados, por longas horas, dificulta a análise dos dados por serem muito extensos. • Uso de muitos eletrodos e fios, o que limita a movimentação. • Cintos apresentam desconforto no uso, além de aumentar a relação sinal- ruído por se apresentarem perto do coração. 	Movimento e/ou Estático

Fonte: (Dados da pesquisa, 2021).

5.3 Termografia

Foram utilizadas as seguintes palavras-chave: **“Thermography AND emotion”**. E foram retornados 6 artigos, explanados na tabela 8.

Tabela 8 - Artigos de termografia

Thermal Infrared Imaging to Evaluate Emotional Competences in Nursing Students: A First Approach through a Case Study.	MARQUÉS-SÁNCHEZ <i>et al.</i>	2020
--	-------------------------------	------

Emotion analysis in children through facial emissivity of infrared thermal imaging.	GOULART <i>et al.</i>	2019
A methodology based on infrared thermography for the study of stress in hands of young people during the Trier Social Stress Test.	CRUZ-ALBARRAN <i>et al.</i>	2018
Infrared thermography processing to characterize emotional stress: a pilot study.	MARISCAL <i>et al.</i>	2017
The mental and subjective skin: Emotion, empathy, feelings and thermography.	SALAZAR-LÓPEZ <i>et al.</i>	2015
The autonomic signature of guilt in children: a thermal infrared imaging study.	Ioannou <i>et al.</i>	2015

Fonte: (Dados da pesquisa, 2020).

O ser humano é considerado homeotérmico, pois consegue manter a temperatura corporal relativamente constante, para que esse fenômeno ocorra é necessário que seja perdido calor para o ambiente. Dessa forma, a pele possui a função de ser um órgão de interface entre o ambiente e a produção de calor, pois é responsável por equilibrar as condições internas e externas. Desse modo, o controle dessa transferência de calor, é conhecido como termorregulação e apresenta dependência do sistema nervoso autônomo para seu funcionamento (BRIOSCHI *et al.*, 2003).

Em vista disso, existem três mecânicos que participam da termorregulação: a condução, convecção e a radiação. Assim, a condução é o processo de transferência em dois meios com contato direto e a temperaturas diferentes, a convecção é a transferência de calor de um meio para o outro, por meio da movimentação de uma substância aquecida e a radiação é troca de calor durante o repouso por meio de raios infravermelhos. Dessa forma, os processos fisiológicos complexos também participam da transferência de calor como: transpiração, geração de calor metabólico e a circulação sanguínea (GUYTON; HALL, 2006).

Diante disso, o controle da temperatura interna do corpo, é realizado quando o hipotálamo ativa os sistemas termorregulatórios que realizam a manutenção da temperatura de regiões profundas em torno de 37°C (JOHNSON; MINSON; KELLOGG, 2014).

A termografia é um instrumento não invasivo e não radioativo, que analisa as funções fisiológicas do corpo que estão relacionadas ao controle da temperatura da pele. Dessa forma, a termografia age detectando a emissão de luz infravermelha pelo corpo e as mudanças de temperatura no mesmo, que estão relacionadas as alterações no fluxo sanguíneo (CÔRTE, HERNANDEZ, 2016).

Em vista disso, é possível a formação de imagens térmicas ou termogramas por meio de equipamentos como: câmeras termográficas ou termovisores. Assim, as câmeras termográficas possuem sensores elétricos e lentes especiais que capturam a emissão de radiação infravermelha, e produzem as imagens térmicas reproduzidas por meio da escrita térmica de um objeto ou de um corpo, que garante a análise de regiões com emissão de calor radiante maior ou menor, de forma diferente (BRIOSCHI, 2011; SILVA, 2012; DELGADO, 2013; HADDAD, 2014; RAJMANOVA *et al.*, 2015).

Assim, essas câmeras são constituídas por detectores de radiação eletromagnéticas, que capturam e fazem a transferência desses dados para um chip, essas informações são processadas e transformadas em imagem (RUDDOCK, 2010; COSTA, GUEDES, BAPTISTA, 2012; BATINJAN *et al.*, 2014). Os softwares de calibração desses equipamentos são utilizados para imagens termográficas e para mensuração de temperatura, são programadas para detectar comprimento de ondas infravermelho na faixa de onda curta (0,9-1,7 micron), onda média (2-6 micron) e onda longa (8-12 micron) (RUDDOCK, 2010).

Dessa maneira, a emissividade é caracterizada como a propriedade dos corpos que sofrem variação em função da temperatura (BRIOSCHI, 2011; RUDDOCK, 2010). Assim, a superfície corpórea realiza emissão de radiações eletromagnéticas na faixa de 9-10 microm (BRIOSCHI, 2011). Na pele saudável essa emissão está na faixa de 8-14 microm, sendo constante (BRIOSCHI, 2011; HADDAD, BRIOSCHI, ARITA, 2012).

Em vista disso, a termografia em humanos deve realizar a detecção em ondas eletromagnéticas de comprimento de onda longo (RING *et al.*, 2007; BRIOSCHI, 2011, HADDAD, BRIOSCHI, ARITA, 2012). Assim sendo, as câmeras termográficas conseguem identificar de 8 a 12 cores na paleta de cores, com imagens de 12 bits (RUDDOCK, 2010; BRIOSCHI, 2011). Dessa forma, é necessário que as câmeras para uso humano, possuam capacidade entre 320x240 a 1200x1200 (1,4 megapixel) (RUDDOCK, 2010; RING *et al.*, 2007).

Desse modo, existem fatores que podem influenciar nos resultados dos exames, como: fatores técnicos (protocolo, câmera, software, análise estatística), fatores ambientais (temperatura ambiente, umidade relativa do ar, pressão atmosférica, radiação, tamanho da sala de coleta) e fatores individuais (idade, sexo, ritmo circadiano, emissividade da pele, antropometria, uso de medicação e prática de exercícios físicos) (CÔRTE, HERNANDEZ, 2016).

Diante disso, para que possa utilizar a termografia em ambientes de testes é necessário segundo Brioschi *et al* (2011) seguir alguns requisitos básicos:

- ✓ A temperatura do local deve ser mantida constante em 22° C, umidade do ar em 55% e velocidade do ar menor que 0,2 m/s;
- ✓ A parte do corpo do voluntário a ser registrada deverá estar despida;
- ✓ O voluntário deverá esperar 15 minutos para estabilizar a temperatura do corpo com o clima do local;
- ✓ A câmera deverá estar posicionada e ajustada a linha mediana da região de interesse a ser avaliada;
- ✓ De preferência a sala não deve ter janelas para evitar a luz do sol e as lâmpadas devem ser fluorescentes
- ✓ O sujeito avaliado deve se manter parado, sem ingestão de álcool e cigarro, pois essas ações podem alterar a temperatura.
- ✓ As regiões de interesse (ROI) no rosto são: boca, ponta nasal, testa, bochechas e olhos (CÔRTE, HERNANDEZ, 2016).

Os estudos relacionados à termografia e emoções evidenciaram que na presença de uma emoção, ocorre uma mudança na temperatura facial, pela emissão de sangue pelo corpo até as áreas subcutâneas, que podem ser mensuradas por meio da termografia (IOANNOU *et al.*, 2015).

5.3.1 Trabalhos relacionados à termografia

Marqués-sánchez *et al.* (2020) avaliaram as competências emocionais de estudantes de enfermagem por meio de imagens infravermelha térmica. Utilizaram a **Câmera FLIR E6**, tendo como regiões de interesse a testa, o nariz e as bochechas esquerda e direita. Os participantes do estudo foram estimulados por meio de vídeos e música para obter o reconhecimento das emoções de felicidade, amor, alegria, raiva, medo e tristeza.

Assim, com o estímulo de vídeo, a temperatura inicial e final da testa nas fases de teste, mostrou um comportamento diferente entre positivo (alegria: 34,5 °C – 34,5°C) e negativo (raiva: 36,1 ° C – 35,1 ° C) emoções durante a fase de aclimação, diferente do aumento e experiente no estímulo (alegria: 34,7° C – 35,0 ° C e raiva: 35,0 ° C – 35,0 ° C) e nas fases de resposta (alegria: 35,0 ° C, 35.0 ° C e raiva: 34.8 ° C, 35.0 ° C). Com o estímulo musical, as emoções mostraram padrões diferentes em cada fase (alegria: 34,2° C, 33,9° C, 33,4 ° C e raiva: 33,8° C, 33,4° C, 33,8 ° C).

Goulart *et al.* (2019), analisaram as emoções em crianças por meio da emissividade facial de imagens térmicas infravermelhas. Para isso utilizou uma **Câmera de imagem térmica infravermelha Therm-App**, e os recursos:

- ✓ *ROIs (Regions of interest);*
- ✓ *Neighborhood component analysis method (NCA);*
- ✓ *Kernel function;*
- ✓ *Linear Discriminant Analysis (LDA);*

Assim, visando identificar emoções de felicidade, repulsa medo, tristeza e surpresa os participantes foram estimulados por meio de estímulos de vídeo. As áreas de interesse para extrair informações afetivas foram localizadas nas regiões da testa, ponta do nariz, bochechas, queixo, região periorbital e perinasal (ROIs). E obtiveram como resultado que o método de classificação baseado no LDA usado

para reconhecer cinco emoções (repulsa, medo, felicidade, tristeza e surpresa) atingiu precisão média de 85,25%. Especificamente, foram alcançados valores de precisão de 89,88% para nojo, 88,22% para felicidade, 86,93% para surpresa, 86,57% para medo e 74,70% para tristeza.

Cruz-albarran et al. (2018), estudaram uma metodologia baseada em termografia infravermelha para o estudo do estresse nas mãos de jovens durante o Trier Social Stress Test. O estudo utilizou uma **câmera FLIR A310**, e como regiões de interesse as pontas dos dedos e palmas das mãos. Assim, o nível de significância adotado para a análise dos resultados foi de 95%.

Mariscal et al., (2017), estudaram o processamento de termografia infravermelha para caracterizar estresse emocional, utilizando a **câmera FLIR T640**, e como recursos:

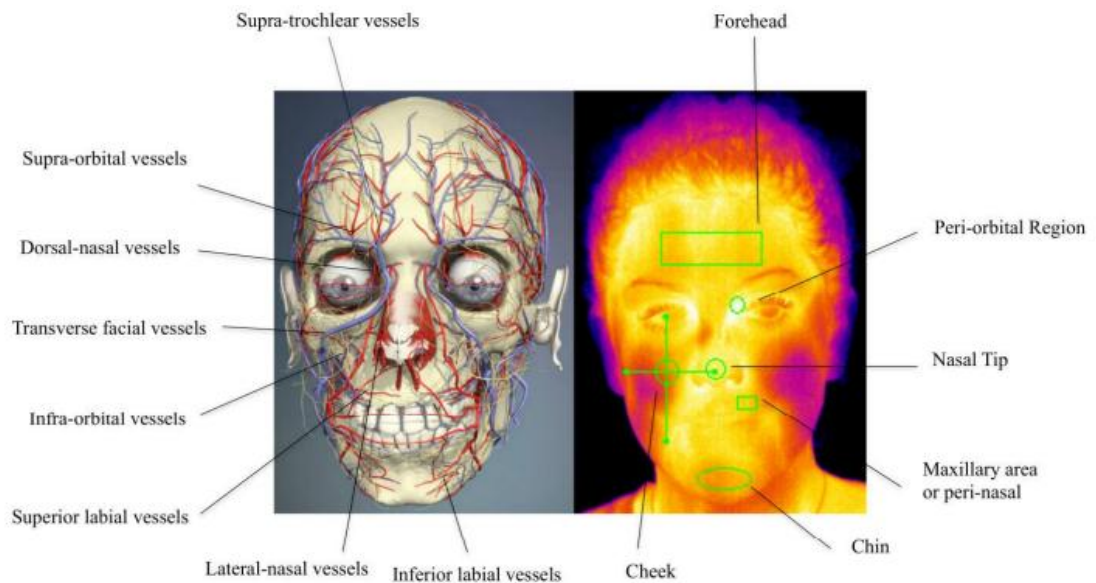
- ✓ *Growing hierarchical self-organizing maps (GHSOM).*,
- ✓ *Self-Organizing Maps (SOMs).*,
- ✓ *Chan-veese model.*

Dessa forma, as regiões de interesse foram o rosto, testa e nariz, os participantes foram estimulados por meio de vídeos e imagens, com a finalidade de identificar emoções de estresse. Assim, o grupo que sofreu queda de temperatura ao longo do tempo mostra um comportamento quadrático, enquanto o aumento é linear. O aumento na temperatura ocorreu enquanto o sujeito fez a maior parte dos erros.

Salazar-López et al. (2015), em que foi utilizado a termografia para identificar a neuropsicologia cognitiva das emoções, obtiveram como resultado uma mudança na temperatura do nariz, que teve diminuição de temperatura quando exposta a estímulos de valência negativa e aumento com padrões de excitação e emoções positivas. Assim, outras regiões como bochechas, testa e área orofacial sofreram alterações de temperatura. Concluindo no estudo que a região nasal quando apresenta alterações de temperatura estão correlacionadas à empatia e alegria.

Ioannou et al. (2015) afirmam que a termografia é utilizada nos estudos para identificação de emoções como culpa, empatia, vergonha, estresse, medo, ansiedade, dor e alegria e que as principais áreas para identificação dessas emoções estão localizadas na face, em regiões como: vasos periorbitários e supra orbitais da face, que estão associados ao músculo corrugador da testa e orbicular dos olhos, ponta do nariz, área maxilar e lábio superior. (Figura 19).

Figura 19 - Regiões vasculares afetadas pela temperatura subcutânea na face e captura da imagem térmica infravermelha



Fonte: (Ioannou *et al.* 2015).

A tabela 9 demonstra a alteração de temperatura de acordo com o estímulo emocional, as setas para cima indicam o aumento de temperatura, as setas para baixo indicam a diminuição de temperatura (IOANNOU, GALLESE E MERLA, 2015).

Tabela 9 - Direções das variações de temperatura, de acordo com o estímulo emocional

Emoções	Estresse	Medo	Assustado	Exciação Sexual	Ansiedade	Alegria	Dor	Culpa
Regiões								
Nariz	↓	↓		↑		↓		↓
Bochecha			↓					
Periorbital			↑	↑	↑			
Supraorbital			↑		↑			
Testa	↓↑	↓		↑			↓	
Maxilar	↓	↓					↓	↓
Carótida do Pescoço			↑					
Nariz	↓							
Cauda		↓					↓	
Dedos/Palmas		↓					↓	
Lábios/Boca				↑				

Fonte: (Ioannou *et al.*, 2015).

No presente estudo, os recursos tecnológicos em termografia que conseguem identificar o emocional são:

Tabela 10 - Tabela de Equipamentos Termografia

Recurso Tecnológico	Empresa responsável
Câmera de imagem térmica infravermelha Therm-App	Therm-App
Câmera FLIR E6	<i>Flir</i>
Câmera FLIR T640	<i>Flir</i>
Câmera FLIR A310	<i>Flir</i>

Fonte: (Dados da pesquisa, 2020).

A **câmera de imagem térmica infravermelha Therm-App** é um dispositivo clipado que se conecta ao smartphone Android para conectar o dispositivo e transformá-lo em uma câmera de visão noturna que pode exibir, registrar e compartilhar imagens térmicas, geralmente de forma segura para aplicações de segurança, aplicações agrícolas e observação de humanos e animais selvagens (ORMAX, 2020).

Figura 20 - Câmera Therm-App

Fonte: (ORMAX, 2020).

O **termovisor FLIR E6** possui uma função de detecção rápida que pode ajudar a identificar a temperatura e a sensibilidade térmica de até 0,06 ° C, apresenta lente de foco livre e um botão para navegar entre as opções de ajuste, modos de imagem, ferramentas de medição e imagens salvas. A bateria pode ser verificada por até 4 horas sem interrupção, e a bateria pode ser substituída de forma

rápida e fácil sem carregar. Ele pode ser carregado diretamente na câmera ou no carregador de bateria (HIGHMED, 2020).

Figura 21 - Termovisor FLIR E6



Fonte: (HIGHMED, 2020).

O **termovisor T640** da série T da Flir tem uma tela sensível ao toque, que é o software da própria Flir para comunicação entre a câmera e o PC. Sua resolução térmica é de 640 x 480 pixels, bem como um sistema de anotação, bússola, GPS e iluminação LED. O bloco ótico giratório pode apontar para cima e para baixo em 120°, foco automático e detecção da direção da câmera (AECWEB, 2020).

Figura 22 - Termovisor T640



Fonte: (AECWEB, 2020).

O **termovisor fixo FLIR A310** é uma solução inteligente para processos que requerem conexão e comunicação usando protocolos padrão. Esta câmera de imagem térmica pode ser instalada em qualquer lugar para monitorar seu processo, sendo muito adequada para qualquer indústria que necessite de equipamentos fixos de proteção contra incêndio, monitoramento crítico e manutenção preventiva (VORTEX, 2020).

Figura 23 - Flir A310



Fonte: (VORTEX, 2020).

Os estudos não evidenciaram algoritmos. E as regiões de interesse (ROIS) para extrair informações afetivas são localizadas nas regiões da testa, ponta do nariz, bochechas, queixo, região periorbital e perinasal.

Dessa forma, a utilização do eletrocardiograma apresenta algumas vantagens e desvantagens para identificar o emocional (Tabela 11).

Tabela 11 - Vantagens e desvantagens da Termografia

Termografia		
Vantagens	Desvantagens	Possibilidade de uso em Teste de Usabilidade
<ul style="list-style-type: none"> Não apresenta ruídos, como os outros sinais fisiológicos. Eficaz para identificar mudança de temperatura no emocional (A temperatura da pele nasal aumenta quando muda para estados mentais agradáveis e diminui quando muda para estados mentais desagradáveis). 	<ul style="list-style-type: none"> Limitação da detecção de apenas temperaturas superficiais dos objetos e sujeitos. Possíveis interferências das condições do ambiente nas medições térmicas. Dificuldade na interpretação das imagens de determinados materiais devido sua emissividade. 	Estático

Fonte: (Dados do estudo, 2020).

5.4 Taxa de respiração (RR)

Foram utilizadas as seguintes palavras-chave: **“Respiration rate analysis AND emotion”**. E foram retornados 1 artigo, detalhados na tabela 12.

Tabela 12 - Artigos RR

Human emotion characterization by heart rate variability analysis guided by respiration.	YAMUZA <i>et al.</i>	2019
--	----------------------	------

Fonte: (Dados da pesquisa, 2020).

O *biofeedback* respiratório captura as respirações por minuto, sua arquitetura e amplitude por meio de sensores colocados na pele. Sendo detectados através da pressão exercida quando acoplasse sensores no tórax e no abdômen, por meio do fluxo de ar nasal, plestismografia no pulso e eletromiografia dos músculos trapézio superiores e abdômen (SÁ, 2004).

Alguns desses sensores são colocados ao redor do tórax em forma de cinto, detectando os movimentos de inspiração e expiração. Eles podem apresentar desvantagens, pelo desconforto de realizar uma determinada atividade vestindo esse cinto e pela imprecisão dos sinais quando se busca a determinação de um evento em tempo preciso, pois podem apresentar reações com atraso (KUIKKANIEMI *et al.*, 2010) (Figura 23).

Figura 24 - Sensor de taxa de respiração (RR)



Fonte: (KUIKKANIEMI *et al.*, 2010).

Dessa forma, as informações de monitoramento respiratório também possuem dados sobre estados emocionais. Assim, a profundidade e a velocidade podem variar de acordo com a emoção humana, ou seja, quando a respiração é rápida e profunda a excitação é acompanhada por emoções como: raiva ou medo e alegria, quando é superficial e rápida demonstra tensão, ou seja, quando o indivíduo está relaxado a respiração é profunda e lenta, enquanto que a respiração superficial e lenta demonstra um estado negativo ou calmo (ZHANG *et al.*, 2017).

Desse modo, no estado calmo a respiração é de cerca de 20 -30 incursões por minuto e na excitação em torno de 40 - 50 incursões por minuto (ZHANG *et al.*, 2017). Assim, para que seja analisada a respiração, é necessário seguir alguns métodos, como:

- ✓ Avaliação manual ou semiautomática da frequência respiratória usando temporizadores simples ou especializados com aplicações de Software;
- ✓ Métodos baseados em medições de flutuação de umidade do ar no ar exalado;
- ✓ Métodos baseados em medições de flutuação de temperatura no ar exalado;
- ✓ Medições baseadas na definição da variação da pressão do ar devido à respiração;
- ✓ Métodos baseados em medições de variação da concentração de dióxido de carbono;
- ✓ Medições de variação da concentração de oxigênio;
- ✓ Métodos baseados em medidas de movimentos corporais;
- ✓ Métodos baseados em medições de sons respiratórios (ZHANG *et al.*, 2017).

5.4.1 Trabalhos relacionados à RR

YAMUZA *et al.* (2019) caracterizaram a emoção humana pela análise da variabilidade da frequência cardíaca guiada pela respiração. O estudo foi realizado utilizando o equipamento **BIOPAC MP100**, e o recurso do modelo de modulação de frequência de pulso integral (IPFM). Os participantes foram estimulados por meio de vídeos com a finalidade de provocar emoções de alegria, medo, raiva e tristeza. Dessa forma, a correlação máxima entre variabilidade de frequência cardíaca e espectro de respiração discriminou alegria versus relaxamento, alegria versus cada emoção de valência negativa e medo versus tristeza com valor de $p \leq 0,05$ e $AUC \geq 0,70$. Com base nesses resultados, a emoção humana pode ser mais bem reconhecida adicionando informações respiratórias à análise de variabilidade de frequência cardíaca.

No presente estudo, os recursos tecnológicos de RR que conseguem identificar o emocional são:

Tabela 13 - Tabela de Equipamentos RR

Recursos Tecnológicos	Empresa Responsável
<i>BIOPAC MP100</i>	<i>BIOPAC</i>

Fonte: (Dados da pesquisa, 2020).

O sistema de aquisição de dados **MP100** oferece uma ferramenta flexível para necessidades de ensino e pesquisa. O sistema de aquisição de dados pode ser usado com amplificadores e acessórios BIOPAC (LINTONINST, 2020).

Figura 25 - MP100

Fonte: (BIOPAC, 2020).

A base de dados que mais foi evidenciada no estudo foi o **DEAP**, que é um conjunto de dados multimodal para a análise dos estados afetivos humanos (KOELSTRA, 2012).

Não foram apresentados algoritmos na pesquisa. E o local de aplicação dos sensores do RR foram no tórax ou no abdômen.

Dessa forma, a utilização do eletrocardiograma apresenta algumas vantagens e desvantagens para identificar o emocional (Tabela 14).

Tabela 14 - Vantagens e desvantagens do RR

Taxa de respiração (RR)		
Vantagens	Desvantagens	Possibilidade de uso em Teste de Usabilidade
<ul style="list-style-type: none"> Quando o usuário está em uma determinada posição durante o monitoramento e não se movimenta muito, como no controle mecânico-técnico ou em operações de condução de carro. 	<ul style="list-style-type: none"> As desvantagens do uso de eletrodos de cinto, é o desconforto de realizar uma determinada atividade vestindo o cinto. Imprecisão dos sinais quando se busca a determinação de um evento em tempo preciso, pois podem apresentar reações com atraso. 	Movimento e/ou Estático

Fonte: (Dados da pesquisa, 2020).

5.5 Eletromiografia

Foram utilizadas as seguintes palavras-chaves: **“electromyography AND emotion”**. E foram retornados 7 artigos, explanados na tabela 15.

Tabela 15 - Artigos de Eletromiografia

Evidence of emotion-antecedent appraisal checks in electroencephalography and facial electromyography	COUTINHO <i>et al.</i>	2018
Recognition of intensive valence and arousal affective states via facial electromyographic activity in young and senior adults.	TAN <i>et al.</i>	2016

Affect dynamics of facial EMG during continuous emotional experiences.	GOLLAND <i>et al.</i>	2018
Mixed emotions to near-miss outcomes: A psychophysiological study with facial electromyography.	SHARMAN., CLARK.	2016
Emotion analysis using audio/video, EMG and EEG: a dataset and comparison study.	ABTAHI <i>et al.</i>	2018
Recognition of Emotion Through Facial Expressions Using EMG Signal.	MITHBAVKAR; SHAH.	2019
The potential of photoplethysmogram and galvanic skin response in emotion recognition using nonlinear features.	GOSHVARPOUR; GOSHVARPOUR.	2020

Fonte: (Dados da pesquisa, 2020).

A eletromiografia é considerada uma técnica de registro e avaliação do potencial elétrico dos músculos. Na área médica, ele serve para identificar anormalidades neuromusculares, em relação ao emocional é utilizado para reconhecer a correlação entre as reações fisiológicas e as emoções cognitivas (ZONG., CHETOUANI, 2009).

Dessa forma, os estudos baseados em EMG apresentam concentração na análise de expressões faciais, pois a mímica facial é um fator contribuinte para a resposta emocional a vários estímulos (EKMAN, 1978).

Assim, os primeiros anúncios sobre a mímica facial auxiliar no reconhecimento do emocional foram de Ekman e Friesen em 1978, que descreveram

as dependências sobre músculos faciais, emoções simples e as ações causadas (EKMAN, 1978) como demonstra a tabela a seguir:

Tabela 16 - Relações entre emoções e expressões faciais.


EMOÇÕES	MÚSCULOS ENVOLVIDOS	AÇÕES
Felicidade	Mm. Orbicular do olho, mm. Zigomático	Fechando as pálpebras, puxando os cantos da boca para cima e lateralmente.
Surpresa	Mm. Frontal, mm. Levantador da pálpebra superior	Levantando as sobrancelhas, levantando mais baixo a pálpebra
Medo	Mm. Frontal, mm. Corrugador do supercílio, mm. Levantador da pálpebra superior	Levantando as sobrancelhas, baixando sobrancelhas, pálpebra superior levantada.
Raiva	Mm. Corrugador do supercílio, mm. Levantador do supercílio, mm. Orbicular do olho.	Abaixando as sobrancelhas, levantando mais baixo A pálpebra, fechando pálpebras
Tristeza	Mm. Frontal, mm. Corrugador do supercílio, mm. Depressor do ângulo da boca	Levantando as sobrancelhas, baixando sobrancelhas, cantos dos lábios deprimentes
Nojo	Mm. Levantador do lábio superior, mm.	Levantando o lábio superior,

	Levantador do lábio superior e da asa do nariz.	levantando o inferior rugas nos lábios e pele nasal
--	---	---

Fonte: (TURABZADEH et al., 2018).

Na figura 26 são evidenciados os pontos típicos para colocação dos eletrodos durante a EMG facial. Desse modo, os eletrodos podem ser classificados em grupos, os principais são: de superfície (ou de pele) e eletrodos inseridos, os de superfície são eletrodos secos e gelificados e os inseridos de agulha e fio fino.

Figura 26 - Pontos de aplicação dos eletrodos de eletromiografia



Fonte: (BOXTEL, 2010).

A principal limitação do EMG é sua sensibilidade à intensidade emocional, mas é uma boa técnica para detectar emoções fortes. No entanto, uma vez que as expressões faciais só mudam devido a emoções fortes, pequenas mudanças na valência e na intensidade da excitação não podem ser detectadas (WIOLETA, 2013).

A segunda limitação é a mesma do EEG e do ECG: esse processo requer a utilização de métodos de mensuração de contato, pois afeta o conforto das pessoas e restringe suas atividades de lazer. Além disso, semelhante ao ECG, o EMG (especialmente ao usar eletrodos de superfície) adiciona requisitos à sala onde esse processo é realizado: luz solar direta e ruído eletromagnético devem ser evitados. A luz solar direta pode causar movimentos descontrolados dos músculos faciais. O ruído eletromagnético pode aumentar o nível de ruído no sinal e destruir o sinal de medição. Comparado com EEG e ECG, a vantagem do EMG é que a análise do

sinal é relativamente simples, porque vários músculos ou grupos deles são afetados por emoções diferentes, e é mais fácil definir emoções individuais analisando os sinais registrados (WIOLETA, 2013).

5.5.1 Trabalhos relacionados à Eletromiografia

Coutinho et al. (2018) avaliaram os antecedentes emocionais em eletroencefalografia e eletromiografia facial. Dessa forma, para essas avaliações foi utilizado o **Sistema Biosemi Active – Two**, os eletrodos de **EEG** foram aplicados segundo o **Sistema Internacional 10-20**, e os eletrodos de **EMG** foram fixados no **lado esquerdo da face, correspondendo a três montagens bipolares distintas sobre o frontal medial, o corrugador supercílio e as principais regiões musculares do zigomático**. Os recursos utilizados foram:

- ✓ *Machine Learning (ML)*;
- ✓ *Component Process Model (CPM)*;
- ✓ *Independent Component Analysis (ICA)*;
- ✓ *Support Vector Machines (SVMs)*;
- ✓ *Linear kernel functions*;
- ✓ *Algorithm Sequential Minimal Optimization (SMO)*,
- ✓ *Hanning fade*;
- ✓ *Root mean square (RMS)*.

Os participantes foram estimulados por meio de imagens afetivas e jogos, com a finalidade de estimular as emoções de: Novidade, prazer intrínseco, condutividade de objetivos, controle e potência. Dessa forma, foi possível alcançar uma classificação de até 85,5% (COUTINHO et al., 2018).

TAN et al. (2016) estudaram o reconhecimento de valência intensiva e estados afetivos de excitação por meio da atividade eletromiográfica facial em adultos jovens e idosos. Utilizando para a pesquisa o equipamento **Nexus – 32** (Eletrodos bipolares foram colocados nas regiões musculares principais do ondulador esquerdo e zigomático), e como recursos:

- ✓ *Empirical mode decomposition technique (EMD)*;
- ✓ *Hilbert spectrum (HS)*;
- ✓ *Support vector machine classifier (SVM)*;
- ✓ *Kernel*.

Os participantes do estudo foram estimulados com imagens afetivas da *International System of Affective Images* (IAPS) e as imagens de Ulm, buscando estimular a valência neutra / baixa excitação (OVLA), valência positiva / alta excitação (PVHA), valência negativa / alta excitação (NVHA), valência positiva / baixa excitação (PVLA) e valência negativa / baixa excitação (NVLA).

Dessa forma, para a linha de base a precisão da classificação atingiu 100% para todas as condições, exceto em 2-2 em grupos de jovens; os cinco estados afetivos variaram de 77,06% a 90,74% no grupo de jovens e de 86,25% a 90,25% no grupo de idosos. As taxas de classificação para adultos idosos foram maiores do que adultos jovens em todas as sete condições (TAN *et al.*, 2016).

Golland et al. (2018) investigaram como a dinâmica da EMG facial afeta durante experiências emocionais contínuas. Para o estudo foi utilizado o equipamento *Bionomadix* (BIOPAC Systems Inc., Santa Bárbara, CA) (Eletrodos aplicados no Zigomático maior, corrugador do supercílio), como recurso:

- ✓ *Fourier transform;*

Dessa forma, foi obtido que as flutuações zigomáticas transitórias eram estreitamente sintonizadas com uma experiência emocional positiva. Durante um filme positivo, mas não negativo, os padrões de resposta zigomática foram consistentes entre os participantes, rastreados com classificações subjetivas e variou com a dinâmica emocional. A atividade do ondulador evidenciou um perfil afetivo mais amplo e variabilidade individual. Assim, foi coordenado com mudanças tônicas na negatividade emocional e inversamente acoplada com mudanças transitórias no afeto positivo.

Sharman e Clark (2016) estudaram emoções mistas para resultados de *Near miss*: um estudo psicofisiológico com eletromiografia facial. Utilizaram o equipamento ***Biopac MP36*** (eletrodos aplicados no zigomático e no corrugador do supercílio) para o estudo das emoções. Dessa forma, as emoções mistas foram estimuladas por meio de jogos. Assim, a atividade zigomática mostrou um efeito principal significativo do resultado.

ABTAHI et al. (2018) analisaram as emoções usando áudio / vídeo, EMG e EEG. Dessa forma, como modelo de aprendizagem eles utilizaram o Long-Short TermMemory (LSTM) e Deep Belief Network (DBN) e como recursos:

- ✓ *Convolutional Neural Network (CNN);*
- ✓ *Recurrent Neural Network (RNN);*

- ✓ *Wavelet transforms (WT);*
- ✓ *Hamming window;*
- ✓ *Mel-Frequency Cepstral Coefficients (MFCC);*
- ✓ *MSR Identity Toolbo.*

Os eletrodos dos equipamentos foram aplicados no levantador do lábio superior, zigomático maior, occipitofrontal, depressor do ângulo da boca (EMG) e no F3, Fz, F4, Cz, P3, Pz, P4 e O2 (EEG). As emoções de felicidade, tristeza, raiva, surpresa, medo, nojo e neutro foram estimulados por meio de vídeos. Os resultados da pesquisa evidenciaram que o LSTM é melhor para classificar informações de áudio e vídeo, cada um com seus próprios extratores sofisticados de recursos (MFCC e CNN), enquanto DBN é melhor para classificar informações de EMG e EEG.

Mithbavkar, Shah (2019) estudaram o reconhecimento da emoção por meio de expressões faciais usando sinal EMG. Dessa forma, foram utilizados os recursos como:

- ✓ *Integrated EMG (IEMG);*
- ✓ *Root Mean Square square (RMS);*
- ✓ *Mean absolute value (MAV);*
- ✓ *Elman neural network classifier (ENN);*
- ✓ *Neural network of propagation of return (BPNN);*
- ✓ *Nonlinear autoregressive exogenous network (NARX).*

Visando reconhecer as emoções de: medo, raiva, felicidade, nojo, tristeza e neutro. Assim, a precisão geral na faixa de 69% a 91% em um determinado ambiente emocional. Em caso de expressões impostas, emoções foram reconhecidas com precisão na faixa de 91% a 97%.

Bouchard et al., (2018) avaliaram as diferenças na expressividade emocional entre jogadores de videogame especialistas e não especialistas usando eletromiografia facial. Utilizaram o equipamento **Biopac MP150** (aplicados no zigomático maior e corrugador do supercílio) e como recurso NASA-TLX. Os participantes foram estimulados por meio de vídeo game com a finalidade de estimular a expressividade emocional. Dessa forma, as pontuações no NASA-TLX foram calculadas para ambos os grupos e revelou que os jogadores experientes perceberam a sessão de jogo como menos mentalmente e fisicamente exigentes do que jogadores não especialistas. Os não especialistas também relataram que

tiveram que trabalhar mais do que os especialistas para atingir seu nível de desempenho.

No presente estudo, os recursos tecnológicos de eletromiografia que conseguem identificar o emocional são:

Tabela 17 - Tabela de Equipamentos de Eletromiografia

Recursos Tecnológicos	Empresa Responsável
<i>Sistema Biosemi Active-Two</i>	<i>BioSemi Biomedical Instrumentation</i>
<i>Nexus – 32</i>	<i>Mind Media</i>
<i>Bionomadix</i>	<i>Biopac Systems</i>
<i>Biopac MP150</i>	<i>Biopac Systems</i>

FONTE: (Dados da pesquisa, 2020).

O **sistema BioSemi ActiveTwo** é equipado com 280 canais, um amplificador DC e resolução de 24 bits, estabelecendo o padrão líder mundial para sistemas de medição biopotencial multicanal de alta resolução para aplicações de pesquisa (ORMAX, 2020).

Figura 27 - BiosemiActiveTwo



Fonte: (Ormax, 2020).

O **NeXus-32** é um dispositivo multimodo que mede até 32 sinais fisiológicos simultaneamente. Ele fornece uma solução completa para EEG, neurofeedback e biofeedback. NeXus-32 tem até 24 entradas para sinais EEG unipolares, até 4

canais EEG, EMG, ECG, EOG e 4 para sinais periféricos (como frequência cardíaca, fluxo sanguíneo relativo, condutância da pele, respiração, Temperatura, etc.). NeXus-32 também fornece entrada para evento ou saturação de oxigênio no sangue / gatilho Spo2 e tem várias opções de interface (MINDMEDIA, 2020).

Figura 28 - Nexus 32



Fonte: (MINDMEDIA, 2020).

O par dual EMG BioNomadix sem fio é composto de módulos transmissores e receptores correspondentes. O par de combinações é especialmente projetado para medir um ou dois canais de dados de eletromiograma (EMG) de pacientes ambulatoriais. Os dados EMG podem ser registrados em dois locais independentes. O transmissor e receptor de EMG sem fio BioNomadix fazem parte de um sistema de pesquisa completo (BIOPAC, 2020).

Figura 29 - Bionomadix



Fonte: (Biopac, 2020).

O sistema de aquisição e análise de dados **MP150** com software AcqKnowledge oferece uma ferramenta flexível para ciências biológicas procurar por todos os sistemas são compatíveis com qualquer computador com Windows ou Mac

compatível com Ethernet (UDP). Vários canais de dados com diferentes taxas de amostragem para maximizar a eficiência e armazenamento em velocidades de até 400 kHz (mais). Conectando o computador diretamente a uma única unidade MP150 através do adaptador Ethernet ETHUSB incluído, ou Acesse vários MP150s conectando a caixa de comutação ao adaptador (BIOPAC, 2020).

E como algoritmos: Kernel Method e Algoritm Sequential Minimal Optimization (SMO).

No aprendizado de máquina, as máquinas kernel são uma classe de algoritmos para análise de padrões, cujo membro mais conhecido é a máquina de vetor de suporte. A tarefa geral da análise de padrões é encontrar e estudar tipos gerais de relações em conjuntos de dados (SHAWE-TAYLOR *et al.*, 2004).

A otimização de ordem mínima (SMO) é um algoritmo usado para resolver problemas de programação quadrática (QP) que ocorrem durante o treinamento da máquina de vetores de suporte (SVM) (PLATT, 1998).

Os principais locais de aplicação dos eletrodos são: no mm. levantador do lábio superior, mm. zigomático maior, mm. occipitofrontal, mm. depressor do ângulo da boca (EMG).

Dessa forma, a utilização da eletromiografia apresenta algumas vantagens e desvantagens para identificar o emocional (Tabela 18)

Tabela 18 - Vantagens e desvantagens do EMG

Eletromiografia (EMG)- Eletrodos de superfície		
Vantagens	Desvantagens	Possibilidade de uso em Teste de Usabilidade
<ul style="list-style-type: none"> • Eletrodos de superfície são mais vantajosos, pois podem ser reutilizáveis e permitem medições não invasivas. • A análise do sinal de EMG é relativamente simples, porque vários músculos ou grupos de músculos são afetados por emoções diferentes, e é mais fácil definir emoções individuais analisando os sinais registrados. 	<ul style="list-style-type: none"> • As desvantagens do uso de eletrodos de superfície são os requisitos para a preparação da pele (cabelo raspado, pele desengordurada), área de medição maior e relação sinal-ruído ineficiente. • Sua sensibilidade à intensidade emocional, mas é uma boa técnica para detectar emoções fortes. No entanto, uma vez que as expressões faciais só mudam devido a emoções fortes, pequenas mudanças na valência e na intensidade da excitação não podem ser detectadas. • A luz solar direta pode causar movimentos descontrolados dos músculos faciais. O ruído eletromagnético pode aumentar o nível de ruído no sinal e destruir o sinal de medição. 	Movimento e/ou Estático

Fonte: (Dados do estudo, 2020).

5.6 Eletroencefalograma

Foram utilizadas as seguintes palavras-chave: “**electroencephalogram AND emotion**”. E foram retornados 12 artigos, explanados na tabela 19.

Tabela 19 - Artigos Eletroencefalograma

Improving the accuracy of EEG emotion recognition by combining valence lateralization and ensemble learning with tuning parameters.	PANE; WIBAWA; PURNOMO.	2019
EEG-based emotion classification using innovative features and combined SVM and HMM classifier.	GUO <i>et al.</i>	2017

Fusion of Motif-and spectrum-related features for improved EEG-based emotion recognition.	TIWARI., FALK.	2019
Fusion of facial expressions and EEG for multimodal emotion recognition.	HUANG <i>et al.</i>	2017
EEG-based multi-modal emotion recognition using bag of deep features: An optimal feature selection approach.	ASGHAR <i>et al.</i>	2019
EEG-based emotion recognition using quadratic time- frequency distribution.	ALAZRAI <i>et al.</i>	2018
Emotion recognition and dynamic functional connectivity analysis based on EEG.	LIU <i>et al.</i>	2019
Bispectral analysis of EEG for emotion recognition.	KUMAR., KHAUND; HAZARIKA.	2016
Emotion recognition from spatiotemporal EEG representations with hybrid convolutional recurrent neural networks via wearable multi-channel headset.	CHEN <i>et al.</i>	2020
Comparison of different feature extraction methods for EEG-based emotion recognition.	NAWAZ <i>et al.</i>	2020
EEG-based emotion recognition using an end-to-end regional-asymmetric convolutional neural network.	CUI <i>et al.</i>	2020

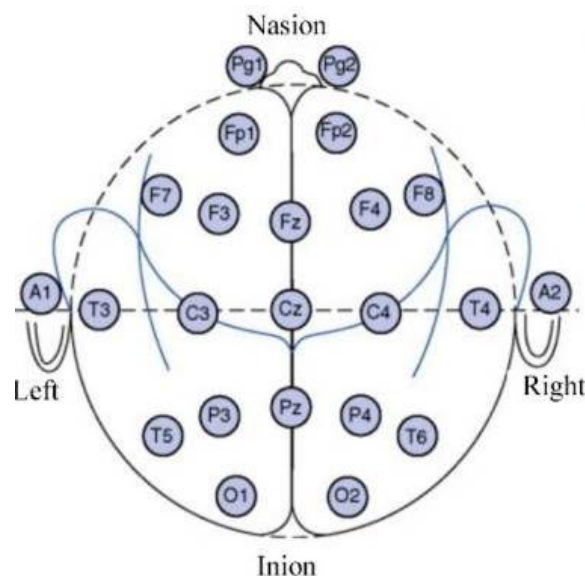
EEG-based emotion classification based on Bidirectional Long Short-Term Memory Network.	YANG <i>et al.</i>	2020
---	--------------------	------

FONTE: (Dados da pesquisa, 2020)

O EEG se caracteriza como uma técnica eletrofisiológica não invasiva, que serve para registrar a atividade elétrica que ocorre dentro do cérebro humano. A coleta dos sinais de EEG é realizada por meio de um dispositivo que é denominado eletroencefalograma, esse dispositivo é formado por eletrodos de placa de metal especiais aplicados ao couro cabeludo humano (LOUIS *et al.*, 2016).

Dessa forma, os eletrodos podem ser de 8, 16 ou 32 pares de eletrodos que se localizam em quatro posições na cabeça: násion, ínion, pontos pré-auriculares direito e esquerdo (AMINOFF, 2012). (Figura 30).

Figura 30 - Eletrodos de EEG no couro cabeludo



Fonte: (AMINOFF, 2012).

Assim, para que se avaliem as emoções humanas, é necessário interpretar as respostas do cérebro a estímulos que geralmente são mensurados e analisados em cinco faixas de frequências de sinais de EEG, sendo elas: delta, teta, alfa, beta e gama (KAUR., SINGH., ROY, 2018). (Tabela 20).

Tabela 20 - Classificação das ondas cerebrais

Ondas	Estado emocional	Descrição
Delta (σ) (0,5 – 4 Hz)	Empatia e intuição	São ondas cerebrais mais lentas, com relação ao sono. As frequências múltiplas dessa faixa gera a liberação do hormônio do crescimento humano. Assim, as ondas produzidas durante o estado de vigília leva ao acesso da atividade do subconsciente.
Teta (θ) (4- 8Hz)	Meditação e Relaxamento profundo	Principalmente os adultos produzem as ondas cerebrais teta, quando a pessoa está no sono leve ou em sonhos. Essas ondas normalmente aparecem com o fechamento dos olhos e desaparecem com a abertura dos olhos. A frequência dessas ondas está associada principalmente ao alívio do estresse e à lembrança da memória. As condições do crepúsculo podem ser usadas para alcançar uma meditação mais profunda, resultando em melhoria da saúde, bem como aumentar a criatividade e as capacidades de aprendizagem.

Alfa (α) (8-16 Hz)	Criatividade, Relaxamento	Essas ondas se apresentam principalmente durante o estado de relaxamento acordado com os olhos fechados. Alpha é o estado de repouso do cérebro. A atividade das ondas alfa diminui em resposta a todos os tipos de atividades motoras. As ondas alfa auxiliam na coordenação mental geral, calma, vigilância, integração mente / corpo e aprendizagem
Beta (β) (16-32 Hz)	Cuidado, concentração.	As ondas beta são produzidas quando a pessoa está em estado de alerta ou ansiedade e é um ritmo dominante. Normalmente, eles são gerados na parte frontal e central do cérebro. Nesse estado, os cérebros podem realizar facilmente: análises, preparações das informações, gerar soluções e novas ideias.
Gama (γ) (acima de 32 Hz)	Aprendizagem Regional, Memória e Processamento e Ideação de Linguagem	Essas ondas são emitidas quando uma pessoa está em uma condição anormal ou quando ocorre algum transtorno mental. Ondas cerebrais gama são as ondas cerebrais mais rápidas e se relacionam ao processamento simultâneo de informações de diferentes áreas do cérebro. Numerosas teorias propuseram que gama contribui diretamente para a função cerebral, mas outros argumentam que gama é melhor vista como um simples subproduto da atividade de rede.

Fonte: (KAUR., SINGH., ROY, 2018).

5.6.1 Trabalhos relacionados à eletroencefalograma

Pane, Wibawa e Purnomo (2019) investigaram como melhorar a precisão do reconhecimento de emoção EEG combinando lateralização de valência e aprendizagem de conjunto com parâmetros de ajuste. Para isso foram utilizados os recursos como:

- ✓ *Wavelet*;
- ✓ *Fourier transform*;
- ✓ *Welch method*;
- ✓ *Discrete wavelet transform (DWT)*;
- ✓ *Daubechies 4 (db4)*;
- ✓ *Random forest (RF)*;
- ✓ *SVM*;
- ✓ *DEAP database*

Os participantes foram estimulados por vídeos com a finalidade de provocar as emoções: feliz, zangado, triste e relaxado. Dessa forma, para a classificação, o método RF fornece a mais alta precisão de 75,6% em comparação com SVM de 69,8% e LDA de 60,4%.

Guo et al. (2017) classificaram as emoções baseada em EEG usando recursos inovadores e classificador SVM. Foi utilizado o sistema 10-20 para aplicação dos eletrodos e o banco de dados DEAP. As emoções de excitação e valência foram estimuladas por meio de vídeos. Assim, os recursos aumentaram a precisão em 5% no eixo de valência e 1,5% no eixo de excitação. O classificador combinado pode melhorar a precisão em 3% em comparação com o classificador SVM.

Tiwari e Falk (2019) estudaram a fusão de recursos relacionados a Motif e espectro para um melhor reconhecimento de emoções baseado em EEG. Assim, foi utilizado o equipamento **Biosemi ActiveTwo** (aplicação dos eletrodos segundo o sistema internacional 10-20) o banco de dados DEAP e os recursos: benchmark, algoritmo mRMR.

As emoções de excitação e valência foram estimuladas por vídeos. Assim, a fusão de características e níveis de pontuação sugere complementaridade entre as medidas baseadas em espectro propostas e benchmark. Quando combinaram os modelos fundidos pode-se fornecer até 9% de melhoria em relação

aos recursos de benchmark isolados e até 16% para recursos teóricos de gráficos não baseados em motivos.

Huang et al. (2017) estudaram a fusão de expressões faciais e EEG para reconhecimento multimodal de emoções. Utilizaram o equipamento **Mindware Mobile**, os recursos: rede neural feedforward e SVM. As emoções de felicidade, neutro, tristeza e medo foram estimulados com filmes. Os resultados mostram que as precisões de duas detecções de fusão multimodal são 81,25% e 82,75%, respectivamente, ambas superiores às da expressão facial ou detecção de EEG. A combinação de expressões faciais e informações de EEG para o reconhecimento de emoções compensam seus defeitos como fontes únicas de informação.

ASGHAR et al (2019) estudaram o reconhecimento de emoção multimodal baseado em EEG usando conjunto de características profundas: uma abordagem de seleção de características ideais. Como recursos foram utilizados:

- ✓ *Wavelet transform;*
- ✓ *AlexNet;*
- ✓ *DNN;*
- ✓ *Bag of deep features (BoDF) model;*
- ✓ *SVM;*
- ✓ *KNN algorithm;*
- ✓ *Kernel functions;*
- ✓ *SEED and DEAP database.*

As emoções de excitação e valência foram estimuladas por filmes e vídeos. Assim, o modelo proposto atingiu 93,8% de precisão no conjunto de dados SEED e 77,4% de precisão no conjunto de dados DEAP.

Alazrai et al. (2018) analisaram o reconhecimento de emoção baseado em EEG usando distribuição quadrática de frequência de tempo. Para isso foi utilizado o equipamento **BioSemi ActiveTwo** (eletrodos aplicados na região parietal P3-P4, P7- P8 E CP5-CP6, na região frontal F3-F4, F7- F8, FC1-FC2,FC5- FC6, AF3-AF4 E FP1-FP2 , na região temporal T7-T8 e na região occipital O1-02). Como recursos:

- ✓ Short-time Fourier transform (STFT);
- ✓ Wavelet transform (WT);
- ✓ SVM;
- ✓ Kernel;
- ✓ KNN algorithm;

- ✓ DEAP database;

Para estímulo de excitação e valência foram utilizados vídeos. E o banco de dados DEAP. Dessa forma, as precisões médias de classificação obtidas na diferenciação entre as várias classes de emoções definidas usando cada um dos quatro esquemas de rotulagem de emoções estão dentro da faixa de 73,8% - 86,2%.

Liu et al. (2019) estudaram o reconhecimento de emoções e análise de conectividade funcional dinâmica com base em EEG. Para isso foi utilizado o equipamento **ESI NeuroScan** (eletrodos aplicados segundo o sistema internacional 10-20). E como recursos:

- ✓ *Independent component analysis (ICA)*;
- ✓ *Wavelet packet transform*;
- ✓ *Dynamic FC*;
- ✓ *SVM*;
- ✓ *The SEED database*.

As emoções positivas, negativas e neutra foram estimuladas por meio de filmes. Dessa forma, os resultados experimentais mostraram que a banda beta é a mais adequada para o reconhecimento de emoções devido ao melhor precisão de 87,03%. E os lobos frontal e temporal são mais sensíveis às emoções do cérebro.

Kumar, Khaund e Hazarika (2016) analisaram bispectral do EEG para reconhecimento de emoções. Utilizaram como recurso:

- ✓ *The dimensional model of valence activation*;
- ✓ *Minimum Linear Kernel*;
- ✓ *Square Support Vector Machine (LS-SVM)*;
- ✓ *Artificial Neural Networks of backpropagation (ANN)*;
- ✓ *Fourier transform*;
- ✓ *DEAP database*.

As emoções: alta Valência, baixa valência, excitação alta e baixa excitação foram estimuladas por vídeos e músicas. Dessa forma, obtiveram como exatidões de validação cruzada de 64,84% para a classificação de Baixa / Alta excitação e 61,17% para baixa / alta valência foram obtidas no DEAP conjunto de dados com base nas características propostas.

Chen et al. (2020) criaram um modelo de reconhecimento de emoções EEG baseado no classificador LIBSVM. Dessa forma, utilizaram o equipamento **Emotiv Epoc** e como recursos:

- ✓ *Lempel-Zi complexity*;
- ✓ *Detail coefficient of the wavelet*.

As emoções de feliz, relaxado, zangado, triste e disrajadas foram estimuladas com filmes. Dessa forma, as classificações de duas categorias são realizadas em excitação e valência, as taxas de reconhecimento são 74,88% e 82,63%, respectivamente.

Nawaz et al. (2020) compararam os diferentes métodos de extração de características para reconhecimento de emoção baseado em EEG. Utilizaram o equipamento **Biosemi ActiveTwo** (eletrodos aplicados segundo o Sistema internacional 10-20) e como recursos:

- ✓ Algoritmo de periodograma modificado;
- ✓ Método Welch;
- ✓ Singular entropia de decomposição de valor (SVDE);
- ✓ Wavelet.

O banco de dados DEAP. As emoções de valência, excitação e dominância foram estimulas por videoclipes. Assim, a classificação geral de 77,62%, 78,96% e 77,60% para valência, excitação e dominância respectivamente.

Cui et al., (2020) estudaram o reconhecimento de emoção baseado em EEG usando uma rede neural convolucional regional assimétrica de ponta a ponta. Como recursos:

- ✓ Rede neural convolucional (CNN);
- ✓ Interpolação de Gauss e linear;
- ✓ SVM;
- ✓ KNN;
- ✓ O banco de dados DEAP e DREAMER.

As emoções de excitação e valência foram estimuladas com vídeos e músicas. Dessa forma, O modelo proposto pode obter acurácias de reconhecimento ao longo de 95% para tarefas de classificação de valência e excitação em ambos os conjuntos de dados, significativamente.

Yang et al. (2020) classificaram as emoções baseada em EEG baseada na Rede de Memória Bidirecional Longa de Curto Prazo. Utilizaram o equipamento *ES/ NeuroScan*. E como recursos:

- ✓ Rede de Long Short-Term Memory (LSTM);
- ✓ Recurrent Neural Rede (RNN);

- ✓ LSTM bidirecional;
- ✓ Algoritmo de padrão;
- ✓ SVM.

As emoções de feliz, triste, medo e neutro foram estimulados por vídeos. Os resultados experimentais finais mostram que foi possível alcançar uma precisão de 84,21% para a classificação de quatro estados emocionais usando o método proposto.

No presente estudo, os recursos tecnológicos de EEG que conseguem identificar o emocional são:

Tabela 21 - Tabela de Equipamentos EEG

Recurso Tecnológico	Empresa Responsável
<i>Biosemi ActiveTwo</i>	<i>Biosemi</i>
<i>Mindwave Mobile</i>	<i>Neurosky</i>
<i>Emotiv Epoc</i>	<i>Emotiv</i>

FONTE: (Dados da pesquisa, 2020).

O sistema **BioSemi ActiveTwo** é equipado com até 280 canais, um amplificador DC e resolução de 24 bits, estabelecendo um padrão líder mundial para sistemas de medição biopotencial multicanal de alta resolução para aplicações de pesquisa. O eletrodo ativo de segunda geração é menor em tamanho, mais leve no peso do cabo e tem melhores especificações em termos de ruído de baixa frequência e impedância de entrada. O sistema BioSemi ActiveTwo mantém uma vantagem em design competitivo (ORMAX, 2020).

O **MindWave Mobile 2 da NeuroSky**, que é um fone de ouvido EEG que pode medir e transmitir com segurança o espectro de energia (onda α , onda β , etc.) de dados por Bluetooth de baixa energia (BLE) ou Bluetooth clássico sem comunicação e Use com seu computador, iOS ou dispositivo Android. Basta colocar este fone de ouvido, você pode ver suas alterações de EEG em tempo real! Com

MindWave Mobile 2, você pode monitorar sua concentração e relaxamento, e até mesmo entender como seu cérebro responde à sua música favorita. Este fone de ouvido é uma excelente introdução ao mundo das interfaces cérebro-computador (SPARKFUN, 2020).

O **EMOTIV EPOC +** possui facilidade de uso e conforto do usuário, e pode capturar dados quantitativos semelhantes aos de equipamentos de pesquisa tradicionais. Permite associar dados a ECG, RGP, expressões faciais, rastreamento ocular, etc., e é outra ferramenta desenhada para fins de pesquisa, incluindo comportamento do usuário para tomada de decisão (EMOTIV, 2020).

Figura 31- Emotiv Epoc



Fonte: (EMOTIV, 2020).

Como recursos o algoritmo KNN e SVM, banco de dados deap, e os locais de aplicação de eletrodos segundo o sistema internacional 10-20.

Dessa forma, a utilização do eletroencefalograma apresenta algumas vantagens e desvantagens para identificar o emocional (Tabela 22).

Tabela 22 - Vantagens e desvantagens do EEG

Eletroencefalograma (EEG)		
Vantagens	Desvantagens	Possibilidade de uso em Teste de Usabilidade
<ul style="list-style-type: none"> O EEG apresenta uma maior mobilidade, pois o aparelho é mais móvel e leve. A velocidade de gravação é muito alta (pois a atividade neural é gravada em segundos após o estímulo), o que beneficia na simulação de situações experimentais. 	<ul style="list-style-type: none"> Apresenta desvantagens devido à quantidade de ruído e artefatos e à dificuldade de análise dos dados. A atividade cortical captada pelo EEG sofre uma série de deformações (ruídos e artefatos) devido ao tecido da cabeça, ossos, presença de cabelo, piscadas dos olhos, batimentos cardíacos do participante, a tensão muscular do participante e fatores não fisiológicos. 	Movimento e/ou Estático

Fonte: (Dados da pesquisa, 2020).

5.7 GSR

Foram utilizadas as seguintes palavras-chaves: "**Galvanic Skin response AND emotion**". E foram retornados 6 artigos, explanados na tabela 23.

Tabela 23 - Artigos de GSR

The potential of photoplethysmogram and galvanic skin response in emotion recognition using nonlinear features.	GOSHVARPOUR; GOSHVARPOUR.	2020
Real-Time Multi-Modal Estimation of Dynamically Evoked Emotions Using EEG, Heart Rate and Galvanic Skin Response.	VAL-CALVO <i>et al.</i>	2020

<p>Emotion recognition via random forest and galvanic skin response: Comparison of time based feature sets, window sizes and wavelet approaches.</p>	<p>AYATA.,YASLAN ., KAMAŞAK.</p>	<p>2016</p>
<p>Human emotion recognition based on galvanic skin response signal feature selection and SVM.</p>	<p>LIU <i>et al.</i></p>	<p>2019</p>
<p>Reliability of the Empatica E4 wristband to measure electrodermal activity to emotional stimuli.</p>	<p>BORREGO <i>et al.</i></p>	<p>2019</p>
<p>UDSP+ stress detection based on user-reported emotional ratings and wearable skin conductance sensor.</p>	<p>LIAPIS <i>et al.</i></p>	<p>2019</p>

Fonte: (Dados da pesquisa, 2020)

A resposta galvânica da pele (GSR), também recebe o nome de condutância da pele ou atividade eletrodérmica (EDA), em que são mensurados continuamente os parâmetros elétricos da pele. Esses parâmetros não são de controle consciente, ou seja, dependem diretamente da variação da reação de suor, que gera mudanças no sistema nervoso simpático (WU., LIU., HAO, 2010).

Dessa forma, quando existem mudanças no suor são induzidas reações emocionais, que são observadas principalmente na superfície das mãos e nos dedos. Assim, as reações de suor gera uma variação da quantidade de sal na pele, o que altera a resistência elétrica da pele. Quando as glândulas sudoríparas encontram-se ativas, elas secretam umidade para superfície da pele, o que leva a um desequilíbrio nos íons positivos e negativos, refletindo nas propriedades de fluxo das correntes elétricas na pele (CRITCHLEY, 2002).


Assim, a condutância da pele se relaciona com o nível da excitação, caso a excitação aumente, a condutância também aumenta. Assim, a amplificação do sinal de GSR se associa com o estresse, engajamento, excitação, raiva e frustração. Os estímulos para atenção a tarefas e que chamam atenção geram um aumento simultâneo da magnitude e frequência do GSR. Portanto, o GSR permite reconhecer não apenas as emoções, mas também a detecção automática do processo de tomada de decisão (DUDA., HAWKINS., MCGILL, 2014).

Diante disso, para que seja realizada a mensuração do sinal de GSR é necessário a aplicação de eletrodos no dedo indicador e médio, o sinal é medido por um ou dois sensores, os eletrodos contém Ag/AgCl (Cloreto de prata) com a pele (AYATA; YASLAN; KAMASAK, 2017). (Figura 11).

Assim o GSR apresenta vantagens na identificação do estado emocional, pelos motivos a seguir: (AYATA; YASLAN; KAMASAK, 2017).

- ✓ Necessita uma quantidade menor de eletrodos de medição, permitindo o uso de dispositivos vestíveis e melhor facilidade de definição do estado emocional nas atividades normais do usuário;
- ✓ Os fornecimentos dos dados brutos do GSR são menores, em especial os de monitoramento longo, o que permite a análise dos dados de forma mais rápida e não apresenta muito poder computacional;
- ✓ O equipamento de medição do GSR é mais barato e simples;

Figura 32 - Sensores de condutância da pele



Fonte: (SETZ, 2009).

E em relação à desvantagem do GSR, a principal está relacionada à falta das informações que tem relação com o nível de valência.

5.7.1 Trabalhos relacionados ao GSR

Goshvarpour e Goshvarpour (2020) estudaram o potencial do fotopletismograma e da resposta galvânica da pele no reconhecimento de emoções usando recursos não lineares. Dessa forma, os sinais GSR foram registrados enquanto dois eletrodos referenciais foram anexados no dedo indicador e no médio e os sinais PPG foram adquiridos a partir do dedo polegar. Os recursos utilizados foram:

- ✓ Expoentes de *Lyapunov*
- ✓ *Poincaré's*;
- ✓ Rede neural probabilística (PNN).
- ✓ *Database DEAP*.

Os participantes foram estimulados por música para provocar excitação e valência. Os resultados mostraram que a fusão tem mais potencial de reconhecimento de emoções do que uso de cada sinal separadamente. Para $\sigma = 0,1$, a maior taxa de reconhecimento foi de 100% em um modo dependente do sujeito. Em um modo independente do sujeito, as precisões máximas de 88,57% e 86%.

Val-calvo et al. (2020) estudaram a estimativa multimodal em tempo real de emoções evocadas dinamicamente usando EEG, frequência cardíaca e resposta galvânica da pele. Para isso foi utilizado o equipamento **OpenBCI EEG e Pulseira Empatica E4**. E como recursos:

- ✓ Média da série de amplitude (OFFSET),
- ✓ Inclinação média da série de valores de amplitude (SLOPE);
- ✓ Desvio padrão da série de valores de amplitude (STD);
- ✓ *Leave-One-Out (LOO) strategy*.

Os participantes foram estimulados por filmes para provocar excitação e valência. Assim, a metodologia de estimativa de emoção provou ter um desempenho nas restrições de tempo real, mantendo alta precisão na estimativa de emoção ao usar o banco de dados multissinais de emoções evocadas dinamicamente de produção própria.

Ayata, Yaslan e Kamasak (2016) estudaram o reconhecimento de emoções por meio de floresta aleatória e resposta galvânica da pele: comparação de conjuntos de recursos baseados em tempo, tamanhos de janela e abordagens de wavelet.

Sendo utilizado o recurso de Random Forest e o banco de dados DEAP. Os participantes foram estimulados por vídeos para provocar excitação e valência. Assim, foram alcançadas 71,53% e taxa de precisão de 71,04% para excitação e valência respectivamente, usando apenas o sinal de resposta galvânica da pele.

LIU et al. (2016) estudaram o reconhecimento da emoção humana com base na seleção de recursos do sinal de resposta galvânica da pele e SVM. Assim, foi utilizado o **e-Health Sensorplataforma V2. 0** e como recursos:

- ✓ SVM;
- ✓ Denoising wavelet;
- ✓ Wavelet db5;
- ✓ Library for Support Vector Machines- LIBSVM;
- ✓ Kernel RBF.

Os participantes foram estimulados por filmes para provocar emoções de felicidade, tristeza, raiva e medo. Dessa forma, foi alcançada uma precisão do reconhecimento superior a 66,67%.

Borrego et al. (2019) avaliaram a confiabilidade da pulseira Empatica E4 para medir a atividade eletrodérmica a estímulos emocionais. Usando os recursos

Nyquist e a IAPS para estimular a excitação e valência dos participantes. Assim, foi concluído que a pulseira E4 deve ser usada com cuidado ao avaliar mudanças nas emoções. Pois os dados da pesquisa mostram que a correlação entre os dois sistemas foi baixa a moderada para imagens negativas e com valências positivas, e inexistentes para imagens neutras.

Assim, corroborando com os dados do estudo, os seguintes autores também evidenciaram o uso do GSR para o reconhecimento do emocional:

Liapis et al. (2019) estudaram as emoções na interação humano-computador, utilizando a condutância da pele para identificar o estresse. A condutância da pele foi registrada utilizando um **sensor Mindfield eSense**. E os recursos:

- ✓ Análise Discriminante Linear (LDA).,
- ✓ Análise Discriminante Quadrática (QDA).,
- ✓ Árvore de Decisão Simples (S-Tree).,
- ✓ Máquina de vetor de suporte linear (L-SVM).,

Nesse artigo, foi realizado um experimento para reconhecimento de estresse na interação humano-computador. Dessa forma, trinta e um participantes saudáveis realizaram cinco tarefas estressantes de IHC e seus sinais de condutância da pele foram monitorados. As tarefas selecionadas foram listadas com mais frequência como estressantes por 15 usuários de computador típicos que estavam envolvidos em entrevistas pré-experimento, pedindo-lhes para identificar casos estressantes de interação do computador. Os sinais de condutância da pele coletados foram analisados usando sete classificadores de aprendizado de máquina populares. A melhor precisão de reconhecimento de tensão foi alcançada pelo classificador de máquina de vetor de suporte cúbico tanto por tarefa (em média 90,8%) quanto para todas as tarefas (Média = 98,8%, DP = 0,6%). Essa precisão muito alta demonstra os potenciais do uso de sinais fisiológicos para reconhecimento de estresse no contexto de tarefas típicas de IHC.

No presente estudo, os recursos tecnológicos de GSR que conseguem identificar o emocional são:

Tabela 24 - Tabela de Equipamentos GSR

Recursos Tecnológicos	Empresa Responsável
Pulseira <i>Empatica E4</i>	<i>Empatica</i>
<i>Power Lab</i>	<u>ADInstruments</u>
e-Health SensorPlataforma V2.0	<i>Libelium</i>

FONTE: (Dados da pesquisa, 2020).

A **pulseira E4** é um dispositivo sem fio vestível projetado para coleta contínua de dados em tempo real na vida diária. A pulseira E4 armazena dados em sua memória interna e os dados podem ser baixados via USB (E4, 2021).


Figura 33 - Pulseira E4

Fonte: (E4, 2021).

O **PowerLab** é um dispositivo de aquisição de dados (DAQ) que detecta sinais por meio de vários dispositivos e sensores ao mesmo tempo com uma frequência de amostragem ajustável (ADINSTRUMENTS, 2020).

O **e-Health Sensor Shield** permite que os usuários do Arduino e do Raspberry Pi usem 9 sensores diferentes para executar aplicativos biométricos e médicos que requerem monitoramento humano. Essas informações podem ser utilizadas para monitorar o estado dos pacientes em tempo real ou obter dados confidenciais para posterior diagnóstico e análise médica. As informações biométricas coletadas podem ser enviadas sem fio usando qualquer uma das 6 opções de conexão disponíveis: Wi-Fi, 3G, GPRS, Bluetooth, 802.15.4 e ZigBee, dependendo do aplicativo (EHEALTH, 2020)

Figura 34 - e-Health Sensor Shield



Fonte: (EHEALTH, 2020).

Os estudos não evidenciaram algoritmos, mas os recursos mais utilizados foi o banco de dados DEAP e o SVM. O **SVM** são modelos de aprendizagem de máquina, que são supervisionados por algoritmos de aprendizagem que analisam os dados utilizados (SOUZA, 2019). E o **Deap** é um conjunto de dados multimodal para a análise dos estados afetivos humanos (SOUZA, 2019).

Dessa forma, a utilização do eletroencefalograma apresenta algumas vantagens e desvantagens para identificar o emocional (Tabela 25).

Tabela 25 - Vantagens e desvantagens do GSR

Condutância galvânica da pele (GSR)		
Vantagens	Desvantagens	Possibilidade de uso em Teste de Usabilidade
<ul style="list-style-type: none"> Necessita uma quantidade menor de eletrodos de medição, permitindo o uso de dispositivos vestíveis e melhor facilidade de definição do estado emocional nas atividades normais do usuário; Os fornecimentos dos dados brutos do GSR são menores, em especial os de monitoramento longo, o que permite a análise dos dados de forma mais rápida e não apresenta muito poder computacional; O equipamento de medição do GSR é mais barato e simples 	<ul style="list-style-type: none"> O movimento da mão ou do braço poderá provocar alteração no nível de contato entre a pele e o eletrodo, levando a alterações bruscas e momentâneas do GSR. Excesso de gordura, maquiagem, calos e pele quebradiça levarão a medidas alteradas de GSR. Ambientes muito frios ou excessivamente quentes podem alterar as medidas do GSR. 	Movimento e/ou Estático

Fonte: (Dados da pesquisa, 2021).

6 CONCLUSÃO

O presente trabalho teve como objetivo identificar equipamentos que mensurem sinais fisiológicos e que auxiliem no reconhecimento emocional de usuários em um ambiente de teste de usabilidade, tendo em vista que as emoções são fatores humanos que influenciam na tomada de decisões e trazem respostas para a compreensão e identificação do comportamento dos usuários.

A pesquisa foi realizada por meio de uma revisão integrativa, em que foi possível identificar os equipamentos para o reconhecimento emocional: **o eletrocardiograma, a termografia, a eletromiografia, a resposta galvânica da pele, a taxa de respiração e o eletroencefalograma**, bem como os algoritmos relacionados a cada sinal e seus locais de aplicação no corpo.

Dado o estudo o equipamento que tem o maior expecto para identificar o emocional é o eletrocardiograma, e o que traz menor informação é a taxa de respiração. Considerando uma avaliação de usabilidade em que o usuário está estático e que se possa ter a visão do rosto do mesmo por completo, com controle de temperatura e com iluminação adequada na sala de teste, a termografia é a opção mais interessante para identificar o emocional do usuário. Quando o cenário apresentar limitações de ambiente e temperatura, o eletrocardiograma é a opção mais adequada.

Caso o usuário esteja se movimentando, pode se utilizar o eletrocardiograma e a condutância galvânica da pele, que permite ser utilizado em dispositivos vestíveis, apesar de não ser plenamente confiável porque em movimento, existe uma geração de ruídos e problemas inerentes ao movimento que podem interferir no resultado do sinal.

7 ESTUDOS FUTUROS

- ✓ Como os resultados de relatórios dos *biofeedback* podem ser incorporados dentro de uma dinâmica de avaliação de usabilidade uma vez que não são feitos para isso?
- ✓ É possível fazer a visualização dos dados em tempo real?
- ✓ Que tecnologias de materiais vestíveis podem ser utilizados para ter um melhor resultado ou ter um resultado mais preciso com relação ao levantamento de *biofeedback* no caso de avaliação de usabilidade que envolva movimento do usuário?

REFERÊNCIAS

AAMI. Human factors engineering: Design of medical devices (ANSI/AAMI HE75:2009). **Association for the Advancement of Medical Instrumentation (Human Engineering Committee)**. Arlington, VA. 2010.

AAMI. Human factors engineering: Design of medical devices (ANSI/AAMI HE75:2009). **Association for the Advancement of Medical Instrumentation (Human Engineering Committee)**. Arlington, VA. 2009.

ABNT. NBR IEC 62366: Produtos para a saúde — Aplicação da engenharia de usabilidade a produtos para a saúde. **Associação Brasileira de Normas Técnicas**. Rio de Janeiro. 2010.

ABTAHI, F. et al. Emotion analysis using audio/video, EMG and EEG: a dataset and comparison study. In: **2018 IEEE Winter Conference on Applications of Computer Vision (WACV)**. IEEE, 2018. p. 10-19.

ALAZRAI, R. et al. EEG-based emotion recognition using quadratic time-frequency distribution. **Sensors**, v. 18, n. 8, p. 2739, 2018.

ALI, M. et al. A globally generalized emotion recognition system involving different physiological signals. **Sensors**, v. 18, n. 6, p. 1905, 2018.

ALZOUBI, O. et al. A Deep Learning Approach for Classifying Emotions from Physiological Data. In: **2020 11th International Conference on Information and Communication Systems (ICICS)**. IEEE, 2020. p. 214-219.

AMINO, M.J. Electroencephalography: General principles and clinical applications. In Amino_'s Electrodiagnosis in Clinical Neurology; Saunders, W.B., Ed.; Elsevier B.V.: Amsterdam, **The Netherlands, and Abnormal Findings in Adults, Children, and Infants; American Epilepsy Society**: Chicago, IL, USA, 2016;

ASGHAR, M. et al. EEG-based multi-modal emotion recognition using bag of deep features: An optimal feature selection approach. **Sensors**, v. 19, n. 23, p. 5218, 2019.

Ayata, D; Yaslan, Y.; Kamasak, M. Emotion recognition via galvanic skin response: Comparison of machine learning algorithms and feature extraction methods. *Istanbul Univ. J. Electr. Electron. Eng.* **2017**, 17, 3129–3136.

AYATA, D; YASLAN, Y; KAMAŞAK, M. Emotion recognition via random forest and galvanic skin response: Comparison of time based feature sets, window sizes and wavelet approaches. In: **2016 Medical Technologies National Congress (TIPTEKNO)**. IEEE, 2016. p. 1-4.

BANICH, M. T.; COMPTON, R. J. **Cognitive neuroscience**. Cambridge University Press, 2018..

BASFORD, J. R. Agentes físicos e biofeedback. In: DELISA, J. A. **Medicina de Reabilitação: Princípio e Prática**. São Paulo: Ed. Manole, 1992.

BASMAJIAN, J. V. **Biofeedback: principles and practice for clinician**. 3. ed. Baltimore: Williams & Wilkins, 1989.

BATINJAN, G., ZORE, Z., CELEBIC, A., PAPIC, M., PANDURIC, D.G., ZORE, I.F. **Thermographic monitoring of wound healing and oral health-related quality of life in patients treated with laser (aPDT) after impacted mandibular third molar removal**. *Int J Oral Maxillofac Surg*, v. 43, p. 1503-1508, 2014.

BEALE, R.; PETER, C. The Role of Affect and Emotion. **Affect and Emotion in Human-Computer Interaction**, v. 4868, p. 1-11, 2008.

BORREGO, A. et al. Reliability of the Empatica E4 wristband to measure electrodermal activity to emotional stimuli. In: **2019 International Conference on Virtual Rehabilitation (ICVR)**. IEEE, 2019. p. 1-2.

BOXTEL, A. Van Facial EMG as a tool for inferring affective states. *Proc. Meas. Behav.* **2010**, 2010, 104–108.

BRÁS, S. et al. Biometric and emotion identification: An ECG compression based method. **Frontiers in psychology**, v. 9, p. 467, 2018.

BRAVE, S.; NASS, C. The human-computer interaction handbook. In: JACKO, J. A.; SEARS, A. (Ed.). Hillsdale, NJ, USA: L. Erlbaum Associates Inc., 2003. cap. **Emotion in Human-computer Interaction**, p. 81–96. ISBN 0-8058-3838-4.

BRIOSCHI, M. L. **Metodologia de normalização de análise do campo de temperaturas em imagem infravermelha humana**. 2011. 115f. Tese (Doutorado em Engenharia Mecânica) – Universidade Federal do Paraná, Curitiba, 2011.

CAMPBELL, A.; CHOUDHURY, T. **From smart to cognitive phones**. IEEE Pervasive Computing, IEEE, n. 3, p. 7–11, 2012.

CASTELNUOVO, G. et al. Psychological Treatments and Psychotherapies in the Neurorehabilitation of Pain: Evidences and Recommendations from the Italian Consensus Conference on Pain in Neurorehabilitation. **Frontiers in psychology**, v. 7, p. 115, 2016.

CHEN, J. et al. Reconhecimento de emoção independente do sujeito com base em sinais fisiológicos: um método de decisão em três estágios. **BMC informática médica e tomada de decisão**, v. 17, n. 3, pág. 167, 2017.

CHEN, J. et al. Emotion recognition from spatiotemporal EEG representations with hybrid convolutional recurrent neural networks via wearable multi-channel headset. **Computer Communications**, v. 154, p. 58-65, 2020. *Comput. Ind.* **2017**, 92–93, 84–90.

CÔRTE, A.; HERNANDEZ, A. Termografia médica infravermelha aplicada à medicina do esporte. **Revista brasileira de medicina do esporte**, v. 22, n. 4, p. 315-319, 2016.

COUTINHO, E. et al. Evidence of emotion-antecedent appraisal checks in electroencephalography and facial electromyography. **Plos one**, v. 13, n. 1, p. e0189367, 2018.

CRISTESCU, I. Emotions in Human-Computer Interaction: the Role of Nonverbal Behavior in Interactive Systems. **Revista Informatica Economică**, v. 12, n. 2(46), p.

CRISWELL, E. Biofeedback and Somatics. **Novato: Freeperson Press**, 1995.

CRITCHLEY, H.D. Review: Electrodermal Responses: What Happens in the Brain. **Neurosci** **2002**, 8, 132–142.

CRUZ-ALBARRAN, I. A. et al. A methodology based on infrared thermography for the study of stress in hands of young people during the Trier Social Stress Test. **Infrared Physics & Technology**, v. 93, p. 116-123, 2018.

CUI, H. et al. EEG-based emotion recognition using an end-to-end regional-asymmetric convolutional neural network. **Knowledge-Based Systems**, p. 106243, 2020.

DANUCALOV, M. A. D. A psicofisiologia e o biofeedback aplicado à educação física. **Revista Mackenzie de Educação Física e Esporte**, v. 9, n. 1, 2010.

DAS, P.; KHASNOBISH, A.; TIBAREWALA, D. N. Emotion recognition employing ECG and GSR signals as markers of ANS. In: **2016 Conference on Advances in Signal Processing (CASP)**. IEEE, 2016. p. 37-42.

DELGADO, J.M.P.Q. (Editor) Industrial and Technological Applications of Transport in Porous Materials. In: BARREIRA, E; DE FREITAS, S.S; DE FREITAS,V.P; DELGADO, J.M. P.Q. **Infrared Thermography Application in Building Diagnosis: A Proposal for Test Procedures**. Springer. Porto. Portugal. 2013.

DESMET, P. F. In: BLYTHE, M. A.; OVERBEEKE, K.; MONK, A. F.; WRIGHT, P. C. (Ed.). Norwell, MA, USA: Kluwer Academic Publishers, 2003. cap. **Measuring Emotion: Development and Application of an Instrument to Measure Emotional Responses to Products**, p. 112.

DESMET, P.; HEKKERT, P. Framework of Product Experience. **International Journal of Design**, v. 1, n. 1, p. 13-23, 2007.

DISSANAYAKE, T. et al. An ensemble learning approach for electrocardiogram sensor based human emotion recognition. **Sensors**, v. 19, n. 20, p. 4495, 2019.

DUDA, S.; HAWKINS, D.; MCGILL, M. Physiological response measurements. In: **Eye tracking in user experience design**. Morgan Kaufmann, 2014. p. 81-108.

- DZEDZICKIS, Andrius; KAKLAUSKAS, Artūras; BUCINSKAS, Vytautas. Human Emotion Recognition: Review of Sensors and Methods. **Sensors**, v. 20, n. 3, p. 592, 2020..
- EARLE, R.; VAGHADIA, H; SAWKA, A. Novel use of the Nexfin HD monitor for hemodynamic management during electroconvulsive therapy in a patient with an unrepaired abdominal aortic aneurysm. **Canadian Journal of Anesthesia/Journal canadien d'anesthésie**, v. 62, n. 6, p. 674-675, 2015.
- EKMAN, P.; FRIESEN, W. V. The repertoire of nonverbal behavior: Categories, origins, usage, and coding. **Semiotica**, v. 1, n. 1, p. 49–98, 1969.
- EKMAN, P.; FRIESEN, W. V. The repertoire of nonverbal behavior: Categories, origins, usage, and coding. **Semiotica**, v. 1, n. 1, p. 49–98, 1969.
- ELLSWORTH, P. C.; SCHERER, K. R. Appraisal processes in emotion. **Handbook of affective sciences**, v. 572, p. V. 595, 2003.
- FERREIRA, Jacqueline et al. An automatic classifier of emotions built from entropy of noise. **Psychophysiology**, v. 54, n. 4, p. 620-627, 2017.
- FERREIRA. S. B. L; LEITE. J. C.P. Avaliação da usabilidade em sistemas de informação: o caso do sistema submarino. **Revista de Administração Contemporânea**, v. 7, n. 2, p. 115-136, 2003.
- FONTAINE, J. R.; POORTINGA, Y. H.; SETIADI, B.; MARKAM, S. S. Cognitive structure of emotion terms in indonesia and the netherlands. **Cognition & Emotion, Taylor & Francis**, v. 16, n. 1, p. 61–86, 2002.
- FONTAINE, J. R.; SCHERER, K. R.; ROESCH, E. B.; ELLSWORTH, P. C. The world of emotions is not two-dimensional. **Psychological science, Sage Publications**, v. 18, n. 12, p. 1050–1057, 2007.
- FULLER, G. D. **Biofeedback: Methods and procedures in clinical practice**. 1 ed. São Francisco: 1979, 1977.
- GAARDER, K. R. and Montgomery. **Penelope S=, Clinical Biofeedback: A Procedural Manual, Baltimore, Mary land: The Williams and Wilkins Company**, 1977.
- GANTI, Vaishnavi et al. Human Emotion Recognition using Bio Signals. **International Journal**, v. 8, n. 5, 2020
- GASPARINI, F; GILTRI, M; BANDINI, S. Discriminating affective state intensity using physiological responses. **Multimedia Tools and Applications**, p. 1-21, 2020.
- GOLLAND, Y. et al. Affect dynamics of facial EMG during continuous emotional experiences. **Biological Psychology**, v. 139, p. 47-58, 2018.
- GOMES FILHO, J. **Ergonomia do objeto: Sistema técnico de leitura ergonômica**. 2ª ed., p.19-54. Escrituras Editora. São Paulo, 2012.

GONÇALVES, V. P. et al. Senior citizens in interaction with mobile phones: A flexible middleware approach to support the diversity. In: **Proceedings of the International Conference on Software Engineering Research and Practice (SERP)**. The Steering Committee of The World Congress in Computer Science, Computer Engineering and Applied Computing (WorldComp), 2013. p. 1.

GONÇALVES, V. P., NERIS, V. P. de A., SERAPHINI, S., DIAS, T. C., PESSIN, G., JOHNSON, T., UEYAMA, J. Providing adaptive smartphone interfaces targeted at elderly people: an approach that takes into account diversity among the elderly. **Universal Access in the Information Society, Springer**, p. 1–21, 2015.

GONÇALVES, V. P.; GIANCRISTOFARO, G. T.; FILHO, P. G.; JOHNSON, T.; CARVALHO, V.; PESSIN, G.; NERIS, V. P. de A.; UEYAMA, J. Assessing users' emotion at interaction time: a multimodal approach with multiple sensors. **Soft Computing, Springer**, p. 1–15, 2016.

GONCALVES, V. P.; NERIS, V. P. D. A.; UEYAMA, J. Interacao de idosos com celulares: Flexibilidade para atender a diversidade. In: **Proceedings of the 10th Brazilian Symposium on on Human Factors in Computing Systems and the 5th Latin American Conference on Human-Computer Interaction**. Porto Alegre, Brazil, Brazil: Brazilian Computer Society, 2011. (IHC+CLIHC '11), p. 343–352. ISBN 978-85-7669-257-7.

GONG, Ping; MA, Heather T.; WANG, Yutong. **Emotion recognition based on the multiple physiological signals**. In: 2016 IEEE International Conference on Real-time Computing and Robotics (RCAR). IEEE, 2016. p. 140-143.

GOSHVARPOUR, Atefeh; ABBASI, Ataollah; GOSHVARPOUR, Ateke. An accurate emotion recognition system using ECG and GSR signals and matching pursuit method. **Biomedical journal**, v. 40, n. 6, p. 355-368, 2017.

GOSHVARPOUR, Atefeh; ABBASI, Ataollah; GOSHVARPOUR, Ateke. Fusion of heart rate variability and pulse rate variability for emotion recognition using lagged poincare plots. **Australasian physical & engineering sciences in medicine**, v. 40, n. 3, p. 617-629, 2017.

GOSHVARPOUR, Atefeh; GOSHVARPOUR, Ateke. The potential of photoplethysmogram and galvanic skin response in emotion recognition using nonlinear features. **Physical and Engineering Sciences in Medicine**, v. 43, n. 1, p. 119-134, 2020.

GOULART, Christiane et al. Emotion analysis in children through facial emissivity of infrared thermal imaging. **PloS one**, v. 14, n. 3, p. e0212928, 2019

GRAZZI, L. Behavioural treatments: rationale and overview of the most common therapeutic protocols. **Neurological Sciences**, v. 28, n. 2, p. S67–S69, 2007. <https://doi.org/10.1007/s10072-007-0753-9>.

GREEN JA, SHELLENBERGER R. A terapia pelo biofeedback. In: Jonas WB, Levin JS. **Tratado de medicina complementar e alternativa**. São Paulo: Manole; 2001. p. 420-37.

GUO, H. et al. Heart rate variability signal features for emotion recognition by using principal component analysis and support vectors machine. In: **2016 IEEE 16th International Conference on Bioinformatics and Bioengineering (BIBE)**. IEEE, 2016. p. 274-277.

GUO, K. et al. EEG-based emotion classification using innovative features and combined SVM and HMM classifier. In: **2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)**. IEEE, 2017. p. 489-492.

GUYTON, A. C.; HALL, J.E **Tratado de fisiologia médica**. 11 ed. Rio de Janeiro: Elsevier, 2006.

HADDAD D.S., BRIOSCHI M.L., ARITA, E.S. Thermographic and clinical correlation of myofascial trigger points in the masticatory muscles. *Dentomaxillofac Radiol.*; 41(8):621-9. 2012

HAYASHI, E.; BARANAUSKAS, M. C. C. Towards a framework for the affective and emotional faces of usability. In: **IEEE. Information Society (i-Society), 2011 International Conference on**. [S.l.], 2011. p. 72–79.

HENIA, Wiem Mimoun Ben; LACHIRI, Zied. Embedded Emotion Recognition System Based on Electrocardiogram Attributes. In: **2018 41st International Conference on Telecommunications and Signal Processing (TSP)**. IEEE, 2018. p. 1-4.

HEWETT, T. T. et al. **ACM SIGCHI curricula for human-computer interaction**. ACM, 1992.

HOPPMANN, T. K. Examining the ‘point of frustration’. The think-aloud method applied to online search tasks. **Qual Quant**, v.43, p. 211-224, 2009.

HSU, Yu-Liang et al. Automatic ecg-based emotion recognition in music listening. **IEEE Transactions on Affective Computing**, 2017.

HUANG, Yongrui et al. Fusion of facial expressions and EEG for multimodal emotion recognition. **Computational intelligence and neuroscience**, v. 2017, 2017.

HWANG, Bosun et al. A novel method to monitor human stress states using ultra-short-term ECG spectral feature. In: **2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)**. IEEE, 2017. p. 2381-2384.

JOHNSON, John M.; MINSON, Christopher T.; KELLOGG JR, Dean L. Cutaneous vasodilator and vasoconstrictor mechanisms in temperature regulation. **Comprehensive physiology**, v. 4, n. 1, p. 33-89, 2011.

KHATIB, Iyad et al. Hardware/software architecture for real-time ECG monitoring and analysis leveraging MPSoC technology. In: **Transactions on High-Performance Embedded Architectures and Compilers I**. Springer, Berlin, Heidelberg, 2007. p. 239-258.

KACZMAREK, Lukasz D. et al. Effects of emotions on heart rate asymmetry. **Psychophysiology**, v. 56, n. 4, p. e13318, 2019.

KATSIGIANNIS, Stamos; RAMZAN, Naeem. 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, 2017

KATSIGIANNIS, Stamos; RAMZAN, Naeem. 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, 2017.

KAUR, B.; SINGH, D.; ROY, P.P. EEG Based Emotion Classification Mechanism in BCI. In Proceedings of the Procedia Computer Science, Sanur, Bali, Indonesia, 17–19 April 2018.

KUIKKANIEMI, Kai et al. A influência do biofeedback implícito e explícito em jogos de tiro em primeira pessoa. In: **Anais da conferência SIGCHI sobre fatores humanos em sistemas de computação**. ACM, 2010. p. 859-868.

KUMAR, Nitin; KHAUND, Kaushikee; HAZARIKA, Shyamanta M. Bispectral analysis of EEG for emotion recognition. **Procedia Computer Science**, v. 84, p. 31-35, 2016.

KWON, Jangho et al. A wearable device for emotional recognition using facial expression and physiological response. In: **2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)**. IEEE, 2016. p. 5765-5768.

LAI, Chin-Feng et al. Physiological signals anticipatory computing for individual emotional state and creativity thinking. **Computers in Human Behavior**, v. 101, p. 450-456, 2019.

LANDREANI, Federica et al. Assessment of ultra-short heart variability indices derived by smartphone accelerometers for stress detection. **Sensors**, v. 19, n. 17, p. 3729, 2019.

LANG, P. J.; GREENWALD, M. K.; BRADLEY, M. M.; HAMM, A. O. Looking at pictures: Affective, facial, visceral, and behavioral reactions. **Psychophysiology, CAMBRIDGE UNIVERSITY PRESS**, v. 30, p. 261–261, 1993.

LANG, P.; BRADLEY, Margaret M. The International Affective Picture System (IAPS) in the study of emotion and attention. **Handbook of emotion elicitation and assessment**, v. 29, p. 70-73, 2007

LANTYER. A.S et al. Biofeedback in the treatment of stress and anxiety-related disorders: a critical review. **Psico-USF**, v. 18, n. 1, p. 131-140, 2013.

LATASH, M. L.; NICHOLAS, J. J. Motor control research in rehabilitation medicine. **Disabil Rehabil**, 18:293-299, 1996.

LAURANS, G.; DESMET, P. M.; HEKKERT, P. P. Assessing emotion in interaction: Some problems and a new approach. In: **UNIVERSITE DE TECHNOLOGIE DE COMPIEGNE. Proceedings of the 4th International Conference on Designing Pleasurable Products and Interfaces, DPPI'09, Compiègne, Oct. 2009.** [S.I.], 2009.

LEE, J.; YOO, S. K. Design of user-customized negative emotion classifier based on feature selection using physiological signal sensors. **Sensors**, v. 18, n. 12, p. 4253, 2018.

LEVENTHAL, H. A perceptual-motor theory of emotion. In: **Advances in experimental social psychology**. Academic Press, 1984. p. 117-182.

LI, C.; XU, C.; FENG, Z. Analysis of physiological for emotion recognition with the IRS model. **Neurocomputing**, v. 178, p. 103-111, 2016.

LIAPIS, A. et al. UDSP+ stress detection based on user-reported emotional ratings and wearable skin conductance sensor. In: **Adjunct Proceedings of the 2019 ACM International Joint Conference on Pervasive and Ubiquitous Computing and Proceedings of the 2019 ACM International Symposium on Wearable Computers**. 2019. p. 125-128.

LIU, M. et al. Human emotion recognition based on galvanic skin response signal feature selection and svm. In: **2016 International Conference on Smart City and Systems Engineering (ICSCSE)**. IEEE, 2016. p. 157-160.

LIU, X. et al. Human emotion classification based on multiple physiological signals by wearable system. **Technology and Health Care**, v. 26, n. S1, p. 459-469, 2018.

LIU, Xucheng et al. Emotion recognition and dynamic functional connectivity analysis based on eeg. **IEEE Access**, v. 7, p. 143293-143302, 2019.

M. K. Abadi, R. Subramanian, S. M. Kia, P. Avesani, I. Patras, and N. Sebe, "DECAF: MEG-based multimodal database for decoding affective physiological responses," *IEEE Transactions on Affective Computing*, vol. 6, no. 3, pp. 209–222, July 2015

MA, G. et al. Electrocardiographic and electrooculographic responses to external emotions and their transitions in bipolar i and ii disorders. **International journal of environmental research and public health**, v. 15, n. 5, p. 884, 2018

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

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

MARISCAL, E. Gómez et al. Infrared thermography processing to characterize emotional stress: a pilot study. 2017.

MARQUÉS-SÁNCHEZ, P. et al. Thermal Infrared Imaging to Evaluate Emotional Competences in Nursing Students: A First Approach through a Case Study. **Sensors**, v. 20, n. 9, p. 2502, 2020.

MARTIN, J. L. et al. Medical device development: The challenge for ergonomics. **Applied ergonomics**, v. 39, n. 3, p. 271-283, 2008.

MARTINS. A. I. et al. The international classification of functioning, disability and health as a conceptual model for the evaluation of environmental factors. **Procedia Computer Science**, v. 14, p. 293-300, 2012.

MARZUKI, A. et al. Classification of human state emotion from physiological signal pattern using pulse sensor based on learning vector quantization. In: **2016 International Seminar on Intelligent Technology and Its Applications (ISITIA)**. IEEE, 2016. p. 129-134.

MENGHINI, L. et al. Stressing the accuracy: Wrist-worn wearable sensor validation over different conditions. **Psychophysiology**, v. 56, n. 11, p. e13441, 2019.

MILLER, N. E. How the brain affects the health of the body. In **Prevention and Early Intervention: The Bio-behavioral Perspective**, ed. by K. D. Craing and S.M. Weiss. New

MILLER, N. E.; BUNUAZIZI, A. Instrumental learning by curarized rats of a specific visceral response, intestinal or cardiac. *J. Comp. Physiol.* **Psychol**, 65:1-7, 1969.

MINHAD, K.ALI, S.; REAZ, M. Happy-anger emotions classifications from electrocardiogram signal for automobile driving safety and awareness. **Journal of Transport & Health**, v. 7, p. 75-89, 2017.

MITHBAVKAR, S.; SHAH, M.. Recognition of Emotion Through Facial Expressions Using EMG Signal. In: **2019 International Conference on Nascent Technologies in Engineering (ICNTE)**. IEEE, 2019. p. 1-6.

MORITZ, F; MEINEL, C. Mobile Web usability evaluation-combining the modified think aloud method with the testing of emotional, cognitive and conative aspects of the usage of a Web application. In: **2010 IEEE/ACIS 9th International Conference on Computer and Information Science**. IEEE, 2010. p. 367-372.

MOZOS, O. et al. Stress detection using wearable physiological and sociometric sensors. **International journal of neural systems**, v. 27, n. 02, p. 1650041, 2017.

NAWAZ, R. et al. Comparison of different feature extraction methods for EEG-based emotion recognition. **Biocybernetics and Biomedical Engineering**, 2020.

NEVES NETO AR. Curso: Biofeedback – o corpo em terapia. In: **17º Encontro Brasileiro de Psicoterapia e Medicina Comportamental**. Campinas. 28 a 31 de agosto de 2008.

NEVES NETO AR. Mesa-redonda: Bio/neurofeedback especificidade da área do psicólogo: política de desenvolvimento da profissão. In: **2º Congresso Brasileiro da Psicologia: Ciência e Profissão**. São Paulo. 05 a 09 de setembro de 2006b.

NEVES NETO AR. Simpósio Ciência e Profissão: Campo de aplicação do bio/neurofeedback na reabilitação psicológica, psicoterapia e treinamento de performances específicas. In: **2º Congresso Brasileiro da Psicologia: Ciência e Profissão**. São Paulo. 05 a 09 de setembro de 2006a.

NIEDENTHAL, P. M.; KRAUTH-GRUBER, S.; RIC, F. Psychology of emotion: Interpersonal, experiential, and cognitive approaches. [S.I.]: **Psychology Press**, 2006.

NIELSEN, J. Usability 101: **Introduction to usability**. 2003

NIELSEN, J. **Usability engineering**. [S.I.]: Elsevier, 1994.

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

NOVELETTO, F.; FILHO, P. B.; SOARES, A. V. Low Cost Biofeedback System for Muscular Strength Analysis and Training. **IEEE Latin America Transactions**, v. 14, n. 2, p. 575–581, 2016. <https://doi.org/10.1109/TLA.2016.7437195>

PAN, J; TOMPKINS, W. A real-time QRS detection algorithm. **IEEE transactions on biomedical engineering**, n. 3, p. 230-236, 1985.

PANE, E; WIBAWA, A.; PURNOMO, M.. Improving the accuracy of EEG emotion recognition by combining valence lateralization and ensemble learning with tuning parameters. **Cognitive processing**, v. 20, n. 4, p. 405-417, 2019.

PATRÃO, B. et al. Demonstration of the influence of human emotions in physiological signals. In: 2015 3rd Experiment International Conference (exp. at'15). IEEE, 2015. p. 128-129.

PESTANA-KNIGHT, E.M.; St. Louis, E.K. Electroencephalography (EEG): An Introductory Text and Atlas of Normal

PETER, C.; URBAN, B. Emotion in human-computer interaction. In: **Expanding the Frontiers of Visual Analytics and Visualization**. [S.I.]: Springer, 2012. p. 239–262.

PICARD, R. W. **Affective computing MIT Media Laboratory Perceptual Computing Section Technical Report No. 321**. [S.I.]: Cambridge, 1995.

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

PLATT, John. Sequential minimal optimization: A fast algorithm for training support vector machines. 1998.

POLLREISZ, D; TAHERINEJAD, N. A simple algorithm for emotion recognition, using physiological signals of a smart watch. In: **2017 39th annual international conference of the IEEE engineering in medicine and biology society (EMBC)**. IEEE, 2017. p. 2353-2356.

- PRATES et al. Introdução à teoria e prática da interação humano computador fundamentada na engenharia semiótica. **Atualizações em informática**, p. 263-326, 2007.
- PREECE, J; ROGERS, Y; SHARP, H. **Design de interação**: além da interação homem-computador. (tradução Viviane Possamai). 2. ed. Porto Alegre: Bookman, 2013
- RAHEEL, A. et al. Physiological Sensors Based Emotion Recognition While Experiencing Tactile Enhanced Multimedia. **Sensors**, v. 20, n. 14, p. 4037, 2020.
- RAJMANOVA, P; NUDZIKOVA, P; VALA, D. Application and technology of thermal imagine camera in medicine IFAC-PapersOnLine 48-4, 492–497, Ostrava. Czech Republic , 2015.
- RAMAKRISHNAN, S.; EMARY, I. M. E. Speech emotion recognition approaches in human computer interaction. **Telecommunication Systems, Springer**, v. 52, n. 3, p. 1467–1478, 2013.
- REDDY, N. P.; GUPTA, V. Computerized Biofeedback Systems for Homecare and Teletherapy. **21st International Conference of IEEE-EMBS**, Atlanta, Nov, 1999.
- REIS, H. et al. ECG manual prático de eletrocardiograma. In: **ECG manual prático de eletrocardiograma**. 2013. p. 121-121.
- RIBEIRO, L. N. N. **Estudo da ansiedade em alunos do ensino superior utilizando o Biofeedback**. (Tese de doutoramento não publicada). Universidade de Aveiro, Portugal. (2012).
- RIBEIRO, L. N. N. **Estudo da ansiedade em alunos do ensino superior utilizando o Biofeedback**. (Tese de doutoramento não publicada). Universidade de Aveiro, Portugal. (2012).
- RING, E.F.J.; AMMER, K.; WIECEK, B.; MURAWSKI, P. Quality assurance for termal imaging systems in medicine. *Thermology Internacional*, v. 17, n. 3, p. 103- 106, 2007
- RODRIGUES, K.; GARCIA, F.; BOCANEGRA, L.; GONÇALVES, V.; CARVALHO, V.;
- NERIS, V. Personas-driven design for mental health therapeutic applications. **SBC**, v. 6, n. 1, p. 18, 2015.
- RODRIGUES, K.; GARCIA, F.; BOCANEGRA, L.; GONÇALVES, V.; CARVALHO, V.;
- NERIS, V. Personas-driven design for mental health therapeutic applications. **SBC**, v. 6, n. 1, p. 18, 2015.
- RUDDOCK, R.W. Basic infrared thermography principles. Editora: Hardcover, 2010

IOANNOU, S. EBISCH, T. AURELI, D. BAFUNNO, H.A. IOANNIDES, D. CARDONE, B. MANINI, G.L. Romani, V. Gallese, A. Merla, The autonomic signature of guilt in children: a thermal infrared imaging study, *PLoS One* 8 (2013), <http://dx.doi.org/10.1371/journal.pone.0079440>.

KOELSTRA, C. MUHL, M. SOLEYMANI, J.-S. LEE, A. YAZDANI, T. EBRAHIMI, T. PUN, A. Nijholt, and I. Patras, "DEAP: A database for emotion analysis using physiological signals," *IEEE Trans. Affect. Comput.*, vol. 3, no. 1, pp. 18–31, Jan. 2012

SÁ, Â. A. R. **Uma Proposta de Sistema Computacional em Tempo Real para Biofeedback**. 2004. 143 f. Universidade Federal de Uberlândia. 2004.

SACHARIN, V; SCHLEGEL, K; SCHERER, K. R. **Geneva emotion wheel rating study**. 2012.

SALAZAR-LÓPEZ, E. et al. The mental and subjective skin: Emotion, empathy, feelings and thermography. **Consciousness and cognition**, v. 34, p. 149-162, 2015.

SAXENA, P. et al. Reconstructing Compound Affective States using Physiological Sensor Data. In: **2020 IEEE 44th Annual Computers, Software, and Applications Conference (COMPSAC)**. IEEE, 2020. p. 1241-1249.

SCHERER, K. R. The nature and dynamics of relevance and valence appraisals: Theoretical advances and recent evidence. **Emotion Review**, v. 5, n. 2, p. 150-162, 2013.

SCHERER, K. R.; CESCHI, G. Criteria for emotion recognition from verbal and nonverbal expression: Studying baggage loss in the airport. **Personality and social psychology bulletin**, v. 26, n. 3, p. 327-339, 2000.

SCHWARTZ, M. S. **Biofeedback: A Practitioner's Guide**. The Guilford Press, New York, 1995.

SCHWARTZ, M. S. **Biofeedback: A Practitioner's Guide**. The Guilford Press, New York, 1995.

SHACKEL et al. **Human factors for informatics usability**. Cambridge university press, 1991.

SHARMA, K. et al. A dataset of continuous affect annotations and physiological signals for emotion analysis. **Scientific data**, v. 6, n. 1, p. 1-13, 2019.

SHARMAN, Steve; CLARK, Luke. Mixed emotions to near-miss outcomes: A psychophysiological study with facial electromyography. **Journal of Gambling Studies**, v. 32, n. 3, p. 823-834, 2016.

SHAWE-TAYLOR, John et al. **Kernel methods for pattern analysis**. Cambridge university press, 2004.

SILVA, D.D.S. Diagnóstico de patologias em fachadas utilizando Termografia. 2012. 132f. Dissertação (Mestrado em Engenharia Civil). Universidade do Porto. Portugal, Cidade do Porto, 2012

SOUZA, I. de et al. **Classificação de sinais fisiológicos para inferência do estado emocional de usuários.** 2019.

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

STREHL, U. *et al.* Sustained reduction of seizures in patients with intractable epilepsy after self-regulation training of slow cortical potentials - 10 years after. **Frontiers in human neuroscience**, v. 8, p. 604, jan. 2014.

STRUNGARU, R. EMG Biofeedback System. *IEEE Eng. Biomedical*, 27: 274-278, 1991.

TAN, J et al. Recognition of intensive valence and arousal affective states via facial electromyographic activity in young and senior adults. **PloS one**, v. 11, n. 1, p. e0146691, 2016.

THOMAS, C; BEVAN, N. **Usability context analysis: a practical guide.** 1996.

TIWARI, Abhishek et al. A comparative study of stress and anxiety estimation in ecological settings using a smart-shirt and a smart-bracelet. In: **2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC).** IEEE, 2019. p. 2213-2216

TIWARI, Abhishek; FALK, Tiago H. Fusion of Motif-and spectrum-related features for improved EEG-based emotion recognition. **Computational intelligence and neuroscience**, v. 2019, 2019.

THUMBO, C. W. et al. A cognitive-affective scale for hurricane risk perception. **Risk analysis**, v. 36, n. 12, p. 2233-2246, 2016.

TULLIS, Thomas ALBERT, William;. **Measuring the user experience: collecting, analyzing, and presenting usability metrics.** Newnes, 2013.

TURABZADEH, Saeed et al. Facial expression emotion detection for real-time embedded systems. **Technologies**, v. 6, n. 1, p. 17, 2018.

VAL-CALVO, Mikel et al. Real-Time Multi-Modal Estimation of Dynamically Evoked Emotions Using EEG, Heart Rate and Galvanic Skin Response. **International Journal of Neural Systems**, v. 30, n. 4, p. 2050013-2050013, 2020.

VALDERAS, M. et al. Mutual information between heart rate variability and respiration for emotion characterization. **Physiological measurement**, v. 40, n. 8, p. 084001, 2019.

WEI, W. et al. Reconhecimento de emoções com base na estratégia de fusão ponderada de sinais fisiológicos multicanais. **Inteligência computacional e neurociência** , v. 2018, 2018.

WINCKLER, M; PIMENTA, M. S. Avaliação de usabilidade de sites web. **ESCOLA REGIONAL de Informática. Porto Alegre: SBC**, p. 1-54, 2002.

WIOLETA, S. Using physiological signals for emotion recognition. In Proceedings of the 2013 6th International

WU, G.; LIU, G.; HAO, M. The Analysis of Emotion Recognition from GSR Based on PSO. In Proceedings of the 2010 International Symposium on Intelligence Information Processing and Trusted Computing, Wuhan, China, 28–29 October 2010; pp. 360–363.

WU, Yan et al. How do amusement, anger and fear influence heart rate and heart rate variability?. **Frontiers in Neuroscience**, v. 13, p. 1131, 2019

XAVIER, R. A. C.; NERIS, V. P. de A. Measuring the emotional experience of users through a hybrid semantic approach. In: **SOCIEDADE BRASILEIRA DE COMPUTAÇÃO. Proceedings of the 13th Brazilian Symposium on Human Factors in Computing Systems**. [S.l.], 2014. p. 226–235.

YAMUZA, M. et al. Human emotion characterization by heart rate variability analysis guided by respiration. **IEEE journal of biomedical and health informatics**, v. 23, n. 6, p. 2446-2454, 2019.

YANG, J. et al. EEG-based emotion classification based on Bidirectional Long Short-Term Memory Network. **Procedia Computer Science**, v. 174, p. 491-504, 2020. York, 1987.

YUCHA, C., GILBERT, C. Evidence-Based Practice in Biofeedback and Neurofeedback. **Association for Applied Psychophysiology and Biofeedback. Colorado: Colorado Springs**. (2004).

ZHANG, Q.; Chen, X.; Zhan, Q.; Yang, T.; Xia, S. Respiration-based emotion recognition with deep learning.

ZHANG, Q et al. Respiration-based emotion recognition with deep learning. **Computers in Industry**, v. 92, p. 84-90, 2017.

ZHOU, F.; QU, X.; HELANDER, M. G.; JIAO, J. R. Affect prediction from physiological measures via visual stimuli. **International Journal of Human-Computer Studies**, Academic Press, Inc., Duluth, MN, USA, v. 69, n. 12, p. 801–819, dez. 2011. ISSN 1071-5819.