



Programa de Pós-Graduação em

# **Computação Aplicada**

**Mestrado Acadêmico**

Clarissa Almeida Rodrigues

Modelo de Classificação Automática de Sinais Fisiológicos  
para Identificação de Estresse

São Leopoldo, 2021

CLARISSA ALMEIDA RODRIGUES

**MODELO DE CLASSIFICAÇÃO AUTOMÁTICA DE SINAIS FISIOLÓGICOS PARA  
IDENTIFICAÇÃO DE ESTRESSE**

Dissertação apresentada como requisito parcial para obtenção do título de Mestre pelo Programa de Pós-Graduação em Computação Aplicada da Universidade do Vale do Rio dos Sinos - UNISINOS

Orientador: Prof. Dr. Sandro José Rigo

São Leopoldo

2021

R696m Rodrigues, Clarissa Almeida.

Modelo de classificação automática de sinais fisiológicos para identificação de estresse / Clarissa Almeida Rodrigues. – 2021.

60 f. : il. ; 30 cm.

Dissertação (mestrado) – Universidade do Vale do Rio dos Sinos, Programa de Pós-Graduação em Computação Aplicada, 2021.

“Orientador: Prof. Dr. Sandro José Rigo.”

1. Estresse. 2. Sinais fisiológicos. 3. Wearables.  
4. Aprendizagem de máquina. 5. Classificação de padrões. I. Título.

CDU 004

Dados Internacionais de Catalogação na Publicação (CIP)  
(Bibliotecária: Amanda Schuster – CRB 10/2517)

CLARISSA ALMEIDA RODRIGUES

**MODELO DE CLASSIFICAÇÃO AUTOMÁTICA DE SINAIS FISIOLÓGICOS PARA IDENTIFICAÇÃO DE ESTRESSE**

Dissertação apresentada como requisito parcial para a obtenção do título de Mestre pelo Programa de Pós-Graduação em Computação Aplicada da Universidade do Vale do Rio dos Sinos - UNISINOS

Aprovado em 09 de Abril de 2021.

BANCA EXAMINADORA

---

Sandro José Rigo - UNISINOS

---

Cristiano André da Costa - UNISINOS

---

Elisa Kern de Castro - Universidade Lusíada de Lisboa

## **ABSTRACT**

Stress has become a relevant disease in today's society, due to a number of factors linked to the context of contemporary life. This imbalance impacts both the personal and professional spheres of individuals because it is associated with the development of several pathologies. The evidence of the state of stress can be identified through different physiological changes, and wearable sensors can be used to measure these signals automatically. Machine Learning approaches have been used for the automatic identification of stress patterns based on the use of data generated by wearable sensors monitoring physiological signals. Despite positive results, these initiatives present a gap in the combined use of several physiological signals and in the use of biological markers for the annotation of data. In order to explore possibilities to describe a model for classifying stress with multiple physiological signals, experiments were developed with different signal combinations (EMG, EDA and ECG) using different machine learning algorithms, using three different datasets (BeWell, WESAD and Training2017). According to experiments carried out in the context of multisignals, the best result was using ECG and EMG when processed with Gaussian Naïve Bayes, obtaining an accuracy of 90%.

**Keywords:** Stress, Physiological signs, Wearables, Machine learning, Pattern classification, Deep learning

## RESUMO

O estresse tem se tornado uma doença relevante na sociedade atual, devido a uma série de fatores ligados ao contexto da vida contemporânea. Esse desequilíbrio impacta tanto a esfera pessoal como profissional dos indivíduos por estar associado ao desenvolvimento de diversas patologias. A evidência do estado de estresse pode ser identificada através de diferentes alterações fisiológicas, podendo ser utilizados sensores vestíveis para a medição desses sinais automaticamente. Abordagens de Aprendizagem de máquina vêm sendo usadas para a identificação automática de padrões de estresse a partir do uso de dados gerados por sensores vestíveis monitorando sinais fisiológicos. Apesar de resultados positivos, essas iniciativas apresentam uma lacuna no uso combinado de diversos sinais fisiológicos e no uso de marcadores biológicos para anotação dos dados. Com o objetivo de explorar possibilidades para descrever um modelo para classificação de estresse com múltiplos sinais fisiológicos, foram desenvolvidos experimentos com diferentes combinações de sinais (*EMG*, *EDA* e *ECG*) usando diferentes algoritmos de aprendizado de máquina, usando três diferentes *datasets* (*BeWell*, *WESAD* e *Training2017*). Segundo os experimentos realizados no contexto de multisinais, o melhor resultado foi utilizando *ECG* e *EMG* quando processado com *Gaussian Naïve Bayes*, obtendo precisão de 90%.

**Palavras-chave:** Estresse, Sinais fisiológicos, Wearables, Aprendizagem de máquina, Classificação de padrões, Aprendizagem profunda

## LISTA DE FIGURAS

Figura 1 – Elementos do Projeto BeWell	4
Figura 2 – Escopo do Projeto BeWell	5
Figura 3 - Bitalino Wearable (r)evolution Board Kit BT	13
Figura 4 - Tipos de Sinais Utilizados	26
Figura 5 - Pipeline do processo de treinamento e classificação	30
Figura 6 - Classificação dos dados coletados	33
Figura 7 - Dados consolidados com base nas anotações e leitura dos dados	33
Figura 9 - Visualização EMG por participante (eixo horizontal tempo e eixo vertical eletromiografia)	34
Figura 10 - Visualização EDA por participante (eixo horizontal tempo e eixo vertical amplitude)	34
Figura 11 – Lista de Features Utilizadas	37
Figura 12 - Esquerda: Dispositivo de aquisição de ECG portátil AliveCor. À direita: exemplos de gravação de ECG para cada classe de ritmo	38
Figura 13 - Visão geral das etapas do protocolo aplicado	42
Figura 14 – Resultado do uso do Bitalino	43
Figura 15 - Formato dos diretórios e arquivos gerados	43
Figura 16 - Média do score z para as médias das medidas de Triangular Index, NN50, Frequência Cardíaca Máxima (Max HR), Atividade Eletrodermal (EDA) e EVA-Estresse	44
Figura 17 – Segmentação de dado usando a técnica de <i>windowing</i>	46
Figura 18 - Modelo de Precisão e Modelo de Perda - Training2017 - 2 Classes	52
Figura 19 - Modelo de Precisão e Modelo de Perda - WESAD - 2 Classes	52
Figura 20 - Modelo de Precisão e Modelo de Perda - BeWell - 2 Classes	52
Figura 21 - Modelo de Precisão e Modelo de Perda - Training2017 - 4 Classes	53
Figura 22 - Modelo de Precisão e Modelo de Perda - WESAD - 4 Classes	53
Figura 23 - Modelo de Precisão e Modelo de Perda - BeWell - 4 Classes	53

## LISTA DE TABELAS

Tabela 1 – Features comumente utilizadas para detecção de dados fisiológicos	17
Tabela 2 – Comparação de artigos estudados, de acordo com os atributos selecionados	23
Tabela 3 – Matriz de Parâmetros Utilizados	47
Tabela 4 – Resultados dos experimentos de Machine Learning, comparando diferentes janelas	50
Tabela 5 - Precisão e Perda	53

## SUMÁRIO

<b>1 INTRODUÇÃO</b>	<b>1</b>
1.1 QUESTÃO DE PESQUISA E OBJETIVOS	3
1.2 METODOLOGIA	6
1.3 ORGANIZAÇÃO TEXTUAL	6
<b>2 FUNDAMENTAÇÃO TEÓRICA</b>	<b>7</b>
2.1 ESTRESSE E SEUS IMPACTOS	7
2.2. SINAIS FISIOLÓGICOS	8
<b>2.2.1 Eletroencefalograma</b>	<b>8</b>
<b>2.2.2 Eletrocardiograma</b>	<b>9</b>
<b>2.2.3 Eletromiograma</b>	<b>9</b>
<b>2.2.4 Atividade Eletrodérmica</b>	<b>10</b>
<b>2.2.5 Temperatura da Pele</b>	<b>10</b>
<b>2.2.6 Padrão de Respiração</b>	<b>11</b>
<b>2.2.7 Volume Sanguíneo</b>	<b>11</b>
<b>2.2.8 Frequência Cardíaca</b>	<b>11</b>
2.3 SENSORES VESTÍVEIS	12
2.4 PROCESSAMENTO DE SINAIS FISIOLÓGICOS	13
<b>2.4.1 Pré-Processamento</b>	<b>13</b>
2.5 APRENDIZADO DE MÁQUINA ( <i>MACHINE LEARNING</i> )	14
<b>2.5.1 Análise e Extração de Features</b>	<b>17</b>
2.6 APRENDIZADO PROFUNDO	19
<b>3 TRABALHOS RELACIONADOS</b>	<b>21</b>
<b>4 MATERIAIS E MÉTODOS</b>	<b>27</b>
4.1 VISÃO GERAL DO PROCESSO ADOTADO	27
4.2 AQUISIÇÃO DE DADOS	29
<b>4.2.1 Dataset <i>BeWell</i></b>	<b>29</b>
<b>4.2.2 WESAD</b>	<b>33</b>
<b>4.2.3 Training2017</b>	<b>36</b>
4.3 SELEÇÃO DE FEATURES E ALGORITMOS UTILIZADOS	36
<b>5 EXPERIMENTOS REALIZADOS</b>	<b>39</b>

5.1 COLETA DE DADOS COM PROTOCOLO TSST	39
5.2 ANÁLISE INTEGRADA DE CORTISOL E DADOS ADICIONAIS	41
5.3 EXPERIMENTOS PARA DETECÇÃO DE PADRÕES COM DIFERENTES COMBINAÇÕES DE SINAIS	43
5.4 EXPERIMENTOS PARA DETECÇÃO DE PADRÕES UTILIZANDO DIFERENTES DATASETS	45
5.5 ANÁLISE DOS RESULTADOS	46
<b>5.5.1 Machine Learning</b>	<b>48</b>
<b>5.5.2 Deep Learning</b>	<b>48</b>
<b>6 CONCLUSÃO</b>	<b>52</b>
6.1 CONTRIBUIÇÕES	53
6.2 TRABALHOS FUTUROS	53
<b>REFERÊNCIAS</b>	<b>55</b>

## 1 INTRODUÇÃO

O estresse tem ampliado seu impacto na sociedade, afetando todos os gêneros, idades e profissões, devido em parte aos crescentes desafios da atual dinâmica social. Os efeitos do estresse podem impactar tanto a esfera pessoal como profissional dos indivíduos, sendo especialmente associado com profissões que lidam com situações críticas, tais como motoristas, pilotos de avião, militares, policiais e cirurgiões, por exemplo (CAN et al., 2019).

O estresse é um fator essencial para a sobrevivência e evolução humana, sendo desencadeado pelas respostas fisiológicas de luta e fuga em uma situação de perigo iminente. Por outro lado, se tais reações ocorrem em demasia ou de forma persistente e crônica, podem ser prejudiciais à saúde (BOONSTRA, 2013; MCEWEN, 2017). Nesse contexto, o estresse crônico torna o ser humano mais propenso à depressão, doenças cardiovasculares, cerebrovasculares e musculoesqueléticas (CAN; ARNRICH; ERSOY, 2019).

O Sistema Nervoso Autônomo (SNA) é responsável pelas atividades involuntárias do corpo, tais como a respiração, a circulação do sangue, o controle de temperatura e a digestão. É composto pelos Sistema Nervoso Simpático (SNS) e Sistema Nervoso Parassimpático (SNP), que possuem funções e formas de atuação distintas. O SNS é responsável por responder rapidamente em situações de estresse, aumentando o ritmo dos batimentos cardíacos, pressão arterial e liberando adrenalina. Diferentemente, o SNP é responsável pelas situações de calma, desacelerando os batimentos cardíacos, diminuindo a pressão arterial e a adrenalina. Essas reações fisiológicas são indicadores que podem auxiliar na identificação do estresse (SHARMA; GEDEON, 2012).

A Internet das coisas (*Internet of Things - IoT*) é uma ferramenta que pode ser usada para coletar e transmitir tais dados fisiológicos de forma flexível, possibilitando sua utilização em análises e identificações de estados agudos ou crônicos de estresse. Cunhado primariamente por Kevin Ashton durante uma apresentação no *Massachusetts Institute of Technology (MIT)*, o termo IoT traz à luz a ideia da utilização de sensores devidamente conectados a objetos através da internet para melhorar a qualidade de vidas das pessoas (ASHTON, 2009). Como um dos exemplos de aplicação desse conceito, os dispositivos vestíveis - ou *wearable devices* - são pequenos aparelhos que o usuário pode utilizar em suas atividades do dia a dia de

forma não invasiva, para coleta de dados fisiológicos diversos. Segundo Rhodes (1997) trata-se de equipamentos portáteis que podem ser utilizados por pessoas em movimento, deixando suas mãos livres para as atividades do cotidiano. Tais instrumentos conseguem captar os dados fisiológicos do usuário e a sua interação com o ambiente por meio de sensores, transmitindo dados confiáveis aos sistemas computacionais (JOVANOVIĆ; MILENKOVIĆ, 2005).

Com o progresso da miniaturização e da microeletrônica, tais sensores estão se tornando cada vez mais eficientes e precisos. Assim, eles estão sendo utilizados para fomentar estudos que visam a identificação e a prevenção do estresse, buscando evitar sua cronicidade (HAN et al., 2017). Alguns dos sensores populares e amplamente utilizados nos estudos atuais são: Eletroencefalografia (EEG), Pulso de Volume de Sangue (BVP), Variabilidade da Frequência Cardíaca (VFC), Resposta Galvânica da Pele (GSR) e Eletromiografia (EMG) (PANICKER et al., 2019). Esta tecnologia tem se expandido rapidamente e vem sendo aplicada em diversos contextos, inclusive de forma promissora na área da saúde. Recentemente, devido à pandemia que impactou o mundo em 2021, estes sensores vestíveis também estão sendo usados como suporte para detecção dos efeitos e evidências da COVID-19, por exemplo (CHEN et al., 2021).

A utilização de recursos de Aprendizagem de Máquina para tratar sinais fisiológicos e detectar padrões de estresse apresenta resultados promissores (NATH et al., 2020). Pesquisas recentes descrevem o seu uso associado com a coleta e a anotação de dados em ambientes controlados, utilizando em sua maioria os algoritmos como *Support Vector Machine* (SVM) e *Artificial Neural Networks* (ANN) (PANICKER et al., 2019). Também existem experimentos com uso de *Deep Learning*, mas ainda considerados incipientes (BARA et al., 2020).

No entanto, faz-se necessário o desenvolvimento de estudos mais amplos envolvendo o uso diário dos sensores vestíveis e a combinação de seus múltiplos sinais.

A detecção e monitoramento precoce, através do reconhecimento automático de alterações fisiológicas associadas ao estresse crônico por sensores vestíveis, são atividades de potencial importância para a redução de custos com tratamentos de saúde, prevenindo o surgimento ou agravamento de diversas patologias (CAN et al., 2020).

Hernandez et al. (2021) e Panicker et al. (2019) destacam pontos que estão em discussão ainda, concentrados no campo da ética, tais como privacidade, além da perspectiva da confiabilidade dos resultados. Com relação à confiabilidade, outras oscilações emocionais podem também ativar o SNS e gerar sinais semelhantes de frequência cardíaca (*heart rate - HR*), assim como variação de contextos podem gerar resultados diferentes, por exemplo uma caminhada acelerada (HAN et al., 2017).

Adicionalmente, Panicker et al. (2019) relata que o eletrocardiograma (ECG) mostrou-se como o sinal fisiológico mais utilizado para identificação de estresse, porém existe uma gama substancial de outros dados que podem ser instrumentalizados. Atualmente, existem poucos trabalhos relacionados ao tema de múltiplos sinais com ampla análise de resultados, o que demonstra uma possibilidade para ampliar o espectro de aplicação e proporcionar resultados mais efetivos para o uso integrado de sensores vestíveis e tratamento de seus dados com aprendizagem de máquina e aprendizagem profunda.

## 1.1 QUESTÃO DE PESQUISA E OBJETIVOS

De acordo com uma pesquisa feita pelo *American Psychological Association* em 2017, um percentual de 77% das pessoas regularmente experimentam sintomas físicos causados pelo estresse. Além disso, avanços na área de sensores tecnológicos e aumento no uso de *wearables* podem ajudar na identificação do estresse de forma online, através da coleta e processamento de dados, usando aprendizado de máquina (modelagem e predição) e aprendizagem profunda baseado em sinais fisiológicos (biosinais), com possibilidade de sugestão de intervenções para minimização de efeitos por recomendação de profissionais da saúde.

Dada a necessidade de identificação e acompanhamento desse fator, ainda não há resultados consistentes sobre qual conjunto de sinais fisiológicos é o mais indicado para sua predição, ou se existe algum sinal específico que, de forma isolada, seja eficiente para tal (GIANNAKAKIS et al., 2019). Para este reconhecimento automático de padrões de estresse a partir de sinais fisiológicos são utilizadas as *features* destes sinais, que são propriedades individuais mensuráveis ou características do sinal sob observação. Desta forma, a partir das *features* estudadas e observadas, as características e regularidades nos dados sob análise podem ser utilizadas como padrões indicativos (BISHOP, 2006).

Como demonstrado em pesquisa recente, grande parte dos trabalhos relacionados a este t3pico tem seu foco atualmente em um 3nico tipo de sinal fisiol3gico ou na combina33o de poucos deles (PANICKER et al., 2019). Li et al. (2020) destaca que a maioria dos estudos utilizam EEG, devido a atividade cerebral ter forte rela33o com as emo33es. Sendo assim, este trabalho tem como objetivo geral a proposi33o de melhorias dos m3todos utilizados no processamento e classifica33o de sinais fisiol3gicos comumente utilizados para mensurar e identificar estresse, trazendo 3 luz a seguinte quest3o de pesquisa:

Quais as combina33es de sinais fisiol3gicos e suas caracter3sticas que permitem a obten33o de melhores resultados na identifica33o de padr3es indicativos de estresse?

Este trabalho de mestrado faz parte de um projeto de pesquisa em parceria com o Programa de P3s-Gradua33o em Psicologia, o Programa de P3s-Gradua33o em Engenharia El3trica e o Programa de P3s-Gradua33o em Ci3ncia da Computa33o da Unisinos. Al3m disso, participam do projeto professores dos Programas de P3s-Gradua33o em Computa33o e em Psicologia da Universidade *Friedrich-Alexander-Erlangen-Nuremberg* (FAU). O projeto, intitulado de *BeWell*, 3 dedicado ao desenvolvimento de um aplicativo para coleta e processamento de sinais fisiol3gicos online, sugerindo interven33es comportamentais.

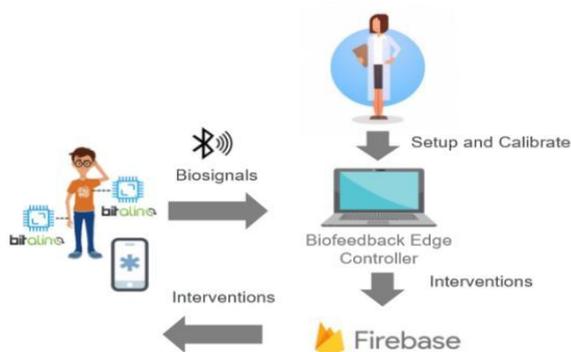


Figura 1 – Elementos do Projeto BeWell. Fonte (Rosa, 2019)

A Figura 1 descreve o cen3rio resumido do projeto *BeWell*, que consiste em um ciclo de etapas complementares, de modo que padr3es de estresse induzido atrav3s de protocolos espec3ficos (como o TSST – *Trier Social Stress Test*, entre outros)

permitam coletar e classificar os dados com base na linha do tempo pelo sensor vestível. Estes dados obtidos são utilizados para a execução de experimentos de Aprendizagem de Máquina com objetivo de identificar padrões associados aos estados de estresse.

A pesquisa desenvolvida nesta dissertação atua em uma das etapas do projeto *Bewell*, como ilustrado na figura 2. Esta etapa é voltada para a construção de um modelo de predição de padrões com uso de Aprendizagem de máquina e Aprendizagem profunda, que será integrado posteriormente em uma aplicação móvel já existente.



Figura 2 – Escopo do Projeto BeWell. Fonte (Rodrigues, 2021)

Neste contexto, dada a questão de pesquisa e o cenário de elementos do projeto, o objetivo principal desta dissertação é o desenvolvimento de estudos com abordagens de classificação de padrões de estresse obtidos em sinais fisiológicos. Para tal, os seguintes objetivos específicos foram elencados: a) verificar qual combinação de sinais fisiológicos, algoritmos de aprendizagem de máquina e *features* apresenta melhor precisão na classificação de padrões de estresse; b) verificar se o uso de múltiplos sinais apresenta melhor precisão do que o uso de um único sinal; c) verificar os impactos da combinação de sinais fisiológicos, algoritmos de aprendizagem de máquina e de aprendizagem profunda em diferentes *datasets*, com foco na precisão na classificação de padrões de estresse.

## 1.2 METODOLOGIA

Este trabalho utilizou-se da abordagem dirigida a dados, pois estimativas de predição são feitas com o uso de técnicas de aprendizagem de máquina, aprendizagem profunda e mineração de dados (BLIKSTEIN, 2011). O trabalho foi dividido nas seguintes etapas, focando nas respostas das questões de pesquisa definidas anteriormente:

- *Revisão Bibliográfica*: Revisão e investigação de trabalhos relacionados a este tema e seu estado da arte;
- *Coleta de dados*: Utilização do *wearable* para coleta de dados utilizando o protocolo TSST, utilizando diferentes combinações de biosinais e coletando o marcador cortisol, para uso futuro com os algoritmos de *machine learning*;
- *Pré-processamento*: Aplicação de filtros e outras técnicas com o intuito de remover ruídos do *dataset*, que podem diminuir a eficácia dos resultados;
- *Experimentação*: Com o *dataset* coletado, realização dos experimentos utilizando diferentes combinações de algoritmos de aprendizagem de máquina. Foram aplicados também algoritmos de aprendizagem profunda em outros *datasets* públicos;
- *Análise de Resultados*: Avaliação dos resultados obtidos, identificando se foi possível responder às questões de pesquisa e quais as contribuições geradas no trabalho.

## 1.3 ORGANIZAÇÃO TEXTUAL

No capítulo 2 são descritos os diversos tipos de sinais fisiológicos que vem sendo utilizados nesta área e como eles estão sendo processados e classificados, utilizando diferentes técnicas. Ainda, é demonstrada a importância da etapa de pré-processamento de sinais para um resultado mais efetivo de acordo com os modelos utilizados. No capítulo 3 são analisados os trabalhos relacionados com o tema, demonstrando o estado da arte da sua utilização em saúde. No capítulo 4 são exemplificados os materiais e algoritmos utilizados. No capítulo 5 os resultados de experimentos são demonstrados e os resultados obtidos são analisados. O Capítulo 6 apresenta as conclusões e indicações de trabalhos futuros.

## 2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo aborda conceitos utilizados no desenvolvimento do trabalho. Primeiramente, descreve aspectos de sinais fisiológicos e como são utilizados para a definição e identificação de estresse. Logo em seguida, são apresentados os sensores vestíveis, alguns aspectos de processamento de sinais e como eles são utilizados em conjunto com abordagens de aprendizado de máquina. Por fim, são descritas abordagens de aprendizagem de máquina e de aprendizagem profunda.

### 2.1 ESTRESSE E SEUS IMPACTOS

Estresse é uma resposta física e mental que vivenciamos ao longo da vida devido às nossas responsabilidades do cotidiano, não sendo possível evitá-lo completamente. Um estudo conduzido pelo *The American Institute of Stress* aponta que 77% das pessoas entrevistadas enfrentam regularmente sintomas físicos relacionados ao estresse, demonstrando a necessidade de controle para que não se torne crônico, pois esse pode causar doenças como obesidade, ataques do coração, diabetes tipo 2, dores de estômago, dores no corpo, infecção da próstata, interrupção do ciclo menstrual, entre outros (LEGG, 2020).

Não há evidências de métricas globais de níveis aceitáveis de estresse por ser uma característica de cada indivíduo. Porém, o *The American Institute of Stress* diferencia entre *estresse agudo* sendo a resposta automática do organismo de “lutar ou correr”, demorando 90 minutos para voltar ao seu estado normal, e o *estresse crônico* que é o estresse resultante das preocupações do dia a dia, não dando-se a devida atenção. Ainda, essa mesma organização enfatiza que estresse é geralmente associado a situações ruins, mas estados eufóricos de alegria também podem resultar nesse estado.

Biologicamente, Cohen et al. (2007) define duas formas distintas que nosso organismo reage ao estresse: uma resposta rápida ao *estresse agudo* seguindo o eixo simpático-adrenal-medular (SAM) e uma resposta lenta ao estresse crônico seguindo o eixo hipotálamo-hipófise-adrenal (HPA). Essas ações são resultado do nosso sistema nervoso autônomo, dividido entre sistema nervoso simpático (SNS) e sistema nervoso parassimpático (SNP).

Durante um fator estressante o hipotálamo ativa o SNS, sendo responsável por sinalizar a medula adrenal o envio de *epinefrina* e *norepinefrina* ao organismo (eixo SAM), aumentando pressão arterial, frequência cardíaca, entre outros fatores fisiológicos. Esta reação induz a liberação de *glicocorticóides* do córtex adrenal (HPA), sendo o Cortisol o mais importante em seres humanos, influenciando a regulação do organismo. Para isto, ele afeta o Sistema Nervoso Central (SNC) exercendo influência direta na aprendizagem, memória, sistema metabólico e imunológico, atingindo seu pico 30 minutos após o fato. Um fator crucial é que a presença de Cortisol não é um estímulo, mas sim um hormônio regulatório ao estresse, ajudando diretamente nosso organismo a estabilizar diferentes fatores fisiológicos (SMETS et al., 2018).

Adicionalmente, é necessário destacar que são possíveis coletar dados numéricos relacionados a fatores fisiológicos, diferentemente fatores psicológicos. Esses são subjetivos, exigindo suporte profissional para sua definição.

## 2.2. SINAIS FISIOLÓGICOS

Atualmente existem vários estudos utilizando sinais fisiológicos para classificação de estresse, tais como: eletroencefalograma, eletrocardiograma, pressão sanguínea, eletromiograma, temperatura da pele, resposta galvânica da pele, fotopletismograma, padrão de respiração, pressão arterial, volume respiratório, frequência cardíaca entre outros que serão detalhados em seguida.

### 2.2.1 Eletroencefalograma

O eletroencefalograma, que analisa a atividade elétrica cerebral espontânea, tem se mostrado eficaz e confiável devido a informação vir diretamente do sistema nervoso central, e por isso, ser praticamente impossível mascará-la. Nesse tipo de dado, as características das ondas como frequência, amplitude, forma e locais do couro cabeludo tornam-se relevantes para análise (NOVÁK et al., 2004). Durante o estado de estresse, ondas rápidas do tipo beta são formadas, com diminuição de ondas alpha, demonstrando maior ativação do lado direito em detrimento ao lado esquerdo (HORLINGS et al., 2008).

Por outro lado, é imprescindível a aplicação dos eletrodos no local exato, sob pena de invalidade dos dados coletados. Kwon et al. (2018) demonstraram eficácia de

73,4% através da análise de EEG com *wavelet functions*, e GSR com *Short Time Zero Crossing Rate*. Ambos os dados foram extraídos de um *DEAP dataset*, na qual uma *Convolution Neural Network* foi treinada utilizando *Maximum Likelihood Estimation*.

Recentemente, o estudo de Fares et al. (2017) atingiu um nível de acurácia de 94,79% utilizando EEG, em que participantes do processo foram submetidos a um protocolo de situações de estresse e relaxamento, quantificando-as em 3 níveis. Para seleção de features foi utilizada *Wavelet Transform*, já SVM com *Error Correction Code* para classificação.

### 2.2.2 Eletrocardiograma

O eletrocardiograma, que mede a atividade elétrica do coração, é o exame para a detecção dos sinais fisiológicos mais comumente utilizados nos estudos analisados, mostrando-se mais preciso que a variabilidade do batimento cardíaco (HRV - *heart rate variability*). ECG são constantes e com *features* definidas, como *R-R intervals*, utilizado como parâmetro para determinar a HRV. Ainda, Healey et al. (2018) demonstraram que esse tipo de sinal é melhor relacionado com o estresse do que eletromiograma (EMG) e padrão de respiração (RSP).

Han et al. (2017) utilizando-se do protocolo de simulação de estresse *Montreal Imaging Stress Task* (MIST), observaram casos em que os indivíduos foram induzidos a atingir três situações: nenhum estresse, estresse moderado e estresse elevado. Os sinais foram aferidos usando um sensor vestível, em conjunto com padrões de respiração em 39 pacientes. Foram extraídos classificadores (*features*) utilizando *Random Forest*, que é usado para selecionar a combinação ótima delas: condição de descanso, situação moderada de estresse, situação de alto estresse e situação de recuperação de estresse. O melhor resultado foi atingido utilizando a combinação de *Random Forest* e *Support Vector Machine* (SVM), melhorando a acurácia de 78% para 84% para a classificação de estresse nos três estados citados, e de 94% na detecção da presença ou não de estresse.

### 2.2.3 Eletromiograma

Eletromiograma é o exame que mede a atividade elétrica produzida pela ativação de nervos e músculos, sendo mais uma possível ferramenta a ser utilizada para

medição de estresse. Contudo, estudos demonstram que Resposta Galvânica da Pele (GSR) e Eletrocardiograma (ECG) acabam sendo mais assertivos para esse tipo de inferência (HEALEY et al., 2018).

#### **2.2.4 Atividade Eletrodérmica**

A atividade eletrodérmica, também conhecida como EDA (*Electrodermal Activity*), está relacionada à resposta periférica oriunda da ativação do sistema nervoso simpático (DOWSON; SCHELL; FILION, 2007, p. 176), cuja resposta involuntária é controlada pelo sistema nervoso central, atuando diretamente na ativação das glândulas sudoríparas da pele, responsáveis pela produção do suor devido a estimulação emocional. Também conhecida como Resposta Galvânica da Pele (GSR – *Galvanic Skin Response*) ou Condução da Pele (SC - *Skin Conductivity*), os dados coletados por essa técnica tem se mostrado significativamente eficientes devido ao fato de não terem origem cognitiva, ou seja, por serem gerados no subconsciente e, portanto, não possível de serem mascarados. Setz et al. (2010) demonstraram eficácia de 82,8% em *features* extraídos desse tipo de dado usando *Linear Discriminant Analysis* (LDA), em comparação com *nearest class center* e *SVM com linear, quadratic, polynomial e rbf kernels*.

#### **2.2.5 Temperatura da Pele**

A temperatura da pele tem se mostrado um dado auxiliar para detecção de estresse, revelando que o nosso corpo, nessa condição, promove uma baixa de temperatura no organismo, e que o contrário também é verdade (REISMAN, 1997). Durante os picos de estresse nos quais o fluxo sanguíneo é controlado pelo SNS, foi identificado que a temperatura corporal pode variar entre 0.1 e 0.2 graus Celsius, sendo possível extrair *features* como temperatura mínima, temperatura máxima e desvio padrão (KAPPELER-SETZ, 2012). Atualmente, não há estudos significativos utilizando esse sinal, somente em concomitância com outros.

### 2.2.6 Padrão de Respiração

O padrão respiratório, que é o processo de troca de gases oxigênio (O<sub>2</sub>) e dióxido de carbono (CO<sub>2</sub>) do organismo com o meio ambiente, é alterado em situações de estresse. Comprovou-se que, durante esse estado, o ser humano apresenta hiperventilação (LABBÉ et al., 2007). Assim, *features* podem ser extraídas utilizando picos (valores máximos) e vales (valores mínimos) entre pares de dados que representam o ciclo do padrão de respiração considerado normal (inspiração e expiração) nos sinais respiratórios obtidos (HAN et al., 2017). Porém, é evidente que essa análise sozinha não é suficiente para demonstrar reação ao estresse, sendo imprescindível usá-la em conjunto com outros fatores.

### 2.2.7 Volume Sanguíneo

O volume sanguíneo é obtido através da técnica de fotopletismograma (PPG - *Photoplethysmography*), que mede o volume sanguíneo de um indivíduo através de um sensor de LED colocado em seu dedo indicador. É comprovado que diminuições no volume sanguíneo estão associados com aumento dos níveis de estresse; conseqüentemente, um aumento desse fator fisiológico implica em uma diminuição dos níveis de estresse, sendo inversamente proporcionais (REISMAN, 1997). A análise do volume sanguíneo, assim, vem sendo comumente utilizado em conjunto com outros sensores para um resultado mais efetivo.

### 2.2.8 Frequência Cardíaca

A frequência cardíaca, que representa a velocidade do ciclo cardíaco medida pelo número de contrações do coração por minuto, é amplamente explorada como forma de extração de *features* através do intervalo dos batimentos cardíacos para reconhecimento de emoções. Essa extração foi feita em um dos estudos selecionados por meio de análise linear e não linear, usando *Vector distance classifier*, *Linear discriminant classifier*, kNN, *Quadratic discriminant classifier*, *Probabilistic Neural Network* e *Multi Layer Perceptron*, para inferir quatro emoções básicas, com 79% de eficácia em repouso e 83,55% em situações de euforia (VALENZA et al., 2014).

### 2.3 SENSORES VESTÍVEIS

Os sensores vestíveis (*wearables*) são integrados diretamente ao corpo para ajudar a monitorar a saúde e fornecer dados clinicamente relevantes para uma avaliação de sinais fisiológicos. As tecnologias de sensores vestíveis tem o potencial de melhorar a qualidade no acompanhamento de cuidados na saúde, atendendo às necessidades existentes de prevenção de doenças crônicas através do incentivo do paciente à utilização de tecnologias em smartphones (LUXTON et al., 2011; FROISLAND et al., 2012). Quando integradas às soluções baseadas em aplicativos móveis, as tecnologias de sensores vestíveis podem auxiliar no monitoramento e alerta ao paciente no cuidado com sua saúde de forma rápida e preventiva.

Segundo Jovanov e Milenkovic (2005), os sensores vestíveis, quando integrados aos aplicativos especializados em diagnósticos, permitem uma avaliação de sinais fisiológicos e, se necessário, também uma comunicação imediata a um profissional da área da psicologia com base nos parâmetros fisiológicos monitorados. De acordo com Weippert, Kumar e Stoll (2010), o potencial de contribuição das tecnologias de sensores vestíveis para apoiar e capacitar os usuários em monitorar seus parâmetros fisiológicos e, dessa forma, ajudá-los a controlar seus próprios comportamentos e a reduzir seu nível de estresse é promissor.

O monitoramento na vida diária utilizando dispositivos vestíveis de *biofeedback* tem como objetivo desempenhar um papel fundamental na prevenção de doenças, melhorando a qualidade de vida através de uma avaliação de sinais fisiológicos. Alguns exemplos são relógios (*smartwatches*), óculos (*smart eyewear*), roupas (*smart clothes*) e rastreador de atividades físicas (*fitness tracker*) inteligentes, podendo estes dados serem salvos localmente ou na nuvem. Em 2020 emergem os sapatos inteligentes (*smart shoes*) seguindo a tendência de Internet das Coisas (*Internet of Things*), capturando dados através de sensores, controladores, dispositivos sem fio, acelerômetro, giroscópio e magnetômetro. Estes são usados para compreender o padrão de caminhada e coletar dados, sendo esses gravados e transferidos via Bluetooth ou Wi-Fi para aplicativos móveis ou computadores (SHAH et al., 2020).

A figura 3 abaixo ilustra um desses dispositivos, o kit Bitalino, que inclui sensores para EMG, ECG, EDA, EEG, ACC, e também a comunicação por comunicação *bluetooth*.



Figura 3 - Bitalino Wearable (r)evolution Board Kit BT

Todos os sensores e outros blocos eletrônicos já estão conectados uns aos outros e prontos para uso *out-of-the-box*, sendo adequado para explorar a análise de sinais fisiológicos multimodais (UMAIR et al., 2021).

## 2.4 PROCESSAMENTO DE SINAIS FISIOLÓGICOS

Sinais são unidades físicas de medida que variam com o tempo e/ou espaço, carregando informações e podendo ser interceptados e processados por um agente de processamento, como filtragem, correlação, e análise espectral. Já um sistema digital caracteriza-se como uma combinação de hardware e software, em que cada um possui responsabilidades específicas (MITRA, 2001).

No âmbito de sinais fisiológicos, informações baseadas nesse contexto tem demonstrado maiores benefícios comparado a outras fontes de dados, sendo impossível mascará-las, pois são resultado de reações involuntárias do corpo. Soma-se a isso a simplicidade para extração dos dados devido a dispositivos de baixo custo, pouco invasivos e efetivos, a possibilidade de leitura contínua de dados e de fácil aceitabilidade entre diferentes culturas (PING et al., 2013).

### 2.4.1 Pré-Processamento

Como forma de extrair melhores resultados desse conjunto de dados, é imprescindível uma etapa de pré-processamento, que é representada pela filtragem e transformação dos mesmos com o objetivo de extração de *features*, minimizando ruídos, dados corrompidos ou faltantes (SCHALKOFF, 1992). Modelos de transformações de sinais têm sido utilizados com o intuito de facilitar seu

entendimento durante as etapas de processamento, os quais são comumente utilizados *Fourier Transform* (FT) e *Wavelet Transform* (WT).

Além disso, mais recentemente *Discrete Wavelet Transform* (DWT) tem demonstrado melhores resultados no pré-processamento para extração de *features* em dados temporais como EEG, diferentemente dos tradicionais *Fourier Transform* e *Wavelet Transform*, que acabam perdendo importantes informações da linha do tempo (YOHANES et al., 2012).

Ademais, pré-processamento vem sendo utilizado em dados fisiológicos como GSR e HRV, além do tradicional EEG, com o intuito de transformá-los do domínio de tempo para frequência, pois algumas *features* são mais recorrentes nesta última, podendo ser analisadas facilmente com o uso de FT. Outra técnica também utilizada para a preparação de sinais que faz uma adaptação similar nos dados é o WT, porém ele categoriza as frequências transformadas em componentes, obtendo melhor resultados em dados que possuem picos ou irregularidades (CLIFFORD, 2002).

Outras técnicas também utilizadas para o mesmo propósito são *Principal Component Analysis* (PCA) e *Independent Component Analysis* (ICA), sendo o primeiro eficiente na eliminação de *features* desnecessárias durante a análise inicial (DHARMAWAN, 2007), e o segundo mais efetivo na remoção de movimentos musculares, geralmente considerado como ruído ou dado inválido (HONAL et al., 2005).

## 2.5 APRENDIZADO DE MÁQUINA (*MACHINE LEARNING*)

Algoritmos cada vez mais complexos vem sendo desenvolvidos com o objetivo de adquirir conhecimento de forma automática, ou seja, “um programa de computador que toma decisões baseadas em experiências acumuladas através da solução bem-sucedida de problemas anteriores” (SCHERER et al., 2008). Esses algoritmos podem ser divididos em supervisionados, cujos exemplos de treinamento são fornecidos previamente classificados; já nos não supervisionados, o algoritmo analisa os exemplos fornecidos e tenta inferir se eles podem ser agrupados por algum parâmetro em comum (CHEESEMAN; STUTZ, 1990).

Logo, aprendizado de máquina apresenta-se como uma ferramenta poderosa, porém sem uma resposta única para todo o tipo de problema, devendo-se observar as limitações de cada algoritmo especificamente para cada tipo de problema. No

âmbito da saúde, diferentes técnicas computacionais têm sido experimentadas com o objetivo de modelar níveis de estresse com base em dados fisiológicos, embora a maioria das ferramentas e bibliotecas desenvolvidas atualmente não sejam especificamente desenvolvidas para esse tipo de informação.

A seguir são descritos brevemente algumas abordagens de aprendizagem de máquina, tais como: *Bayesian Classification*, *Decision Trees (DT)*, *Artificial Neural Networks (ANN)*, *Support Vector Machines (SVM)*, *Markov Chains* e *Fuzzy*.

*Bayesian Classification* é um método de *Machine Learning* utilizado para classificar dados probabilisticamente, baseados em características específicas, usando o Teorema de Bayes. No âmbito de dados fisiológicos, ele vem sendo utilizado para calcular probabilidades de estados de estresse (ZHAI et al., 2006). Diferentemente, *Naive Bayesian Classification* tem como premissa que as classes de dados já extraídas são independentes, usando uma regra de decisão para rotulá-las em “estresse” ou “normal”. Quando há dependência entre essas classes, *Bayesian belief* ou *Bayesian Network (BN)* são utilizadas para inferir classificadores baseados em um modelo condicional de probabilidade para determinado atributo ou variável. Diferentemente também da BN, a técnica *Dynamic Bayesian Network (DBN)* consiste em demonstrar a oscilação das variáveis ao longo do tempo.

O algoritmo *Decision Tree* é utilizado quando é necessário construir modelos de classificação dividindo o conjunto de dados principal em subconjuntos cada vez menores, associando uma árvore de decisão de forma incremental. Além disso, sua utilização está associada atualmente com outros dados fisiológicos, como EEG (DHARMAWAN, 2007).

Outro modelo bastante utilizado são as *Artificial Neural Networks (ANN)*, no qual, assim como na biologia, ANN está constantemente aprendendo e se atualizando, baseado nas experiências em que é submetido. Com o objetivo de solucionar problemas cada vez complexos, *hidden layers* podem ser adicionadas, como é o caso das *Multi-layered Perceptron (MLP)*. Apesar de tornar o método de classificação mais robusto, há um prejuízo no aumento do tempo de processamento.

Logo, a utilização desses algoritmos para gerar modelos de classificação de estresse estão atualmente em estado inicial, porém, com resultados promissores que evidenciam a importância do número de *hidden layers* ser considerado para a eficácia da análise (FUKUOKA et al., 2000). Quando poucos deles são utilizados, as ANNs não conseguem ter um resultado satisfatório com dados complexos, e, ao contrário,

seu uso em demasia pode generalizar o resultado devido ao excesso de parâmetros, diminuindo sua acurácia (BUNDELE et al., 2009).

Embora *Support Vector Machine (SVM)* possa ser utilizada tanto para classificação quanto para regressão, esse modelo é popularmente utilizado para a primeira opção. Tal tipo de técnica utiliza dados previamente rotulados (*supervised learning*) para classificar novos exemplos em duas dimensões, claramente separadas de forma linear. Alguns estudos demonstraram sua aplicação para a predição de estresse usando os dados fisiológicos de BVP, GSR e ST, enquanto outros utilizaram-na para a classificação dos sintomas do estresse, como a agitação em pacientes com demência, usando HRV, GSR e ST (SAKR et al., 2009).

Dentre os métodos baseados em estados temos ainda *Markov Chains*, que faz a transição para os fundamentados em regras de probabilidade, utilizando como base somente seu estado atual. Por outro lado, o método de *Hidden Markov Model (HMM)* assume que o dado observado não é o estado atual, mas o que foi gerado pelo *hidden layer*, que não é visível para nós e baseia-se em eventos passados. À primeira vista, essa predição aparenta dificultar a inferência dos dados, porém o resultado é o oposto, devido a sua flexibilidade e a eficiência computacional. No espectro de pesquisas referentes à identificação de estresse, HMMs são amplamente utilizadas para tal através de dados de voz (SCHULLER et al., 2003).

Estudos recentes mostram o uso da técnica de *Fuzzy Clustering*, ou seja, o agrupamento de dados com base na similaridade de suas características e variáveis, para a remoção de ruídos na mensuração de estresse (KUMAR et al., 2010) e para a sua identificação com base em HRV (KUMAR et al., 2007). Diferentemente da técnica tradicional de *clustering*, em que um dado faz parte de apenas um grupo em sua maioria, no método de *Fuzzy Clustering* os itens podem pertencer a mais de um grupo, com diferentes níveis de associação.

Evidências demonstram o uso de técnicas específicas para classificação de dados isoladamente e concomitantemente com outras, nas quais SVM apresentou melhores resultados em comparação com *Naive Bayesian* e *Decision Tree* nos trabalhos avaliados (SHARMA et al., 2012).

Mecanismos como *Neural Networks*, *Naive Bayes* e SVM se mostraram eficientes para categorizar dados em 5 classes, com eficiência de 71% para estado de relaxamento e 81% para estado de estresse elevado (HORLINGS et al., 2008). Ademais, no contexto de EEG novos métodos para extração de *features* utilizando

*wavelets* foram utilizados, como sub-bandas: gamma – diretamente associada com estados emocionais, beta, alpha, theta e delta.

*Deep Learning* vem sendo utilizado para a classificação de dados, como *Spatial Temporal Recurrent NN* rotulando-os como positivo, negativo e neutro, após extração de *features* das bandas delta, theta, alpha, beta e gamma, demonstrando acurácia de 89%, sendo esse e outros resultados sumarizados e analisados em seguida (ZHANG et al., 2019).

### 2.5.1 Análise e Extração de Features

A análise e extração de *features* de dados fisiológicos vem demonstrando grandes vantagens em relação a outras formas de coletas de dados, tais como questionários, pois esses dados não podem ser mascarados pelo participante devido ao fato ser uma resposta involuntária do organismo. Porém, um dos desafios nesta área é a grande sensibilidade desses dados ao movimento, podendo por exemplo sofrer alterações em movimentos mais rápidos nos batimentos cardíacos, o que não necessariamente significa situação de estresse (WAGNER et al., 2005).

*Features* são definidas por Bishop (2006) como características de uma propriedade individual mensurável ou característica de um fenômeno sendo observado. Na tabela 1 abaixo encontram-se descritas as mais utilizadas no contexto de detecção de padrões através de dados fisiológicos, até o ano de 2018.

**Tabela 1 – Features comumente utilizadas para detecção de dados fisiológicos**  
(adaptada de Wagner et al., 2005)

Sinal Fisiológico	Feature	Descrição
ECG	Mean HR	Frequência cardíaca (média)
	SDNN	Desvio padrão dos picos R-R
	RMSSD	Raiz quadrada média das diferenças sucessivas entre os picos R-R
	pNN20	Porcentagem de intervalos R-R sinusais normais sucessivos mais de 20ms
	pNN50	Porcentagem de intervalos R-R sinusais normais sucessivos mais de 50ms
	HF	Faixa de alta frequência dos intervalos R-R (0,15 - 0,4 Hz)
	LF	Faixa de alta frequência dos intervalos R-R (0,04 - 0,15 Hz)
	LF/HF	Razão de faixas de frequência baixa versus alta
	SD1	Desvio padrão transversal do gráfico de Poincaré
	SD2	Desvio padrão longitudinal do gráfico de Poincaré
SC	SCL	Nível de condutância da pele (média)
	SCR duration	Duração da resposta de condutância da pele
	SCR magnitude	Magnitude da resposta de condutância da pele

	SCRR	Taxa de resposta de condutância da pele
	OPD	Duração da perturbação ôhmica: período durante o qual um sujeito permanece sob efeito de estimulação e é medido desde o início do estímulo até o início da recuperação
EMG	RMS	Raiz quadrada média do sinal EMG
	Gaps	Um ou mais segmentos (0,2-4 s) em uma linha com um valor RMS abaixo de 5% da contração de referência RMS
	Static load	10% dos valores RMS ordenados por classificação
	Medium load	50% dos valores RMS ordenados por classificação
	Peak load	90% dos valores RMS ordenados por classificação
BP	SBP	PA sistólica, pressão quando o coração bate
	DBP	PA diastólica, pressão entre batimentos cardíacos
Pupil	Pupillary dilation	Diâmetro da pupila
Eye blinks	Frequency	Frequência de piscar de olhos
ST	Mean	ST médio
	SD	Desvio padrão de ST
	Slope	Declive do ST
Respiration	MeanRsp	Frequência respiratória média
	EB1	Densidade de potência espectral, somando a energia na banda 0-0,1 Hz
	EB2	Densidade de potência espectral, somando a energia na banda 0,1-0,2 Hz
	EB3	Densidade de potência espectral, somando a energia na banda 0,2-0,3 Hz
	EB4	Densidade de potência espectral, somando a energia na banda 0,3-0,4 Hz
EEG	Delta	Faixa de frequência de 0,5 - 3,5 Hz do sinal EEG
	Theta	Faixa de frequência de 4 - 7,5 Hz do sinal EEG
	Alpha	Faixa de frequência de 8 - 13 Hz do sinal EEG
	Beta	Faixa de frequência de 14 - 32 Hz do sinal EEG
	Sem	Amostra entropia

Essas características únicas de cada tipo de sinal fisiológico, que serão necessárias para treinar o modelo de classificação, podem ser extraídas manualmente ou automaticamente através de algoritmos de aprendizado de máquina. Por exemplo, *Minimum Redundancy Maximum Relevance* (mRMR) tem sido usado para seleção de *features*, reduzindo a redundância das informações e, assim, maximizando dados relevantes e mostrando resultados promissores em conjunto com *Support Vector Machine* (SVM) e *Extreme Learning Machine*, quando utilizado com *Symlets*. Em um estudo o mRMR se mostrou eficiente na seleção de 40 *features* ótimas, sendo 114 identificadas inicialmente (SAVRAN et al., 2006).

No entanto, em Kwon et al. (2018) a mRMR foi usada também para seleção de *features*, porém associada com SVM e *Random Forest* para classificação, em que este último se mostrou mais eficiente. A combinação entre esses dois últimos algoritmos se mostrou eficiente em uma outra análise (HAN et al., 2017), aumentando

a acurácia de 78% para 84% devido a sua performance em resolver problemas não-lineares, porém demonstrando limitações com parâmetros e *kernels*. Ainda, Han et al. (2017) se utilizaram do método *Random Forest* para extração de *features*, e SVM, *Linear Discriminant Analysis* (LDA), *Adaboost* e *Nearest Neighbors* (KNN) para classificação.

## 2.6 APRENDIZADO PROFUNDO

Aprendizado profundo (*deep learning* - DL), é definido como uma abordagem de aprendizado de máquina onde computadores aprendem a compreender o mundo e identificar padrões, com a experiência de análise de grandes volumes de dados, sendo estes conceitos graficamente representados através de múltiplas camadas de componentes de análise (GOODFELLOW et al., 2016). Estudos recentes mostram o seu uso incipiente, porém promissor no processamento de sinais fisiológicos (RIM et al., 2020), pois diferentemente de técnicas convencionais de *Machine Learning* é possível trabalhar com uma grande massa de dados devido à natureza de monitoramento contínuo de dados biológicos, não sendo necessário utilização de técnicas como *windowing*. Possui também a habilidade de aprendizagem contínua agrupando informações por sua similaridade, removendo assim a necessidade de seleção e extração de *features*, sendo esta a tarefa mais complexa que afeta diretamente a acurácia do modelo (MAHMUD et al., 2020).

Entre as diferentes arquiteturas existentes de DL, Mahmud et al. (2020) descreve as mais frequentemente usadas no processamento de sinais fisiológicos:

- **Autoencoder:** Rede neural (*neural network*) não supervisionada mapeando automaticamente grande quantidade de entradas em saídas menores, comumente utilizada para redução de dados;
- **Deep Belief Network (DNN):** É um algoritmo não linear de detecção de *features*, sendo composto por uma camada visível e outra não;
- **Convolutional Neural Network (CNN):** Rede neural multicamada, desenvolvida de modo que suas entradas são correlacionadas, diminuindo a necessidade de ajuste (*overfitting*) e sendo necessário menos parâmetros quando comparado com outros modelos, pois seus dados (pesos entre nodos) são compartilhados entre camadas. Mesmo em casos em que a quantidade de

dados é exorbitante, é possível resolver este problema utilizando redes minimamente conectadas, como AlexNet, VGGNet e GoogLeNet;

- **Recurrent Neural Network (RNN)**: Rede neural que detecta sequências em fluxos de dados, mapeando uma saída a uma entrada, dependendo da saída das camadas anteriores.

Santamaria-Granados et al. (2019) e Wang et al. (2020) descrevem melhores resultados de DL em comparação com ML, utilizando os *datasets* públicos AMIGOS com pré-processamento adicional removendo os picos de ECG no primeiro estudo e SRAD no segundo, com 90.09% de acurácia. Rim et al (2020) demonstram em *survey* conduzida recentemente em uma grande quantidade de trabalhos que em sua maioria utilizam-se de *dataset* públicos em comparação a dados privados.

Os trabalhos evidenciados nessa pesquisa destacam três tipos de arquiteturas, em que não foi possível compará-las pois nenhum deles utilizou-as com o mesmo *dataset*. São elas:

- **ML para extração de features e DL como classificador**: Este padrão tem por característica aumentar a precisão da classificação devido a conversão de dados brutos em *features*. O modelo de DL é treinado usando essas *features* previamente extraídas de forma supervisionada, pois suas características permitem uma melhor acurácia do modelo do que os dados sem nenhum tratamento;
- **DL para extração de features e ML como classificador**: Diferente do modelo anterior, esta arquitetura reduz a necessidade da extração de *features* manualmente, treinando o algoritmo de DL de forma não supervisionada;
- **DL**: Neste formato é utilizado somente o algoritmo de DL como forma de treinar e verificar a saída dos dados brutos. Este modelo não depende de atributos específicos de entrada, pois se entende que quanto mais o modelo “aprender” mais robusto e eficiente ele será, treinando-os de forma supervisionada.

No próximo capítulo, serão descritos como estas arquiteturas estão sendo utilizadas e parametrizadas em estudos recentes, em conjunto com seus resultados.

### 3 TRABALHOS RELACIONADOS

Com o objetivo de identificar tendências em relação ao uso de *wearables* no contexto de estresse, foi realizada uma pesquisa não sistemática e por conveniência. As bases de dados utilizadas foram a DL-ACM, IEEE, Elsevier, Springer, Science Direct foram empregadas as seguintes palavras-chaves: "*stress*", "*physiological signals*", "*machine learning*" e "*deep learning*", e selecionadas publicações desde 2015.

Na pesquisa, o objetivo foi identificar principalmente abordagens utilizadas na detecção de padrões em sinais fisiológicos e as possibilidades em seus pré-processamentos.

Uma vez obtidos os artigos preliminares pela busca nos bancos de dados, foram selecionados aqueles que continham a maior quantidade de informações de interesse para este trabalho, resultando em 16 artigos.

Embora seja um tema ainda recente, observam-se resultados promissores da utilização de algoritmos em ambiente controlado usando em grande maioria SVM e ANN (NATH et al., 2020), porém necessitando ainda de mais estudos que contemplem o seu uso diário, bem como a combinação de múltiplos sinais.

Como forma de redução de custos com tratamentos de saúde e prevenção de doenças associadas a estresse crônico, a sua detecção e seu monitoramento precoce através do reconhecimento automático dos seus fatores fisiológicos preditivos são de extrema importância (NATH et al., 2020). Desta forma, ganhos nas áreas da educação, trânsito e produtividade no trabalho poderiam ser identificados.

Além disso, mostrou-se relevante a etapa de pré-processamento dos dados, na qual os ruídos ou outros dados não relevantes são removidos, que podem diminuir a eficiência do método de classificação (CAN et al., 2019). Os principais métodos utilizados nessa etapa são *Wavelet transform* e *Passband filter*, cujo desafio é identificar o processo mais eficiente que consiga remover somente os dados não desejáveis, não causando uma distorção ou um *dataset* de dados tendencioso.

A maioria dos estudos utilizou dados coletados especialmente para o experimento, mas *datasets* públicos relacionados a oscilações emocionais como SEED - contendo as classes "positivo", "negativo" e "neutro" (ZHANG et al., 2018) e DEAP (KWON et al., 2018), ambos contendo dados fisiológicos de EEG e expressões faciais, também foram utilizados. Geralmente, para reconhecimento de tais alterações, uma grande

quantidade de dados é analisada, devido a necessidade de coleta contínua. Técnicas como janelas de tempo podem ser utilizadas como forma de reduzir esses dados, porém o desafio encontra-se em deixar o *dataset* em um tamanho suficiente para que nenhuma informação relevante seja perdida (SAEED et al., 2017).

Os trabalhos escolhidos foram analisados comparativamente com base nas seguintes informações, descritas também na tabela 2:

- **Sinais Fisiológicos:** Tipos de sinais fisiológicos utilizados e suas combinações;
- **Pré-Processamento:** Métodos e etapas de pré-processamento aplicados para eliminação de ruídos nos sinais coletados, ou amplificação de aspectos de interesse;
- **Métodos de extração de features:** Métodos de extração utilizados, relacionados com o tipo de sinal utilizado;
- **Dataset Utilizado:** Tipos de *datasets* utilizados, sendo dados reais coletados de algum experimento, dados sintéticos e ainda avaliando a sua disponibilidade para uso público;
- **Métodos de Classificação de Dados:** Algoritmos utilizados nos estudos para classificação dos dados;
- **Classes Utilizadas:** Classes extraídas utilizando diferentes métodos de classificação e sinais;
- **Precisão da Qualificação:** Análise da eficácia do resultado do estudo, usando diferentes combinações de sinais fisiológicos e métodos.

**Tabela 2 – Comparação de artigos estudados, de acordo com os atributos selecionados**

Artigo	Sinais Fisiológicos	Pré-Processamento	Método de Extração de Features	Dataset utilizado	Método de Classificação de Dados	Classes Utilizadas	Precisão da Qualificação
Detecting work-related stress with a wearable device (HAN et al., 2017)	ECG e RSP	Segmentação em intervalos de 1 minuto	Random Forest	Dados reais	SVM	Sem estresse, estresse moderado e estresse elevado	84% na classificação dos 3 estados, e 94% na sua classificação binária
Discrete wavelet transform coefficients for emotion recognition from EEG signals (YOHANES et al., 2012)	EEG	PCA	DWT	Dados reais	ELM, SVM	Feliz e Triste	84% para Triste e 89,33% para Feliz
Spatial-temporal recurrent neural network for emotion recognition (ZHANG et al., 2018)	EEG	NA	Fourier Transform	SEED (emotional EEG)	STRNN	Positivo, Neutro e Negativo	89,50%

Electroencephalography based fusion two-dimensional (2D)-Convolution Neural Networks (CNN) model for emotion recognition system (KWON et al., 2018)	EEG e GSR	<i>Wavelet transform</i> (tempo e frequência)	CNN	DEAP (EEG, physiological e video signals)	Fusion CNN	Irritado, prazer, deprimido, relaxado	73,40%
Revealing real-time emotional responses: a personalized assessment based on heartbeat dynamics (VALENZA et al., 2014)	HRV	<i>Wavelet transform</i> (tempo e frequência)	<i>NARI Point-Process</i>	Dados reais	SVM	Irritado, prazer, deprimido, relaxado	79,15% em valência e 83,55% em excitação
Method for improving EEG based emotion recognition by combining it with synchronized biometric and eye tracking technologies in a non-invasive and low-cost way (LÓPEZ-GIL et al., 2016)	EEG e EDA	ICA, <i>passband filter</i> (0.1–50 Hz) e <i>notch filter</i> (50 Hz)	PAD	Dados reais	ELM, SVM	6 níveis	Inconclusivo
Towards multilevel mental stress assessment using SVM with ECOC: an EEG approach (AL-SHARGIE et al., 2017)	EEG	Filtro entre 0.5 e 30 Hz (Butterworth filter)	DWT	Dados reais	SVM com ECOC	Sem estresse, estresse moderado e estresse elevado	94,79%
Discriminating stress from cognitive load using a wearable EDA device (SETZ et al., 2010)	EDA	Correção de erros causados pela comunicação Bluetooth	<i>leave-one-person-out cross validation</i>	Dados reais	LDA	6 níveis	82,80%
Detecting stress during real-world driving tasks using physiological sensors (HEALEY et al., 2005)	ECG, EMG, EDA e RSP	EMG foi pré-processado com um smoothing filter	Segmentação de intervalos de 5 minutos de dados durante o descanso, rodovia e cidade	Dados reais	ANN	Baixo, médio e alto	97,40%
Emotion recognition using brain activity (HORLINGS et al., 2008)	EEG	Remoção de linha de base, redução de resolução, referência e filtragem	Fourier transform	Dados reais	SVM, libsvm e naive Bayes classifier	3 classes (valência e excitação)	81%
Identifying user state using electroencephalographic data (HONAL et al., 2005)	EEG [24]	ICA	LDA	Dados reais	NN, SVM	6 estados do usuário	94,10%
Stress recognition using non-invasive technology (ZHAI et al., 2006)	BVP, GSR e ST	<i>Congruent (C)</i> e <i>Incongruent (IC)</i>	<i>Ktonas' 7-point Lagrangian interpolation</i>	Dados reais	SVM	Relaxado e Estressado	90,10%
Emotion recognition from speech: stress experiment (SCHERER et al., 2008)	EEG	ICA	<i>SVM-recursive feature elimination (RFE)</i>	Dados reais	SVM	Desgosto, neutro, feliz, triste e tenso	93,31%
Detection of fatigue of vehicular driver using skin conductance and oximetry pulse: a neural network approach (BUNDELE et al., 2009)	GSR	N/A	Segmentação em intervalos de 2 segundos para 10 assuntos	Dados reais	MLP ANN, TANH	Raiva e Medo	93,17%

An Ensemble Classification Model with Unsupervised Representation Learning for Driving Stress Recognition Using Physiological Signals (WANG et al., 2020)	EMG, ECG, GSR, HR, RESP (testados cada um separadamente)	N/A	N/A	SRAD	MLP, SLFN, AdaBoost	Sem estresse, estresse moderado e estresse elevado	90%
Stress detection using deep neural networks (Li et al., 2020)	EMG, ECG, GSR, HR, RESP, ACC, BVP	N/A	N/A	WESAD	CNN, MLP	3 estados (Sem estresse, estresse moderado e estresse) e 2 estados (elevado e estressado)	CNN: 99.80% (2 estados) e 99.55% (3 estados) MLP: 99.65% (2 estados) e 98.38% (3 estados)

Tomando como ponto de análise o tipo de sinais utilizados, observa-se que 67% dos trabalhos analisados utilizavam apenas um sinal fisiológico, 20% utilizavam dois sinais e apenas 13% dos trabalhos utilizavam três dos sinais passíveis de detecção precoce. Conforme a figura 4 abaixo, o ECG foi o sinal fisiológico mais utilizado para identificação de estresse, representando 44% dos artigos selecionados, devido à sua precisão e confiabilidade para determinar alterações emocionais (MANGALA et al., 2018). EDA aparece em 16% dos estudos, mostrando-se mais confiável que RSP, que representa apenas 8% dos estudos (DING et al., 2020), nos quais padrões de respiração vêm sendo utilizados por minimizar restrições em relação à privacidade por não conter dados sensíveis. Ainda, é possível relacionar padrões de nível baixo com estado de relaxamento e respiração irregular e rápida com raiva ou estresse, com 84% de acurácia, bem menos eficiente que ECG ou EDA (LEE et al., 2020).

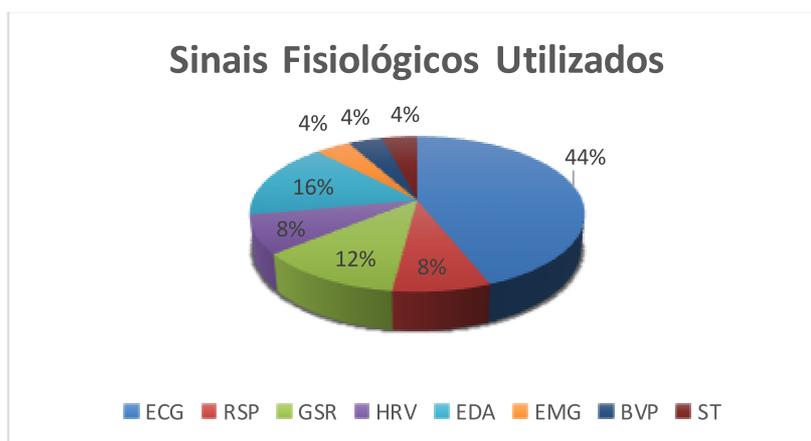


Figura 4 - Tipos de Sinais Utilizados

Utilizado em 12% dos estudos, o GSR se destaca por não ser custoso e por sua conveniência para uso no dia a dia para monitoramento em tempo real, embora não

possua a mesma eficácia que o ECG (NATH et al., 2020). O HRV, utilizado em 8% dos estudos, mostrou-se não ser de natureza contínua, fazendo-se necessária uma gravação de longo prazo com efetivo pré-processamento para cálculo da variabilidade nos intervalos R-R (GUREL et al., 2020). Além desse sinal não retornar os resultados esperados, como revelado por DING et al. (2020), durante uma tarefa de dificuldade elevada. Outros sinais como EMG, BVP e ST também foram utilizados, porém em apenas 4% dos estudos relacionados.

Além disso, é possível observar que *Support Vector Machine - SVM* é um dos métodos de classificação com base em dados supervisionados (*supervised learning*) mais utilizado nos trabalhos selecionados (PANICKER et al., 2019), devido a sua performance ser significativamente boa tanto em acurácia quanto em poder computacional. Porém, estudos mapeados na Tabela 2 (NATH et al., 2020) sugerem mais estudos com novos métodos de classificação como *unsupervised learning*, *Artificial Neural Networks*, *Deep Learning* e *Reinforcement Learning*, para que uma análise comparativa entre eles possa ser desenvolvida.

Desafios que ainda se encontram em discussão e demandam atenção são aqueles relacionados com ponto de vista ético como privacidade, segurança e legislação, e ainda com a perspectiva da confiabilidade dos resultados, custo e interoperabilidade (HERNANDEZ et al., 2021). Com relação à confiabilidade, outras fontes de alterações emocionais podem também ativar o SNS e gerar sinais semelhantes de HR, assim como situações cotidianas podem gerar viés nos resultados (PANICKER et al., 2019).

Tripathi et al. (2017) comparou o uso de CNN (81.41% e 73.36% em um modelo com duas classes de relaxamento-excitação) com DNN (66.79% e 57.58% para três classes) utilizando o *dataset* público DEAP, demonstrando melhores resultados no primeiro modelo. Embora este seja um excelente resultado, a utilização de dados pré-processados afeta diretamente o modelo, como por exemplo utilização de pequenas janelas de tempo no mesmo *dataset*, demonstrando que as informações podem se sobrepor e *features* podem ser alteradas por outras informações (CANDRA et al, 2015). Além dos bons resultados obtidos com CNN, estudo recente demonstra seu uso também em conjunto com RNN. Nesse mesmo estudo que mapeou o uso de DL em dados fisiológicos médicos por 2 anos, foi evidenciado que EEG e ECG são os sinais fisiológicos largamente utilizados, com poucos estudos no campo de multisinais - EEG com 79 estudos, ECG com 47 e multisinais com apenas 5 (RIM et al, 2020).

Somente um estudo (LI et al., 2020) foi encontrado comparando DL com diferentes algoritmos de ML usando exatamente o mesmo *dataset*, mostrando melhor acurácia usando DL comparado com ML, usando dados fisiológicos do tipo EMG, ECG, GSR, HR, RESP, ACC e BVP (DL:99,55%, LDA: 76,50%; DL:98,38%, AdaBoost: 75,21%). Quando os dados de ACC são removidos essa consistência de performance se mantém (DL:97,48%, AdaBoost: 80,34%; DL:93,64%, Random Forest: 76,17%). Apesar dos resultados promissores, não há amostra significativa ainda para que seja possível responder consistentemente qual destes é mais eficiente, devido a parametrização e complexidade entre arquiteturas.

Desta forma, o presente trabalho irá atuar no contexto identificado como uma lacuna de pesquisa quanto ao uso de diferentes sinais e sua etapa de pré-processamento, buscando identificar combinações mais promissoras para a detecção de padrões de estresse. Também não foi observado nos trabalhos estudados o uso de marcadores biológicos tais como o Cortisol, reconhecido como sendo importante para identificação de estresse, porém implicando em uma coleta invasiva, sendo realizada através de saliva ou sangue. Desta forma, sugere-se o uso desse indicador validando a etapa de anotação dos dados, garantindo uma melhor acurácia no *dataset* utilizado para os experimentos.

No próximo capítulo, será descrito o processo desenvolvido, os materiais e métodos utilizados nos experimentos desenvolvidos, bem como a visão detalhada desse processo.

## 4 MATERIAIS E MÉTODOS

Este trabalho propõe-se a examinar a relação entre múltiplos sinais fisiológicos e seu uso na classificação de estresse através de algoritmos de Aprendizagem de Máquina (*Machine Learning*) e Aprendizagem Profunda (*Deep Learning*). Com isso, busca-se colaborar com a lacuna identificada na literatura, que indica que atualmente as abordagens baseiam-se no uso de poucos sinais.

Nesse capítulo será apresentada a metodologia geral adotada, bem como a descrição das suas etapas. O item 4.1 descreve a visão geral do processo adotado na pesquisa, no item 4.2 são apresentados em detalhes os três datasets utilizados, bem com informações sobre coleta do material utilizado e seu pré-processamento. Já no item 4.3, são descritas quais as features extraídas e os algoritmos de aprendizado de máquina utilizados.

### 4.1 VISÃO GERAL DO PROCESSO ADOTADO

Este trabalho de mestrado faz parte de um projeto em parceria com o Programa de Pós-Graduação em Psicologia e Engenharia Elétrica da Unisinos e o Programa de Pós-Graduação em Ciência da Computação e Psicologia da Universidade Friedrich-Alexander Erlangen-Nuremberg (FAU). Este projeto é intitulado de *BeWell*, dedicado ao estudo de recursos para coleta e processamento de sinais fisiológicos de modo online com uso de sensores vestíveis, avaliando seu potencial para apoiar a indicação de intervenções comportamentais.

Os objetivos deste trabalho de mestrado estão associados com a etapa de aquisição e processamento de dados para detecção de padrões fisiológicos associados ao estresse, portanto uma etapa inicial do escopo do projeto citado.

O processo geral utilizado neste trabalho encontra-se subdividido em sete etapas (figura 5). As etapas são: Coleta de Dados, Pré-processamento, Rotulação de Dados, Visualização de Dados, Seleção de Atributos, Aprendizagem de Máquina e Análise de Resultados. Na etapa de Coleta de Dados, um grupo específico foi selecionado para aplicação de protocolo de coleta (*TSSST*), cujas atividades estressantes e relaxantes foram desenvolvidas em uma linha do tempo, sendo manualmente anotada por profissionais capacitados da área da saúde. A partir

desses dados devidamente coletados, é feito o Pré-processamento, aplicando-se filtros específicos a cada tipo de sinal, segmentados em janelas de tempo.

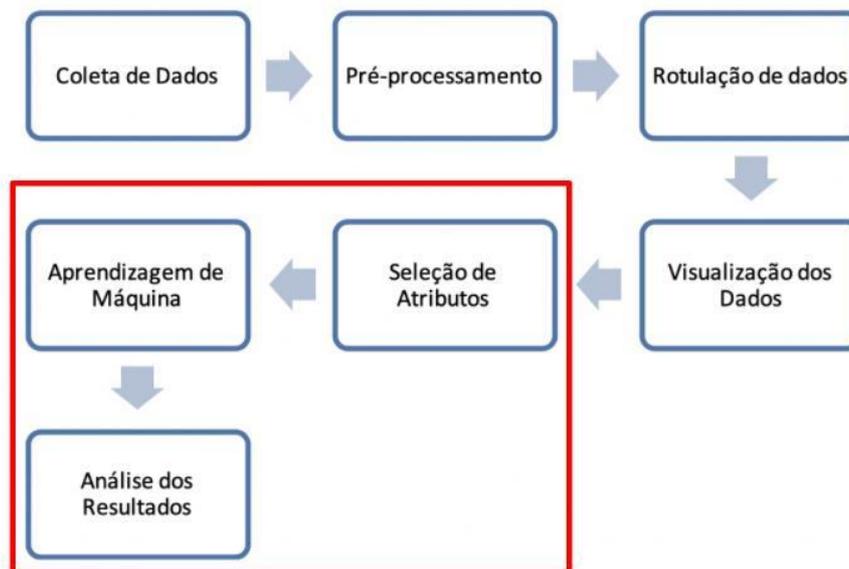


Figura 5 - Pipeline do processo de treinamento e classificação

Na etapa de Rotulação de Dados, os dados já coletados e pré-processados são revisados quanto à sua rotulação, visando a sua utilização como *dataset* de treino e teste para diferentes tipos de algoritmos de Aprendizado de Máquina.

Em seguida, na etapa de Visualização dos Dados, são aplicadas técnicas de análise de dados exploratória, visando identificar sua capacidade preditiva, com base em propriedades específicas e na qualidade da estrutura de dados a ser analisada.

A atuação deste trabalho concentra-se especificamente nas etapas de Seleção de Atributos (ou seleção de *features*), sendo utilizados posteriormente na etapa de Aprendizado de Máquina. Os algoritmos utilizados são basicamente os que possuíam maior relevância na literatura à questão de pesquisa, sendo estes **Decision Tree Classifier**, **KNeighbors Classifier**, **Random Forest Classifier** e **Gaussian Naive Bayes** com diferentes combinações de sinais de **ECG**, **EMG** e **EDA**. Finalmente, o resultado da eficácia de diferentes algoritmos foi comparado durante a Análise de Resultados.

A seguir serão descritas as etapas desenvolvidas e métodos utilizados no estudo de caso deste trabalho, desde a coleta de dados até a seleção dos algoritmos de Aprendizagem de Máquina, adicionalmente com Aprendizagem Profunda.

## 4.2 AQUISIÇÃO DE DADOS

O trabalho envolveu o uso de três *datasets* diferentes. Um deles foi gerado dentro do âmbito do projeto Bewell. Outros dois foram obtidos a partir de trabalhos relacionados que indicaram publicamente o acesso aos dados coletados. Esta experimentação com três diferentes *datasets* permitiu avançar no estudo da importância de determinadas *features* e de uso integrado de diferentes sinais, conforme os objetivos do trabalho e a questão de pesquisa.

A seguir serão detalhadas a coleta de dados de cada um dos três *datasets* utilizados e suas particularidades. É descrito em maiores detalhes o processo de coleta, processamento e rotulação do dataset *BeWell*, experimento desenvolvido por alunos e professores do Curso de Mestrado em Psicologia da Unisinos.

### 4.2.1 Dataset *BeWell*

Este *dataset* foi obtido a partir de um trabalho realizado de forma multidisciplinar, proveniente da Dissertação de Mestrado da psicóloga Andréia Rodrigues. Neste trabalho, foi efetuada a coleta de dados de 36 pacientes saudáveis após a exclusão de pacientes com doenças crônicas - como cardíacos e desordem psicológica – que usavam algum fármaco psicoativo ou que fizeram uso de cafeína ou outro estimulante, grávidas, aqueles com problemas de insônia, ou aqueles que enfrentam atualmente situação de estresse específico. Para isso, foram utilizados os questionários *Perceived Stress Scale (PSS)* para identificação do nível atual de estresse do candidato ao experimento e o *Inventory of State-Trait Anxiety Inventory (STAI)*, um dos mais conhecidos protocolos para identificação de indícios de ansiedade (RODRIGUES, 2019).

Os dados fisiológicos utilizados neste trabalho foram selecionados devido a suas características aderentes à identificação de estresse. Para isso, faz-se necessário levar em consideração as particularidades dos diferentes tipos de dados fisiológicos. Como exemplo, comumente associados à classificação de estresse encontra-se a variabilidade de frequência cardíaca (HRV), pois resulta em alterações no ritmo da respiração, alterações físicas, comportamentais e emocionais (GIARDINO; LEHRER; FELDMAN. 2000). Diferentemente da frequência cardíaca (HR), HRV elevados indicam a interação ideal entre os sistemas nervoso simpático

(SNS) e parassimpático (SNP) (LAGOS et al., 2008). Apesar dessa interação ser útil para a detecção do estresse, esse sinal é sensível a muitas variáveis, como forma de coleta e padrões pessoais de cada indivíduo (KIM et al., 2017). Já a atividade eletrodermal (EDA) é um dado fisiológico bastante confiável, pois é influenciada exclusivamente pela ativação do SNS (POSADA-QUINTERO; CHON, 2020).

A coleta foi realizada coletando os seguintes sinais fisiológicos: batimentos cardíacos, condutividade elétrica da pele e atividade elétrica muscular. Foram usados sensores para cada sinal (ECG, EDA, EMG), com base no equipamento Bitalino (UMAIR et al., 2021). Esses dados foram segmentados e analisados em diferentes janelas de tempo. Os dados de batimentos cardíacos, obtidos com o sensor de ECG, foram analisados utilizando algoritmos para *Peak detecto*, em que picos de frequência cardíaca foram extraídos, bem como outros atributos, tais como desvio padrão, juntamente com a variação da frequência cardíaca (HRV) obtida através da localização das batidas do coração como demonstrado por Malik (1996). Adicionalmente, energias relacionadas a diferentes faixas de frequência também foram analisadas.

O sinal EDA foi separado conforme procedimento utilizado por Fritz et al. (2014), dividindo-o em 2 componentes: componente fásico (*skin conductance response - SCR*) associado a eventos de resposta rápida como reações de surpresa, e outro componente tônico (*skin conductance level - SCL*) referente à resposta lenta a eventos de euforia. Para isso, utilizou-se um filtro *lowpass* de 5Hz para identificação do SCL, sendo possível extrair *features* como média, desvio padrão e faixa dinâmica, diferentemente da SCR, que foi obtida através da análise de picos.

Para o sinal EMG foi utilizado os procedimentos descritos por Wijsman et al. (2010), onde filtro *lowpass* de 50Hz foi aplicado e segmentado em janelas de 60 segundos, analisando-se a razão entre diferentes picos e amplitude média. Nesses mesmos dados outro filtro foi aplicado, dessa vez *highpass* segmentando em janelas de 5 segundos, com o objetivo de calcular os picos de frequência consideradas em bandas de 0 a 350Hz.

Na etapa de rotulação os dados de diferentes sinais fisiológicos coletados foram unificados e pré-processados, com o objetivo de melhorar a sua qualidade, aperfeiçoando, assim, diretamente a precisão do modelo (HAN; KAMBER; PEI, 2006).

Com base no estudo de caso, os momentos iniciais de cada uma das etapas de aquisição de dados foram anotados manualmente, sendo assim disponibilizados para

posterior treinamento de modelos de Aprendizagem de máquina e Aprendizagem Profunda, com a finalidade de identificar padrões.

A figura 6 mostra parte do conjunto de dados coletados, devidamente rotulados com as observações devidas, baseadas no horário e no paciente.

	DATA	PARTICIPANTE	HORAINICIO	CRONOMETROINICIO	HORAFINAL	CRONOMETROFINAL	CATEGORIA	OBSERVACOES
0	11/06/2019	P003	2019-06-11 14:19:00	00:00:00	NaT	None	Ligou Polar	None
1	11/06/2019	P003	2019-06-11 14:20:00	00:00:48	NaT	None	Ligou Esense	None
2	11/06/2019	P003	2019-06-11 14:20:00	00:01:39	NaT	None	Ligou Bewell 1 – mão	None
3	11/06/2019	P003	2019-06-11 14:21:00	00:01:51	NaT	None	Ligou Bewell 2 – peito	None
4	11/06/2019	P003	2019-06-11 14:24:00	00:04:08	2019-06-11 14:24:00	00:04:16	Instruções para coleta da linha de base	None

Figura 6 - Classificação dos dados coletados

A partir dos dados dos participantes consolidados (figura 7), fez-se o uso, nesta etapa, de pré-processamento usando a biblioteca *BioSPPy* (<https://pypi.org/project/biosppy/>), especializada em padrões de reconhecimento para sinais biomédicos, removendo assim ruídos e distorções. Ela ainda possui suporte para extração de *features*, filtragem, detecção de picos, entre outras, para os sinais fisiológicos mais usados: ECG, EMG, EDA, EEG, BVP e RSP.

	PARTICIPANT	DATA_DURATION	ANNOTATIONS_DURATION
0	P035	00:46:16	00:51:00
1	P052	01:26:00	01:02:00
2	P056	00:08:27	00:34:00
3	P059	00:19:14	01:03:00
4	P060	00:11:50	01:04:00
5	P062	00:05:17	01:02:00
6	P065	00:34:46	00:39:00
7	P071	00:03:19	00:42:00

Figura 7 - Dados consolidados com base nas anotações e leitura dos dados

Para investigações iniciais dos dados com o intuito de descobrir padrões, anomalias ou simplesmente testar alguma situação previamente assumida, utilizou-se a Análise de dados exploratória. Esse termo foi cunhado primeiramente como sendo “uma filosofia onde o pesquisador examina os dados sem ideias pré-concebidas, com o objetivo de descobrir o que os dados podem dizer a ele” (TUKEY, 1977). Para tanto, foi utilizada a biblioteca Pandas (<https://pandas.pydata.org/>) para gerar visualizações

com base nos dados coletados de ECG, EMG e EDA, segmentados individualmente por participante (figuras 8, 9 e 10). Essas imagens apoiaram os dados numéricos coletados, facilitando o uso no dia a dia por psicólogos, por exemplo.

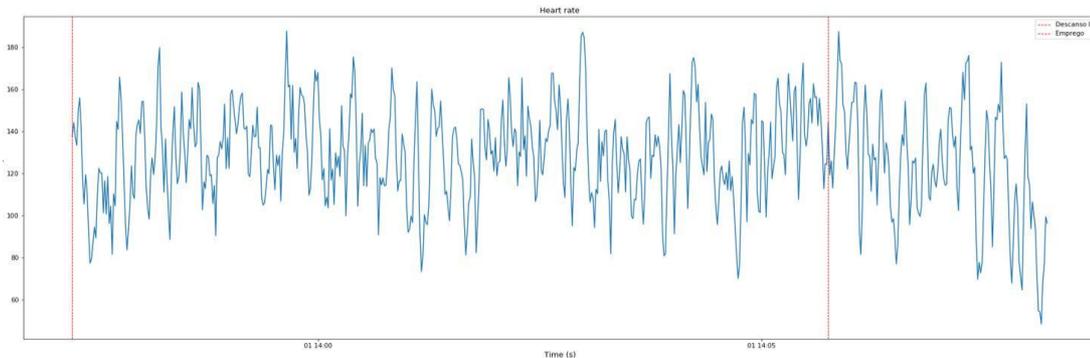


Figura 8 - Visualização ECG por participante (eixo horizontal tempo e eixo vertical amplitude)

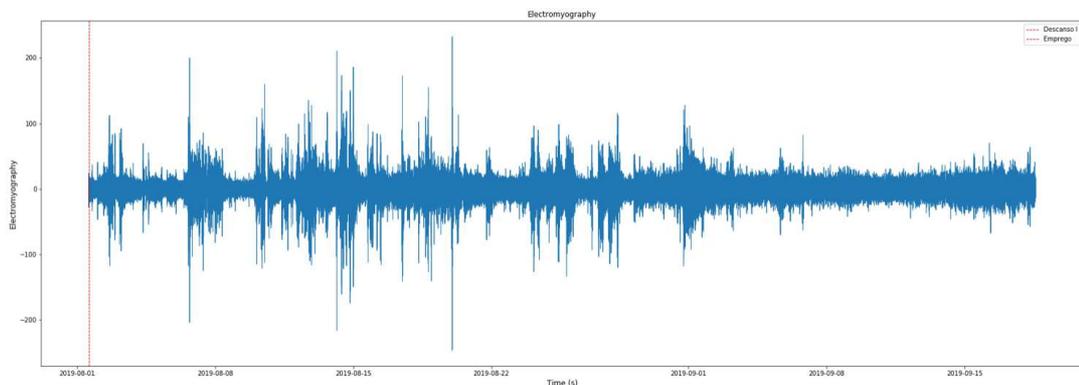


Figura 9 - Visualização EMG por participante (eixo horizontal tempo e eixo vertical eletromiografia)

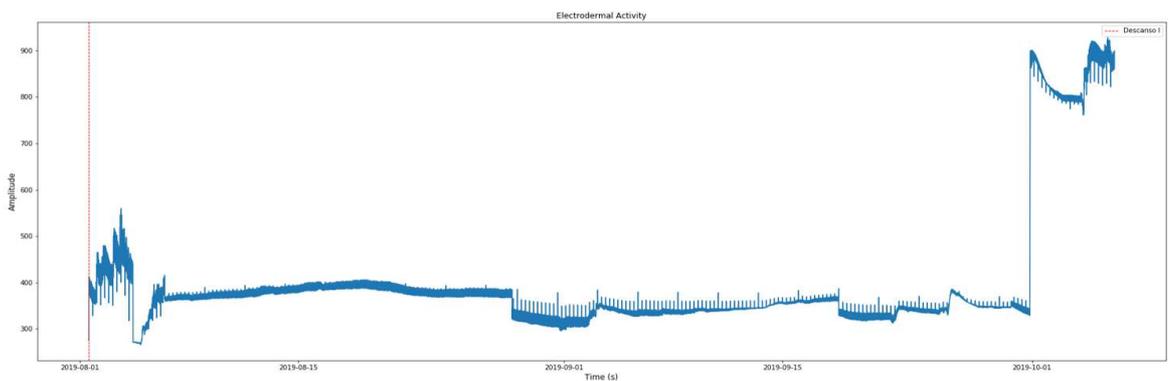


Figura 10 - Visualização EDA por participante (eixo horizontal tempo e eixo vertical amplitude)

Embora seja um tema de estudo ainda recente, este experimento inicial demonstrou resultados promissores, cujas visualizações e usos tem sido validadas em parceria com equipes multidisciplinares da área da saúde e elétrica.

#### 4.2.2 WESAD

WESAD (SCHMIDT et al., 2018) é um conjunto de dados publicamente disponível pelo Centro para *Machine Learning* e Sistemas Inteligentes da UCI (Universidade da Califórnia, UCI), amplamente utilizado para detecção de emoções. Os dados brutos do sensor foram registrados com dois dispositivos: um dispositivo usado no peito (RespiBAN) e um dispositivo usado no pulso (Empatica E4). O dispositivo RespiBAN fornece os seguintes dados do sensor: eletrocardiograma (ECG), atividade eletrodérmica (EDA), eletromiograma (EMG), respiração, temperatura corporal e aceleração de três eixos. Todos os sinais são amostrados em 700 Hz. O dispositivo Empatica E4 fornece os seguintes dados do sensor: pulso de volume sanguíneo (BVP, 64 Hz), atividade eletrodérmica (EDA, 4 Hz), temperatura corporal (4 Hz) e aceleração de três eixos (32 Hz).

Estes dados foram pré-processados usando um *sliding window* de 0,25 segundos, já os dados de aceleração foram calculados com cinco segundos como amplamente utilizado na literatura para este tipo de dado (REISS et al., 2012). Todas as *features* (exceto para características EMG e de frequência) foram calculados com um tamanho de janela de 60 segundos, em alinhamento com outros estudos (KREIBIG et al., 2010). Diferentes características estatísticas foram extraídas dos dados de aceleração, como média e desvio padrão, calculados para cada eixo separadamente e como magnitudes absolutas, somadas sobre todos os eixos (3D). Além disso, a frequência de pico foi calculada para cada eixo separadamente.

Foram aplicados algoritmos de detecção de pico nos dados de ECG/BVP brutos, com essa informação foi possível encontrar a frequência cardíaca (HR) e suas características como média e desvio padrão. Ainda a variabilidade da frequência cardíaca (HRV) foi derivada da localização do coração, como a energia em diferentes bandas de frequência. As bandas de frequência usadas foram *ultra low* (0,01-0,04 Hz), *low* (0,04-0,15 Hz), *high* (0,15-0,4 Hz) e *ultra high* (0,4-1,0 Hz). Os dados de EDA são especialmente sensíveis a alta excitação, sendo utilizado primeiramente um filtro *lowpass* de 5 Hz nos valores brutos, semelhante a outros trabalhos na área (SETZ et al., 2010).

Após isso, informações estatísticas foram calculadas (por exemplo média, desvio padrão, faixa dinâmica, etc). Esse sinal possui 2 componentes característicos: SCR que é um componente tônico responsável pela condutância da pele, e o SCL que

é o fator físico responsável por essa resposta utilizando o procedimento sugerido por Choi et al. (2012). Com isso, foi possível coletar dados adicionais como número de picos no SCR por exemplo.

Dois processos distintos foram aplicados ao EMG bruto, primeiramente utilizando filtro *highpass* foi aplicado removendo o componente DC. Em seguida, o sinal foi segmentado em janelas de 5 segundos, onde dados como frequência de pico foram calculados. Além disso, a energia espectral (PSD) foi calculada em sete frequências espaçadas uniformemente em bandas de 0 a 350 Hz. No segundo processo, foi utilizado um filtro *lowpass* de 50 Hz e em seguida segmentado em janelas de 60 segundos, sendo possível extrair informações como número de picos, amplitude média, etc.

Já no sinal de respiração um filtro *bandpass* foi aplicado, segmentando em frequências de 0,1 e 0,35 Hz, e em seguida um detector de pico foi usado para identificar mínimos e máximos. Com esse dado, a média e o desvio padrão da inspiração / expiração foram calculados, possibilitando estipular a proporção entre inalação e exalação, intervalo de alongamento e respiração, volume de inspiração, frequência respiratória e duração da respiração.

Esta amostra representa a aplicação do protocolo TSST, que abrange atividades de relaxamento e estresse devidamente cronometrados em cinco momentos: *baseline*, condição divertida, condição de estresse, meditação e recuperação. Durante as atividades de estresse, os avaliadores foram treinados a não serem receptivos, como um cálculo matemático apresentado verbalmente em frente a eles, forçando o participante a recomeçar em caso de falha. Esse procedimento foi aplicado em 15 indivíduos durante um estudo de laboratório, utilizando também questionários de auto avaliação para cada momento do protocolo como forma de validar os resultados e auxiliar na rotulação, resultando na lista final de *features* que pode ser vista na figura 11.

	Feature	Description
ACC	$\mu_{ACC,i}, \sigma_{ACC,i}$ $i \in \{x, y, z, 3D\}$ $\  \int_{ACC,i} \ $ $i \in \{x, y, z, 3D\}$ $f_{ACC,j}^{peak}$ $j \in \{x, y, z\}$	Mean, STD for each axis separately and summed over all axes Absolute integral for each/all axes Peak frequency for each axis $i$
ECG and BVP	$\mu_{HR}, \sigma_{HR}$ $\mu_{HRV}, \sigma_{HRV}$ $NN50, pNN50$ $TINN$ $rms_{HRV}$ $f_{HRV}^x$ $x \in \{ULF, LF, HF, UHF\}$ $f_{HRV}^{LF/HF}$ $\sum_x^f$ $x \in \{ULF, LF, HF, UHF\}$ $rel_x^f$ $LF_{norm}, HF_{norm}$	Mean, STD of the HR Mean, STD of the HRV # and percentage of HRV intervals differing more than 50 ms Triangular interpolation index Root mean square of the HRV Energy in ultra low, low, high, and ultra high frequency component of the HRV Ratio of LF and HF component $\sum$ the freq. components in ULF-HF Relative power of freq. component Normalised LF and HF component
EDA	$\mu_{EDA}, \sigma_{EDA}$ $min_{EDA}, max_{EDA}$ $\partial_{EDA}, range_{EDA}$ $\mu_{SCL}, \sigma_{SCL}, \sigma_{SCR}$ $corr(SCL, t)$ $\#_{SCR}$ $\sum_{SCR}^{Amp}, \sum_{SCR}^t$ $\int_{scr}$	Mean, STD of the EDA signal Min and max value Slope and dynamic range Mean, STD of the SCR/SCL Correlation btw SCL and time # identified SCR segments $\sum$ SCR startle magnitudes and response durations Area under the identified SCRs
EMG	$\mu_{EMG}, \sigma_{EMG}$ $range_{EMG}$ $\  \int_{EMG} \ $ $\tilde{\pi}_{EMG}$ $P_{EMG}^{10}, P_{EMG}^{90}$ $\mu_{EMG}^f, \tilde{f}_{EMG}$ $f_{EMG}^{peak}$ $PSD(f_{EMG})$ $\#_{EMG}^{peaks}$ $\mu_{EMG}^{Amp}, \sigma_{EMG}^{Amp}$ $\sum_{EMG}^{Amp}, \tilde{\sum}_{EMG}^{Amp}$	Mean, STD of EMG signal Dynamic range Absolute integral Median of the EMG signal 10th and 90th percentile Mean, median and Peak frequency Energy in seven bands # peaks Mean, STD of peak amplitudes $\sum$ and normalised $\sum$ of peak amplitudes
RESP	$\mu_x, \sigma_x$ $x \in \{I, E\}$ $I/E$ $range_{RESP}, vol_{insp}$ $rate_{RESP}$ $\sum_{RESP}$	Mean, STD of inhalation (I) and exhalation (E) duration Inhalation/exhalation ratio Stretch, Volume Breath rate Respiration duration
TEMP	$\mu_{TEMP}, \sigma_{TEMP}$ $min_{TEMP}, max_{TEMP}$ $range_{TEMP}$ $\partial_{TEMP}$	Mean, STD of the TEMP Min, max TEMP Dynamic range Slope

Figura 11 – Lista de Features Utilizadas (Schmidt et al., 2018)

Além disso, o conjunto de dados preenche a lacuna entre estudos de laboratório anteriores sobre estresse e emoções, contendo três diferentes estados afetivos (neutro, estresse, diversão).

#### 4.2.3 Training2017

Este conjunto de dados publicado por Goldberger et al. (2000) foi disponibilizado para *Physionet Challenge Computing in Cardiology 2017*, que é um fórum online para a disseminação e troca de sinais biomédicos gravados e o software para análise de tais sinais. Os competidores foram convidados a construir um modelo para classificar uma forma de onda de ECG de derivação única como Ritmo Sinusal Normal, Fibrilação Atrial, Outro Ritmo ou Ruidoso como demonstrado na figura 12.

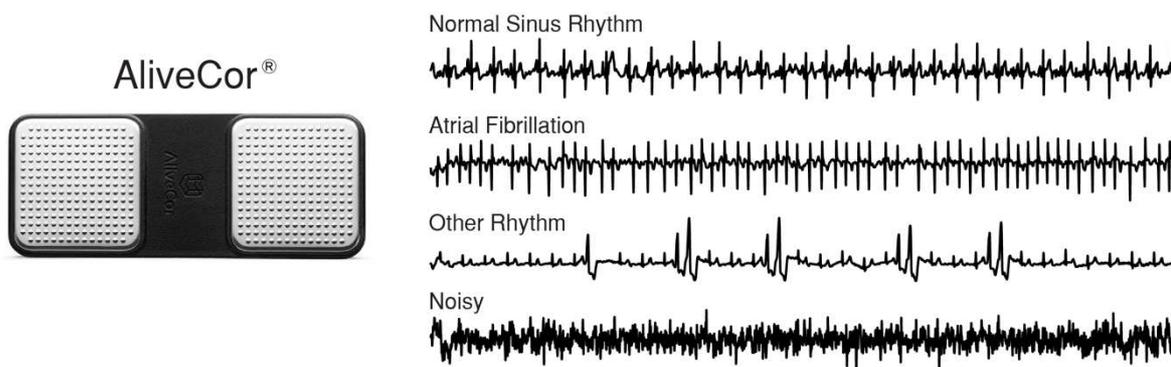


Figura 12 - Esquerda: Dispositivo de aquisição de ECG portátil AliveCor. À direita: exemplos de gravação de ECG para cada classe de ritmo, Goodfellow et al. (2018).

O conjunto de dados consistia em 12.186 formas de onda de ECG doadas pela AliveCor. Os dados foram adquiridos por pacientes usando uma das três gerações do dispositivo de ECG de canal único da AliveCor. As formas de onda foram registradas por uma média de 30 segundos com a forma de onda mais curta sendo 9 segundos e a forma de onda mais longa sendo 61 segundos.

#### 4.3 SELEÇÃO DE FEATURES E ALGORITMOS UTILIZADOS

Neste trabalho foram realizados experimentos de *Machine Learning*, onde selecionamos os algoritmos já estabelecidos por se mostraram relevantes para o tipo de situação-problema como **Decision Tree Classifier**, **KNeighbors Classifier**, **Random Forest Classifier** e **Gaussian Naive Bayes** (NATH et al., 2020) em diferentes combinações de dados **EMG**, **EDA** e **ECG**. Adicionalmente, foram

realizados experimentos de e *Deep Learning* com algoritmos que se destacam na literatura com a combinação de **rede neural convolucional (CNN)** e **rede neural recorrente (RNN) (LSTM)**, utilizando diferentes janelamentos (10 e 100 frames) em três diferentes *datasets* (**BeWell, WESAD e Training2017**).

No contexto de ML a extração de *features*, que representa alguma informação relevante para a solução da questão sob investigação, se mostrou relevante, pois afeta diretamente a eficácia do modelo (CAN et al., 2019). Técnicas populares para extração de *features* incluem transformações de *Fourier* (FT) e Transformações *wavelet* (WT), removendo ruídos em séries temporais como parte do pré-processamento dos dados ou extraindo características específicas (HAAK et al, 2018). O mesmo autor ainda pontua que é comum transformar dados fisiológicos como ECG, GSR e HRV de tempo para frequência, sendo possível extrair informações que são visíveis depois da transformação utilizando WT. FT também pode ser utilizado nessa transformação, porém apresenta melhor performance quando os dados possuem picos e baixas acentuadas.

Já nos dados de ECG tem se mostrado útil para a extração de *features* técnicas como Análise de Componentes Principais (PCA) e Análise de Componentes (ICA), mas que também podem ser utilizadas no pré-processamento para redução de *features* não desejáveis (DHARMAWAN et al., 2007). Can et al. (2019) destacam na literatura que os sinais mais efetivos e menos intrusivos para detecção de estresse são EDA e HR, especialmente no domínio de frequência baixa, frequência alta e utilizando as duas ao mesmo tempo.

Adicionalmente, é comum a segmentação dos dados para redução do material a ser analisado, devido à natureza do monitoramento contínuo dos dados fisiológicos. Usando este recurso é possível capturar perspectivas diferentes, e também reduzir o efeito do ruído de dados ausentes, diferentemente da análise bruta (HEALEY et al, 2005).

DL tem emergido como uma possibilidade viável frente a ML, pois remove algumas complexidades presentes em ML como extração de *features* manualmente, o que acaba por ser um processo geralmente trabalhoso e demorado, mas tem grande impacto no desempenho do modelo. Por sua vez, DL elimina a necessidade de pré-processamento de dados “aprendendo” automaticamente através da combinação dos resultados da camada anterior, transformados em um novo conjunto de *features* por meio de um mapeamento não linear (ZHANG et al., 2020).

Wang et al. (2020) observa que classificação do estresse através de *features* extraídas de sinais fisiológicos é um desafio, pois a relação entre o estado de estresse e a maioria delas não são claras. Eles indicam maiores estudos nesse campo, sugerindo o uso de DL nesse contexto, como por exemplo uma rede neural convolucional (CNN) para capturar a dependência local entre vários sensores, enquanto a rede neural recorrente (RNN) poderia aprender os recursos temporais dos sinais da série temporal. Além disso, diferentes tipos de redes também podem ser combinadas em um modelo híbrido.

Zhang et al. (2020) adiciona que técnicas de DL como *autoencoder*, rede neural convolucional (CNN) e rede neural recorrente (RNN) tiveram um impacto significativo (com quase desempenho de nível humano) em visão computacional, reconhecimento de fala, reconhecimento de objetos, processamento de linguagem natural (PNL) e tradução automática. Devido ao fato que DL pode realizar abstração de alto nível de dados, tem sido usado para desenvolver arquiteturas reconfiguráveis para reconhecimento de emoção. Infelizmente, DL requer grande número de dados rotulados que podem ser difíceis de coletar em cenários de aplicativos do mundo real.

No próximo capítulo, experimentos de ML e DL foram executados e serão detalhados, pois possuem especificidades que influenciam diretamente a eficácia do modelo. Com isto, busca-se responder a questão-problema sobre quais combinações de sinais e qual arquitetura de aprendizagem de máquina é mais eficiente para classificação de estresse usando dados fisiológicos.

## 5 EXPERIMENTOS REALIZADOS

Neste capítulo serão apresentados os experimentos realizados neste trabalho. As atividades de coleta de dados e análise de cortisol, respectivamente os itens 5.1 e 5.2 desse capítulo, foram realizadas de forma multidisciplinar pelos grupos de pesquisa da Engenharia Elétrica e Psicologia. Estes experimentos são descritos pois são usados para os experimentos de detecção de padrões. O item 5.3 e 5.4 apresenta experimentos realizados com este e outros dois *datasets*, utilizando algoritmos de ML e DL respectivamente.

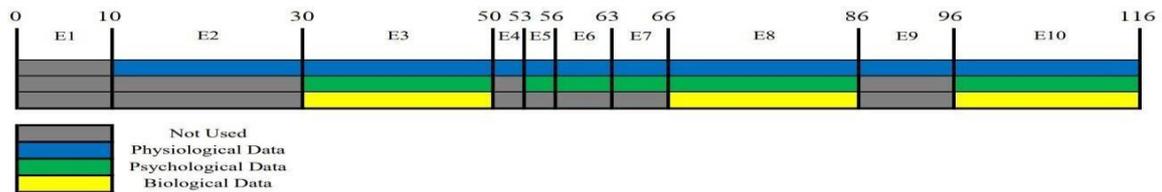
### 5.1 COLETA DE DADOS COM PROTOCOLO TSST

Foi aplicado na amostra de indivíduos selecionada o protocolo TSST (*Trier Social Stress Test*), no qual os estados de estresse e de relaxamento foram induzidos de forma intermitente em diferentes etapas, e os sinais fisiológicos foram coletados em cada uma dessas tarefas de forma controlada, como demonstrado na figura 13. Durante a *etapa 1*, o paciente respondeu um questionário específico analisando a viabilidade de participação no experimento, considerando fatores pré-existentes que afetariam os resultados. Na *etapa 2*, o paciente teve um tempo de descanso de 20 minutos para garantir estado de repouso, para que, na *etapa 3*, os sensores fossem alocados corretamente e a amostra de saliva fosse coletada.

Já na *etapa 4*, o procedimento e a atividade estressante a serem desenvolvidos foram explicados, e se basearam em uma apresentação verbal a uma mesa de jurados. Durante a *etapa 5*, o participante teve 3 minutos para preparar seu discurso, e ao final desse tempo ele teve 5 minutos para sua apresentação em frente ao júri. Durante a *etapa 6*, o participante foi requisitado para uma tarefa aritmética durante 5 minutos – considerada como uma atividade estressante – na qual o mesmo deveria subtrair mentalmente e continuamente, o mais rápido possível, o número 17, começando com 2023. Se algum erro acontecesse, o júri o interromperia e pedir-lhe-ia que recomeçasse a tarefa. Já nos momentos finais, na *etapa 7*, o participante recebeu instruções para coletar o resultado do teste posteriormente; na *etapa 8* foi coletado feedback e clarificado perguntas, e na *etapa 9* foi aplicada uma técnica de relaxamento, que consistiu na atividade de inspiração por 4 segundos e expiração por 6 segundos.

Na *etapa final*, a saliva foi coletada novamente para avaliação de níveis de cortisol, assim como aconteceu no início do processo.

Figura 13 - Visão geral das etapas do protocolo aplicado (Rodrigues, 2019)



Em cada uma dessas etapas foi utilizado o dispositivo *BeWell* (composto pelo sensor Bitalino Kit - PLUX Wireless Biosignals S.A.), os sensores de *eletrocardiograma (ECG)* - usando o dispositivo *Polar RS800CX Heart Rate Variability Monitor* para a coleta, que foi posteriormente processado via *Núbios HRV Software Version 3.1* usando RMSSD calculation - em conjunto com sensores de *atividade eletrodermal (EDA)* colocado diretamente nos dedos, através do dispositivo *MindField Esense Skin Response*. Um sensor adicional foi responsável pela coleta do *eletromiograma (EMG)*. Adicionalmente, o cortisol foi coletado utilizando o kit *Elisa* da *DRG Instruments* e foi analisado por estudantes treinados do *Grupo de Estudos Avançados em Psicologia da Saúde (GEAPSA)*.

Esses sensores tiveram como objetivo captar diferentes dados, como a variabilidade de frequência cardíaca (HRV) e a frequência cardíaca (HR) através do *EEG*. Adicionalmente, o *EDA* teve por finalidade a captura de sinais elétricos conduzidos pela pele, que é basicamente o suor produzido pela pele quando o SNS é ativado. Finalmente, o *EMG* foi responsável pela coleta da atividade elétrica das glândulas sudoríparas e tradução em sinais numéricos. Para futura análise ainda foram coletados dados através de um sensor de acelerômetro, para diferenciar a aceleração entre movimento físico e resposta emocional. Esses resultados foram pré- validados por especialistas na área da psicologia e registrados como *Statistical Package for the Social Sciences – SPSS, version 25.0*, e podem ser visualizados na figura 14.

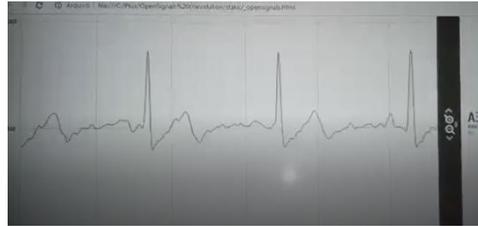


Figura 14 – Resultado do uso do Bitalino

O *dataset* foi salvo em uma matriz, com o número de amostras lidas para cada canal. Os valores de cada leitura individual foram no tamanho de 10 bits, que representaram valores de 0 a 1023. Esses dados foram salvos diretamente sem tratamento algum em arquivos individuais (extensão “.data”), ou seja, pode-se dizer que a cada amostra recebida (que em geral é de 1000) um arquivo “.data” foi criado. Os nomes dos arquivos foram gerados de forma sequencial.

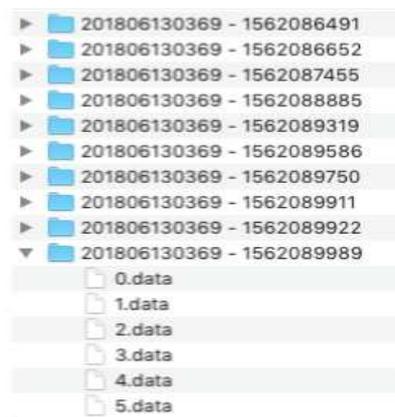


Figura 15 - Formato dos diretórios e arquivos gerados

O nome da pasta onde os arquivos foram armazenados foi composto pelo endereço MAC do dispositivo que realizou a leitura e pelo *timestamp* de início da leitura. No caso de diversas leituras terem sido realizadas em sequência, quando ocorreu interrupção das leituras por algum motivo foram geradas diversas pastas com o respectivo *timestamp*, permitindo que os dados fossem tratados de forma integrada posteriormente, como demonstrado na figura 15.

## 5.2 ANÁLISE INTEGRADA DE CORTISOL E DADOS ADICIONAIS

Este experimento fez parte do projeto multidisciplinar intitulado *BeWell*, demonstrado no trabalho “Avaliação do estresse através de dispositivos *wearables*”:

Contribuições da psico-fisiologia para a clínica em Psicologia” de autoria de Andréia Kunzler Rodrigues (RODRIGUES, 2019). Neste estudo, 36 voluntários foram submetidos ao protocolo TSST para indução de atividades estressantes e relaxantes, sendo coletados biosinais relevantes para leitura e interpretação da HRV, EDA, HR e cortisol.

As amostras de saliva dos pacientes foram processadas e a análise de Cortisol revelou acurácia geral superior a 95% utilizando HRV (NN50 e HRV Triangular Index), Max HR, EDA e a EVA-Estresse como medidas significativas para a predição de estresse agudo (figura 15). Particularidades em diferentes sinais foram identificadas, dentre as quais EDA mostrou-se efetivo para detecção de estresse, mas não para medir sua recuperação após atividades estressantes, apresentando queda lenta nesse sinal.

Conforme mesmo trabalho, o Cortisol é um fator de referência para identificação de estresse, sendo utilizado nos experimentos e análises para apoiar a identificação do estresse contida nos sinais coletados nos sensores vestíveis. Uma característica relevante do Cortisol é que ele apresenta elevação somente 30 minutos após o início do evento, sendo mais adequado para a confirmação no momento da análise do que o monitoramento em tempo real. Ademais, a combinação de sinais que medem tanto a SNS quanto a SNP, como o EDA e a HRV, pode indicar uma boa compreensão da dinâmica entre esses sistemas (LIMA et al., 2019).

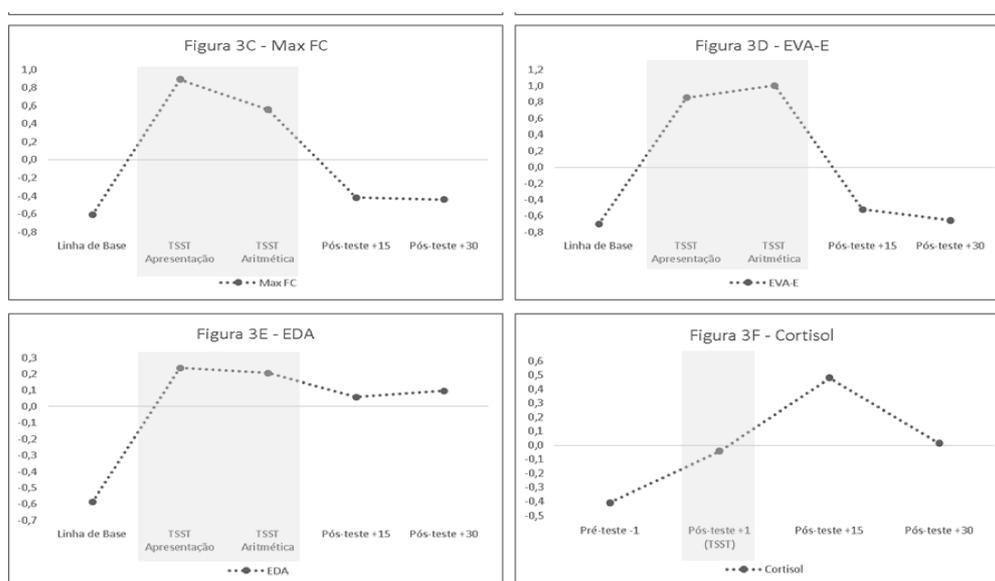


Figura 16 - Média do escore z para as médias das medidas de Triangular Index, NN50, Frequência Cardíaca Máxima (Max HR), Atividade Eletrodermal (EDA) e EVA-Estresse. Fonte: Rodrigues 2019.

Ainda, na figura 16, observa-se que a curva de aumento do Cortisol é consistente com os estados do processo TSST, correspondendo, em linhas gerais, a expectativa do experimento em gerar estresse e relaxamento.

Embora os resultados até o momento sejam promissores, este mesmo estudo identifica a lacuna do uso de *Machine Learning* utilizando padrões de Cortisol para reforçar a anotação de dados feitas previamente em cada etapa, contexto ainda pouco explorado para detecção e predição de estresse.

Nath et al. (2020) corrobora com esse ponto, mostrando que é possível relacionar sinais fisiológicos (não invasivos) com o Cortisol (invasivo), que é considerado o padrão-ouro de medição de estresse, permitindo o desenvolvimento de um modelo de estresse independente do sujeito.

### 5.3 EXPERIMENTOS PARA DETECÇÃO DE PADRÕES COM DIFERENTES COMBINAÇÕES DE SINAIS

Experimentos visando a detecção de padrões foram conduzidos na linguagem Python, pela aderência às bibliotecas disponíveis para visualização de dados, algoritmos de Aprendizado de Máquina e filtragem de sinais. Durante esse processo, foi identificada uma lacuna com dados faltantes em determinado período de tempo, resultante provavelmente de uma falha de comunicação entre o dispositivo *Bitalino* e o computador receptor dos dados.

Para isso, o *script* desenvolvido leu arquivos com os dados coletados de cada participante comparando com os dados anotados manualmente durante a aplicação de cada etapa do procedimento, utilizando a biblioteca *Pandas* para análise de dados exploratória (EDA). Com os dados já pré-processados, estes foram comparados com os dados anotados manualmente, baseados no *timestamp*.

Após a consolidação desses dados, eles foram segmentados nas seguintes janelas de tempo: *Baseline*, *TSST*, *Aritmética*, *Sensor Pos-Test I*, *Sensor Pos-Test II* e *Sem Categoria* - esta última sendo criada para armazenar os dados de participantes que tiveram falhas nos dados durante a coleta, e após descartados do experimento.

Foram utilizados dados de um participante como *dataset* de teste, e de outros três participantes como *dataset* de treino para os algoritmos de aprendizado de máquina. Na próxima etapa, os dados foram filtrados utilizando a biblioteca *Biosppy*, específica para análise de dados fisiológicos, como BVP, ECG, EMG, EDA e EEG. Os

dados classificados como filtrados foram usados para adquirir a taxa de variabilidade linear de todos os dados anteriormente adquiridos.

Devido à complexidade de análise de uma grande quantidade de dados – aproximadamente 1.886.000 linhas de dados – a técnica de *windowing* foi utilizada, na qual uma função matemática foi aplicada com o objetivo de reduzir a quantidade de dados, removendo uniformemente de cada janela de tempo, simetricamente. Como forma de prevenir eventuais distorções causadas por esse processo, o cálculo delta foi aplicado aos dados removidos. Tal processo pode ser exemplificado na figura 17, quando aplicado em 1000 linhas de dados usando uma janela de 10 linhas, resultando em 100 linhas de “dados puros” e em 100 linhas de dados baseados na média dos dados removidos, totalizando 200 linhas.

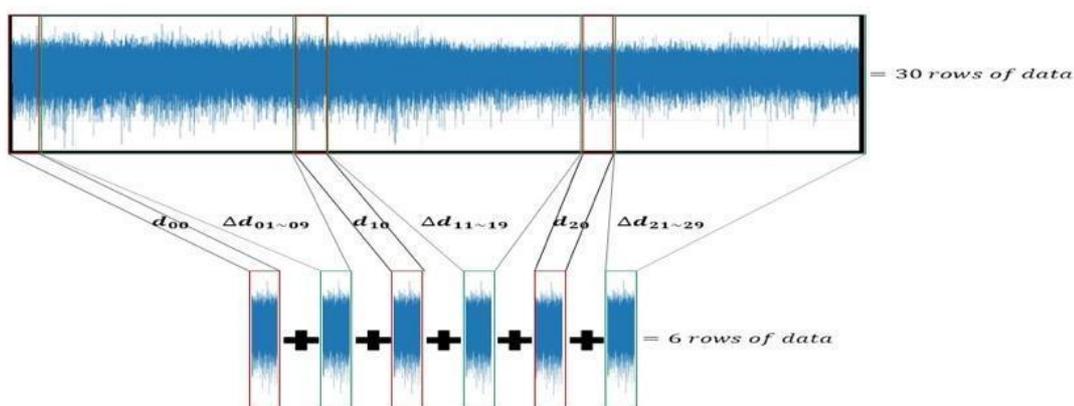


Figura 17 – Segmentação de dado usando a técnica de *windowing*

Após a redução considerável na quantidade de dados, eles foram divididos em *dataset* de treino com os dados de todos os sinais e *dataset* de teste, devidamente segmentados em categorias que foram utilizadas nos algoritmos de aprendizado de máquina, e armazenados em arquivos em formato *numpy*.

Com o objetivo de verificar a melhor eficácia, a seguinte combinação de dados foi utilizada: ECG, somente EMG, somente EDA, ECG com EMG, ECG com EDA e EMG com EDA. Quatro algoritmos foram aplicados, utilizando a biblioteca de código aberto *Scikit-Learn*: Decision Tree Classifier, KNeighbors Classifier, Random Forest Classifier e Gaussian Naive Bayes. Para cada algoritmo utilizado quatro métricas foram coletadas, segmentadas em janelas de 10 e 100 *frames*: acurácia, precisão, *recall* e F1 (combinação de *recall* e precisão). O resultado deste experimento, com

diferentes combinações de algoritmos, *frames* de tempo e sinais fisiológicos obtiveram resultados similares.

Utilizando janelas de 10 *frames* o processamento demorou 30% mais tempo, no qual o tempo adicional no processamento não é justificado devido a melhoria de eficácia extremamente irrelevante entre elas. Além disso, muitas das combinações não tiveram resultados quando utilizado SVM, seja ele *Linear* ou *Radical kernel*, somente quando utilizado dados de ECG.

Ademais, é possível observar que os dados fisiológicos de EDA não obtiveram resultados significativos para identificação de estresse, quando usado de forma isolada ou combinada. Entre os dados utilizados, EMG mostrou-se o mais relevante, especialmente quando processado com *Gaussian Naïve Bayes*. Futuramente, sugere-se que este experimento seja reprocessado utilizando-se uma maior quantidade de dados e integrando-o a dados de Cortisol.

#### 5.4 EXPERIMENTOS PARA DETECÇÃO DE PADRÕES UTILIZANDO DIFERENTES DATASETS

Cada um dos três conjunto de dados (*BeWell*, *WESAD* e *Training2017*) foram treinados duas vezes utilizando rede neural convolucional em conjunto com rede neural recorrente (CNN + RNN), utilizando diferentes janelamentos (10 e 100 frames), primeiro realizando uma classificação binária e um segundo realizando a classificação com todas as classes disponíveis no conjunto de dados. Todos os conjuntos de dados foram treinados em 30 épocas e com dimensões definidas das matrizes, pois como cada *dataset* possui uma quantidade de dados diferente, interferindo na disposição dos dados nas matrizes conforme demonstrado na tabela 3.

**Tabela 3 – Matriz de Parâmetros Utilizados**

	Training2017		WESAD		BeWell	
<b>Número de Classes</b>	2	4	2	4	2	5
<b>Colunas</b>	2590	3650	100	100	3800	9500
<b>Linhas</b>	9000	9000	240	360	1000	1000
<b>Largura</b>	20	20	10	10	10	10
<b>Altura</b>	450	450	24	36	100	100
<b>Canal</b>	1	1	35	35	1	1

Devido as características de cada conjunto de dados, sua preparação antes da aplicação do modelo também é diferente. Apesar dessas diferenças, procurou-se realizar o tratamento o mais próximo possível dos dados, como forma de evitar que esse tratamento afetasse diretamente o desempenho do conjunto de dados no treinamento. Na preparação dos dados do *Training2017*, a matriz é reformulada e o código identifica quais dados representam cada classe, o mesmo método é aplicado para os outros conjuntos de dados, sendo aplicados filtros diferentes daqueles aplicados nas etapas anteriores por Goldberger et. al (2000).

O conjunto de dados *WESAD* foi preparado usando a biblioteca *Numpy* para *Fast Fourier Transform* (FFT), como forma de extrair *features* como recomendado por Schmidt et al. (2018), gerando de oito a trinta e cinco *features*. Durante a fase de experimento, ele foi testado removendo o número de *features* e o resultado de precisão permaneceu próximo ao obtido com todos as *features*. Finalmente, para a preparação do conjunto de dados *BeWell*, foram aplicados filtros além dos aplicados pelos autores do conjunto de dados, os quais foram aplicados com filtros da biblioteca *BioSPPY*, para filtrar ruídos de sinais fisiológicos.

A seguir, será apresentada a análise comparativa entre os experimentos descritos até o momento, e sua efetividade em relação a questão-problema.

## 5.5 ANÁLISE DOS RESULTADOS

Com o objetivo de comparar a melhor abordagem no contexto de multissinais, modelos de *Machine Learning* foram comparados com um modelo híbrido de *Deep Learning*, combinando CNN e LSTM. De acordo com a revisão bibliográfica utilizada, este tipo de modelo híbrido tem apresentado bons resultados em termos de predição de padrões em sinais fisiológicos.

Os experimentos utilizando ML utilizando o dataset *BeWell* atingiram a precisão de 89% de utilizando ECG e EMG com Gaussian Naive Bayes no treinamento binário, porém quando adicionada mais classes no experimento foi possível observar a precisão reduzir para cerca de 60%, dependendo do conjunto de dados usado para o treinamento. Ainda, os sinais de ECG tendem a apresentar uma maior diferença entre os sinais normais e alterados, sendo mais úteis em análises para classificação de sinais, embora os demais sinais contribuam para uma maior precisão na predição. Com os resultados obtidos, é possível concluir que uma classificação binária para

sinais fisiológicos tende a ter maior acurácia, principalmente quando treinados dois sinais distintos, como alterado e normal, sem as fases intermediárias entre um estado e outro.

Já os experimentos de DL foram feitos usando três conjuntos de dados diferentes (WESAD, Training2017 e BeWell), dois voltados para detecção de estresse e um voltado para classificação de sinais com ou sem arritmia. Os conjuntos de dados WESAD alcançou uma precisão de 87% quando treinados com todos os sinais disponíveis como também quando treinados de forma binária, muito próximo do *dataset* Training2017 com 84%, diferentemente do BeWell que apresentou precisão de 49%, muito provavelmente pela falha no aparelho durante a coleta de dados.

Com base nestes resultados, o presente trabalho buscou evidências sobre quais combinações de sinais fisiológicos e suas *features* permitiriam melhores resultados na identificação de padrões indicativos de estresse utilizando algoritmos de *Machine Learning*, e também *Deep Learning*, em diferentes *datasets*. Para tanto, foram demonstrados resultados adquiridos através de dois *datasets* públicos e de um *dataset* obtido em um estudo de caso desenvolvido em colaboração com pesquisadores de Psicologia da Unisinos e da FAU.

Estas evidências respondem suficientemente à pergunta de qual modelo de ML e combinação de sinais fisiológicos possuem melhor precisão - ECG e EMG com 87% de precisão com Gaussian Naive Bayes, colaborando a clarificação da questão de pesquisa levantada, demonstrando que o modelo poderia ser usado para este tipo de predição.

Ainda, o trabalho apresenta um modelo híbrido de DL com precisão de 87% utilizando o *dataset* Training 2017 contendo dados de ECG, adaptável a quaisquer sinais fisiológicos para treinamento de outros *datasets* além dos três já utilizados, pois elimina a necessidade de extração de *features*. Diferentemente de outros estudos encontrados até o momento, este trabalho compara de forma inovadora DL aplicada a diferentes *datasets* validando este modelo, além dos experimentos utilizando ML.

Como sugestão para trabalhos futuros, por se tratar de um tema incipiente com poucos trabalhos na área, sugere-se novos estudos com a utilização dos mesmos conjuntos de dados públicos, aumentando o número de *features*, bem como avaliar possíveis extrações de *features* como realizado em o conjunto de dados do WESAD. Para isto, é necessário realizar uma análise aprofundada dos sinais obtidos com cada conjunto de dados de forma mais precisa, sem distorcer os sinais ou acabar

prejudicando o treinamento. Adicionalmente é possível utilizar dados de Cortisol, o principal marcador biológico em relação ao estresse, como forma de suporte para rotulação de dados ou validação da eficácia do modelo.

### 5.5.1 Machine Learning

Nesta etapa foram utilizadas diferentes combinações de sinais com o objetivo de determinar qual o melhor método. As combinações usadas foram: apenas ECG, apenas EMG, apenas EDA, ECG e EMG, ECG e EDA, e EMG e EDA.

*Scikit-Learn*, uma biblioteca de código aberto para Python, foi selecionada para aplicar os experimentos de ML com módulos de diferentes algoritmos. Para cada combinação foram aplicados quatro algoritmos: **Decision Tree Classifier**, **KNeighbors Classifier**, **Random Forest Classifier** e **Gaussian Naive Bayes**. Para cada algoritmo, quatro métricas foram usadas para avaliar os resultados: exatidão, precisão, recall e pontuação F1 (a combinação de recall e precisão). Com base nessas informações, é possível determinar o melhor método para implementar um sistema de detecção de estresse.

Durante os experimentos foram utilizadas duas abordagens diferentes de janelamento, a primeira com 10 frames e a segunda com 100 frames. O processo realizado com uma janela de 10 vezes demonstrou uma execução consideravelmente mais demorada, cerca de 30% mais do que a janela 100 vezes. A maioria das combinações não retornou bons resultados ao aplicar a maioria dos algoritmos, e apenas o sinal de ECG apresentou resultado significativo.

Em relação às métricas obtidas, ambas apresentaram resultados muito semelhantes. Comparando as métricas resultantes das diferentes janelas realizadas durante o processo e todas as quatro combinações, o melhor contexto em precisão foi a combinação de **ECG e EMG com Gaussian Naive Bayes** com 90% usando 100 frames.

### 5.5.2 Deep Learning

Da mesma forma como nos experimentos anteriores, cada conjunto de dados foi treinado duas vezes, uma com apenas os dois sinais mais interessantes e distintos e uma segunda vez com todos os sinais disponíveis no conjunto de dados.

Abaixo estão os resultados gráficos obtidos no treinamento, relacionando acurácia e perda para cada um dos conjuntos de dados.

Nas três figuras abaixo estão presentes os resultados obtidos durante o treinamento dos modelos com apenas duas classes, primeiro os resultados relativos ao conjunto de dados *Training2017* usando ECG (figura 18), em seguida os resultados do conjunto de dados *WESAD* usando ECG, EMG, EDA, BVP, fluxo respiratório e acelerômetro (figura 19) e, por fim, o *BeWell* usando ECG (figura 20). Especificamente neste último, utilizando em conjunto com o EMG o resultado foi bem inferior (diferentemente de ML), já o resultado não satisfatório em conjunto com o EDA foi o mesmo quando utilizado ML, assim como nos experimentos de ML.

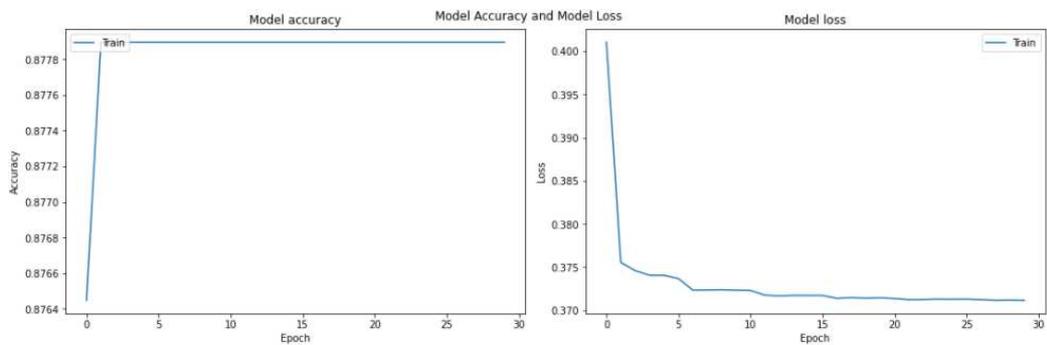


Figura 18 - Modelo de Precisão e Modelo de Perda - Training2017 - 2 Classes

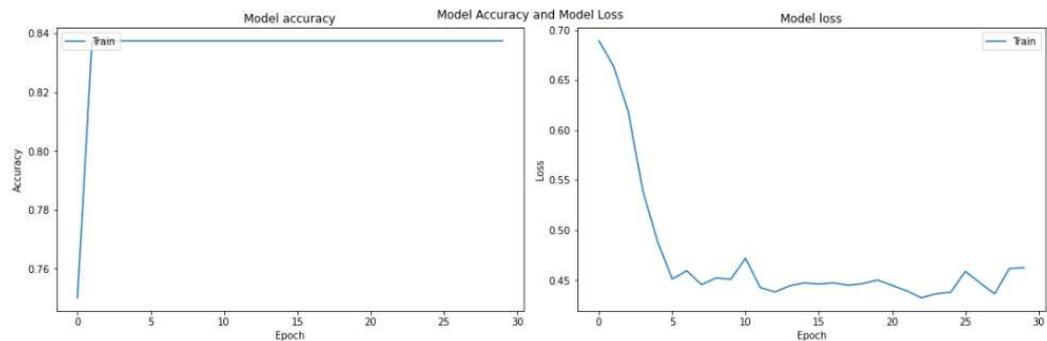


Figura 19 - Modelo de Precisão e Modelo de Perda - WESAD - 2 Classes

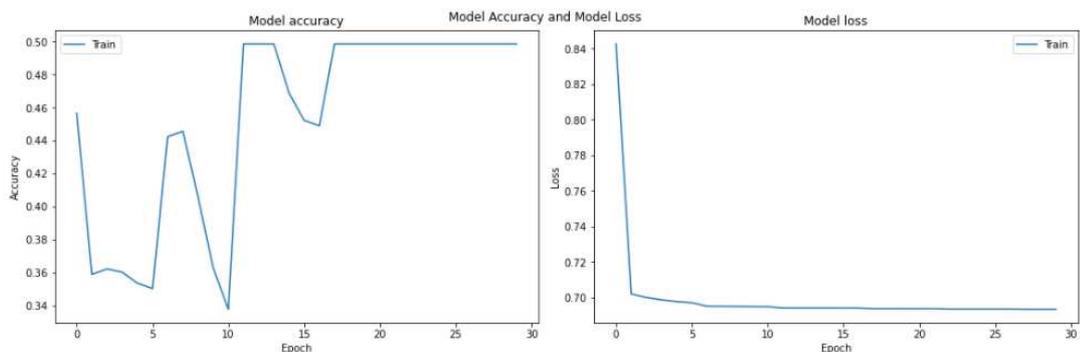


Figura 20 - Modelo de Precisão e Modelo de Perda - BeWell - 2 Classes

Em seguida, estão apresentados os resultados gráficos utilizando todas as classes disponíveis nos mesmos respectivos *datasets*, *Training2017* (figura 21), em seguida os resultados do conjunto de dados *WESAD* (figura 22) e, por fim, o *BeWell* resultados (figura 23).

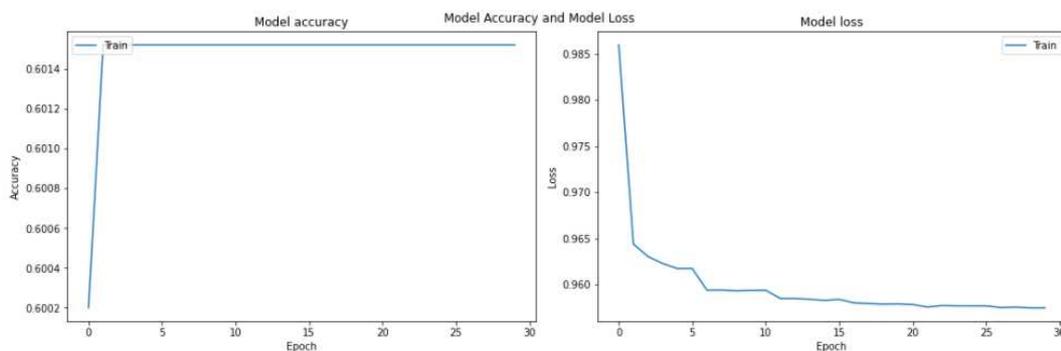


Figura 21 - Modelo de Precisão e Modelo de Perda - Training2017 - 4 Classes

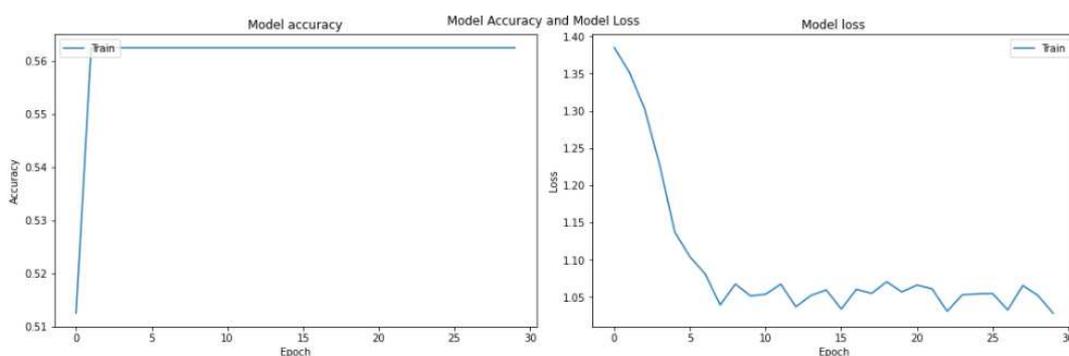


Figura 22 - Modelo de Precisão e Modelo de Perda - WESAD - 4 Classes

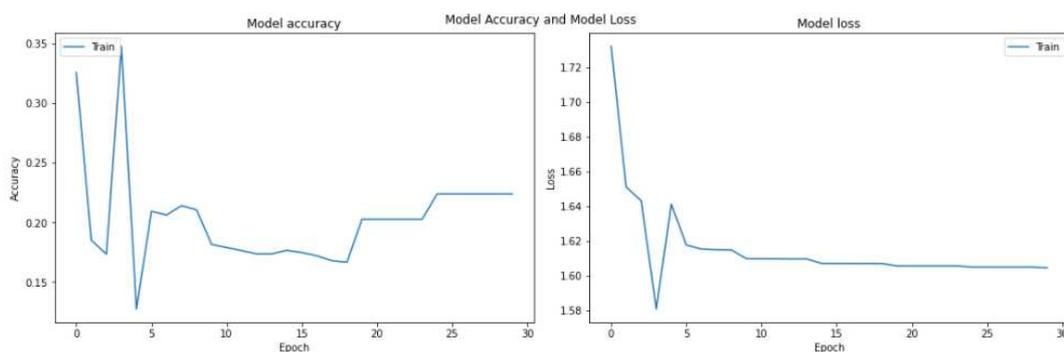


Figura 23 - Modelo de Precisão e Modelo de Perda - BeWell - 4 Classes

Na tabela 4 abaixo é possível visualizar dados comparativos de precisão e perda nos três *datasets* utilizados. A precisão é medida após o modelo ser parametrizado, testado e corrigido, comparando o acerto em alvos reais e o número de erros com base em amostras de teste fornecidas ao modelo. Já o valor de perda implica o quão bem ou mal um determinado modelo se comporta após cada iteração

de otimização - idealmente, seria de se esperar a redução da perda após cada, ou várias, interações.

**Tabela 4 - Precisão e Perda**

	Training2017		WESAD		BeWell	
Número de Classes	2	4	2	4	2	5
Precisão	0,8779	0,6015	0,8375	0,5625	0,4985	0,2239
Perda	0,3711	0,9575	0,4623	1,0281	0,6933	1,6045

Sendo assim, é possível identificar que o *dataset* Training2017 utilizando 2 classes foi o que apresentou maior precisão e menor perda, seguido pelo WESAD também com 2 classes.

No capítulo a seguir, são sumarizados os aprendizados e contribuições deste trabalho, bem como suas considerações finais.

## S6 CONCLUSÃO

A partir de estudos de artigos publicados recentemente, observou-se que poucos trabalhos foram desenvolvidos utilizando dois ou mais sinais fisiológicos para detecção de padrões de estresse; logo, há uma lacuna para validação da hipótese de que o uso de multisinais é mais promissor do que seu uso de sinais fisiológicos de forma singular. Destaca-se ainda que apenas um trabalho estudado utilizou dados de Cortisol em conjunto com sinais fisiológicos como forma de auxiliar na validação dos resultados (NATH et al., 2020). Este trabalho e outras publicações (LEE et al., 2020) destacam a necessidade de experimentos com quantidade massiva de dados.

Este trabalho faz parte do projeto multidisciplinar BeWell, colaborativo entre áreas da Psicologia, Computação e Engenharia Elétrica com a participação de diversas universidades, consistente de diversas etapas. Primeiramente, dados foram coletados utilizando protocolo com atividades de relaxamento e estresse, devidamente cronometrados, onde o Cortisol foi coletado ao final do processo. Experimentos iniciais foram realizados, demonstrando ser possível classificar estresse neste dataset, e que Cortisol se mostrou um eficiente marcador para o auxílio na validação dos dados, porém não em tempo real pois sua ativação acontece 30 minutos depois do fator estressante.

Ainda, experimentos foram realizados utilizando multisinais e diferentes *datasets*, onde ECG destacou-se dentre os demais como o mais eficiente para este propósito. Ainda, outra contribuição significativa deste trabalho é o modelo híbrido desenvolvido utilizando *Deep Learning*, onde não há a necessidade de extração e seleção de features, sendo adaptável para qualquer dataset e com resultado muito próximo da arquitetura em que features são necessárias, e sua seleção está diretamente ligada a eficácia do modelo.

Finalmente, este trabalho conseguiu responder a sua questão-problema que buscava identificar quais combinações de sinais fisiológicos e suas características que permitem a obtenção de melhores resultados na identificação de padrões indicativos de estresse. O resultado minimamente superior de *Machine Learning* comparado a *Deep Learning* indica não se justificar devido a sua complexidade, sugerindo-se novos experimentos utilizando o mesmo *dataset* e diferentes features para validação desta hipótese.

## 6.1 CONTRIBUIÇÕES

Foram desenvolvidos projetos de colaboração com outros colegas, como a monografia do curso de Ciência da Computação intitulada “Estratégias de Aprendizagem de Máquina para Reconhecimento de Padrões de Estresse em Dados Fisiológicos” da aluna Amanda Grams Jabroski, bem como a dissertação do programa de pós-graduação de Psicologia “Desenvolvimento de um dispositivo wearable para avaliação de estresse: medidas fisiológicas durante tarefas de estresse cognitivo e relaxamento” da mestrandia Maria Júlia Armiliato.

Experimentos de coleta de dados por protocolo TSST foram realizados utilizando multisinais em combinação com diferentes algoritmos de aprendizado de máquina de forma multidisciplinar, em colaboração com grupo de pesquisa da Engenharia Elétrica e Psicologia da Unisinos em São Leopoldo e da Ciência da Computação e Psicologia da FAU na Alemanha.

Dois artigos foram aprovados, sendo um no evento *Brazilian Conference on Intelligent Systems (BRACIS)* sob o título “*Evaluating a new approach to data fusion in wearable physiological sensors for stress monitoring*” (Rodrigues et. Al, 2020) e outro no simpósio *Upper-Rhine Artificial Intelligence Symposium 2020 (UR-AI 2020)*, intitulado “*Towards Classification and Prediction of Stress Patterns using Multiple Physiological Signals*” (Rodrigues et al., 2020).

Também foram enviados artigos para os eventos *Grace Hopper Celebration* (<https://ghc.anitab.org/>), *UX Healthcare* (<https://uxhealthcare.co/>), descrevendo elementos da temática do trabalho desenvolvido. Ainda, está em andamento a atividade de publicação do dataset *BeWell para a comunidade*, como forma de propagar novos experimentos.

## 6.2 TRABALHOS FUTUROS

Como sugestão para trabalhos futuros, por se tratar de um tema incipiente com poucos trabalhos na área, sugere-se novos estudos com a utilização dos mesmos conjuntos de dados públicos, aumentando o número de features, bem como avaliar possíveis extrações de features como realizado em o conjunto de dados do WESAD. Para isto, é necessário realizar uma análise aprofundada dos sinais obtidos com cada conjunto de dados de forma mais precisa, sem distorcer os sinais ou acabar

prejudicando o treinamento. Adicionalmente, é possível utilizar dados de Cortisol, o principal marcador biológico em relação ao estresse, como forma de suporte para rotulação de dados ou validação da eficácia do modelo.

## REFERÊNCIAS

- Han, L., Zhang, Q., Chen, X., Zhan, Q., Yang, T., Zhao, Z., Detecting work-related stress with a wearable device, *Computers in Industry* 90 (2017) 42–49.
- Yohanes, R. E. J., Ser, W., Huang, G. Discrete wavelet transform coefficients for emotion recognition from EEG signals. *Proc. 34th Annual International Conference of the IEEE EMBS*; 2012.
- Savran, A., Ciftci, K., Chanel, G., Mota, J., Viet, L. H., Sankur, B. et al. Emotion detection in the loop from brain signals and facial images; 2006, <http://www.enterface.net/results/2006>.
- Horlings, R., Datcu, D., Leon, J., Rothkrantz, M. Emotion recognition using brain activity. *Proc. International Conference on Computer Systems and Technologies*; 2008.
- Zhang, T., Zheng, W., Cui, Z., Zong, Y., Li Y. Spatial–temporal recurrent neural network for emotion recognition. *IEEE Trans Cybern* 2018;01–9.
- Kwon, Y.H., Shin, S.B., Kim, S.D.. Electroencephalography based fusion two-dimensional (2D)-Convolution Neural Networks (CNN) model for emotion recognition system. *Sensors* 2018;18(5).
- Valenza, G., Citi, L., Lanata, A., Scilingo, E.P., Barbieri, R. Revealing real-time emotional responses: a personalized assessment based on heartbeat dynamics. *Sci Rep* 2014;4:4998. <http://dx.doi.org/10.1038/srep04998>
- López-Gil, J., Gomá, J.V., Gil, R., Guilera, T., Batalla, I., González, J.S., et al. Method for improving EEG based emotion recognition by combining it with synchronized biometric and eye tracking technologies in a non-invasive and low-cost way. *Front Computer Neuroscience* 2016;10(465).
- Al-Shargie, F., Tang, T.B., Badruddin, N., Kiguchi, M. Towards multilevel mental stress assessment using SVM with ECOC: an EEG approach. *Med Biol Eng Comput* 2017;56(1).
- Setz, C., Arnrich, B., Schumm, J. et al. Discriminating stress from cognitive load using a wearable EDA device, *IEEE Trans. Inf. Technol. Biomed.* 14 (2) (2010) 410–417.
- Healey, J.A., Picard, R.W. Detecting stress during real-world driving tasks using physiological sensors, *IEEE Transactions on Intelligent Transportation Systems* 6 (2005) 156–166.
- Reisman, S. Measurement of physiological stress, in: *Bioengineering Conference*, 1997, pp. 21–23.
- Labbé, E. et al. Coping with stress: the effectiveness of different types of music, *Applied Psychophysiology and Biofeedback* 32 (2007) 163–168.

Clifford, G.D. Signal processing methods for heart rate variability, Doctor of Philosophy, Engineering Science, University of Oxford, 2002.

Dharmawan, Z. Analysis of computer games player stress level using EEG data, Master of Science Thesis Report, Faculty of Electrical Engineering, Mathematics and Computer Science, Delft University of Technology, Netherlands, 2007.

Honal, M., Schultz, T. Identifying user state using electroencephalographic data, presented at the Workshop on Multimodal Multiparty Meeting, Trento, Italy, 2005.

Zhai, J., Barreto, A. Stress recognition using non-invasive technology, in: Proceedings of the 19th International Florida Artificial Intelligence Research Society Conference FLAIRS, 2006, pp. 395–400.

Fukuoka, Y., Ishida, A. Chronic stress evaluation using neural networks, IEEE Engineering in Medicine and Biology Magazine 19 (2000) 34–38.

Bundele, M.M., Banerjee, R. Detection of fatigue of vehicular driver using skin conductance and oximetry pulse: a neural network approach, in: Proceedings of the 11th International Conference on Information Integration and Web-based Applications and Services, Kuala Lumpur, Malaysia, 2009, pp. 739–744.

Sakr, G.E., et al. Multi level SVM for subject independent agitation detection, in: IEEE/ASME International Conference on Advanced Intelligent Mechatronics, Singapore, 2009, pp. 538–543.

Schuller, B. et al. Hidden Markov model-based speech emotion recognition, in: IEEE International Conference on Acoustics Speech, and Signal Processing (ICASSP '03), 2003, pp. II-1-4.

Kumar, M. et al. Fuzzy filtering for physiological signal analysis, IEEE Transactions on Fuzzy Systems 18 (2010) 208–216.

M. Kumar, et al., Fuzzy evaluation of heart rate signals for mental stress assessment, IEEE Transactions on Fuzzy Systems 15 (2007) 791–808.

Sharma, N., Gedeon, T. Objective measures, sensors and computational techniques for stress recognition and classification: A survey. Computer Methods and Programs in Biomedicine 108 (2012) 1287-1301.

Kappeler-Setz, C. Multimodal Emotion and Stress Recognition, ETH Zurich, 2012.

Scherer, S. et al. Emotion recognition from speech: stress experiment, in: Proceedings of the 6th International Language Resources and Evaluation (LREC 2008), Marrakech, Morocco, 2008.

Cheeseman, P. On finding the most probable model. In Jeff Shragar and Pat Langley, editors, *Computational Models of Discovery and Theory Formation*, pages 73–96. Morgan Kaufmann, Palo Alto, 1990.

Ashton, K., 2009. That Internet of Things thing. *RFID J.* 1–2.

Samuel, A.L. Some studies in machine learning using the game of checkers. *IBM J Res Dev* 1959; 3: 210–29.

Giannakakis, G., Grigoriadis, D., Giannakaki, K., Simantiraki, O., Roniotis, A., & Tsiknakis, M. (2019). Review on psychological stress detection using biosignals. *IEEE Transactions on Affective Computing*, 1–22. <https://doi.org/10.1109/TAFFC.2019.2927337>.

Boonstra, R. (2013). The ecology of stress: A marriage of disciplines. *Functional Ecology*, 27(1), 7–10. <https://doi.org/10.1111/1365-2435.12048>.

Can, Y. S., Chalabianloo, N., Ekiz, D., Ferenandez-Alvarez, J., Riva, G., Ersoy, C. (2020). Personal Stress-Level Clustering and Decision Level Smoothing to Enhance the Performance of Ambulatory Stress Detection With Smartwatches. *IEEE*. DOI: 10.1109/ACCESS.2020.2975351.

Can, Y. S., Arnrich, B., Ersoy, C. (2019). Stress detection in daily life scenarios using smart phones and wearable sensors: A survey. *Elsevier*. DOI: 10.1016/j.jbi.2019.103139.frodri

Mitra, S. K. *Digital signal processing: a computer-based approach*. 2nd ed. Boston: McGraw-Hill, 2001.

Nath, R. K., Thapliyal, H., Caban-Holt, A. Validating Physiological Stress Detection Model Using Cortisol as Stress Bio Marker. 2020 IEEE International Conference on Consumer Electronics (ICCE).

Lee, J. H., Remaley, S. M. J., Tashev, H. G. I., Holbery, J., Dong, S. e Yoon, S. H. Stress Monitoring using Multimodal Bio-sensing Headset. *CHI 2020*. CHI 2020, April 25–30, 2020, Honolulu, HI, USA.

Panicker, S. Suja, Gayarhri, Prakasam. A survey of machine learning techniques in physiology based mental stress detection systems. *Biocybernetics and Biomedical Engineering*. Volume 39, Issue 2, April–June 2019, Pages 444-469.

Simon, Herbert A. *Sciences of the Artificial*. 1979.

Stress Research. American Psychological Association, 2017. <https://www.apa.org/news/press/releases/stress/2017/state-nation.pdf>

Ping, H.Y., Abdullah, L. N., Halin, A. A., Sulaiman, P.S. A Study of Physiological Signals-based Emotion Recognition Systems. *International Journal of Computer and Technology*. Vol 11, No. 1. 2013.

Nath, R. K., Thapliyal, H., Caban-Holt, A., Mohanty, S.P. Machine Learning Based Solutions for Real-time Stress Monitoring. 2020 IEEE International Conference on Consumer Electronics (ICCE).

Mangala, G. S. G., Raj, C.P. Energy density feature extraction using different wavelets for emotion detection. *Int J Appl Eng Res* 2018;13(1):520–7.

Lee, M., Moon, J., Cheon, D., Lee, J., Lee, K. Respiration Signal based Two Layer Stress Recognition across Non-verbal and Verbal Situations. SAC '20: Proceedings of the 35th Annual ACM Symposium on Applied Computing. March 2020. Pages 638–645.

Ding, Y., Cao, Y., Duffy, V. G., Wang, Y., Zhang, X. Measurement and identification of mental workload during simulated computer tasks with multimodal methods and machine learning, 2020, *Ergonomics*, 63:7, 896-908, DOI: 10.1080/00140139.2020.1759699

Gurel, N. Z., Wittbrodt, M. T., Jung, H., Ladd, S. L., Shah, A. J., Vaccarino, V., Bremner, J. D., Inan, O. T. Automatic Detection of Target Engagement in Transcutaneous Cervical Vagal Nerve Stimulation for Traumatic Stress Triggers. *IEEE Journal of Biomedical and Health Informatics*. 2020. DOI 10.1109/JBHI.2020.2981116

Saeed, A., Trajanovski, S., Keulen, M., Erp, J. Deep Physiological Arousal Detection in a Driving Simulator using Wearable Sensors. 2017 IEEE International Conference on Data Mining Workshops. DOI 10.1109/ICDMW.2017.69

Bara, P. C., Papakostas, M., Mihalcea, R. A Deep Learning Approach Towards Multimodal Stress Detection. Proceedings of the 3rd Workshop of Affective Content Analysis, New York, USA, 07-FEB-2020, published at <http://ceur-ws.org>

Rodrigues, Andréia Kunzler, Desenvolvimento e evidências de validade do *BeWell*: Dispositivo *mHealth* de *biofeedback* para avaliação de estresse. Programa De Pós-Graduação em Psicologia, Unisinos, 2019.

Wagner, J., Kim J., André, E. From physiological signals to emotions: Implementing and comparing selected methods for feature extraction and classification. *IEEE International Conference on Multimedia and Exp*, 2005. DOI: 10.1109/ICME.2005.1521579.

Bishop, Christopher (2006). *Pattern recognition and machine learning*. Berlin: Springer. ISBN 0-387-31073-8.

Elzeiny, S., Qaraqe, M. Machine Learning Approaches to Automatic Stress Detection: A Review. *IEEE/ACS 15th International Conference on Computer Systems and Applications (AICCSA)*. 2018. DOI: 10.1109/AICCSA.2018.8612825.

The Effects of Stress on Your Body, Healthline. [Online]. Available: <http://www.healthline.com/health/stress/effects-on-body>.

S. Cohen, D. Janicki-Deverts and G. Miller, "Psychological Stress and Disease," *JAMA*, vol. 298, no. 14, pp. 1685-1687, 2007.

E. Smets, W. De Raedt, and C. Van Hoof. Into the Wild: The Challenges of Physiological Stress Detection in Laboratory and Ambulatory Settings. *IEEE Journal of Biomedical and Health Informatics*. 2018. DOI 10.1109/JBHI.2018.2883751.

RODRIGUES, C.; FROHLICH, W. R.; JABROSKI, A. G.; RIGO, SANDRO JOSÉ; RODRIGUES, A.; CASTRO, E. K. Evaluating a new approach to data fusion in wearable physiological sensors for stress monitoring In: BRACIS - Brazilian Conference on Intelligent Systems, 2020, Rio Grande/RS. BRACIS - Brazilian Conference on Intelligent Systems. Rio Grande / RS: SBC, 2020. v.1. p.1 – 15.

RODRIGUES, C.; FROHLICH, W. R.; RODRIGUES, A.; CASTRO, E. K.; FIGUEIREDO, R. M.; MALLMAN, A. P.; RIGO, SANDRO JOSÉ Towards Classification and Prediction of Stress Patterns using Multiple Physiological Signals In: UR-AI Upper-Rhine Artificial Intelligence Symposium 2020, 2020, Karlsruhe/Alemanha. UR-AI Upper-Rhine Artificial Intelligence Symposium 2020. Karlsruhe/Alemanha: UR-AI, 2020. v.1.p.1 – 10.

Bishop, Christopher (2006). *Pattern recognition and machine learning*. Berlin: Springer. ISBN 0-387-31073-8.

Shah, N., Kamdar, L., Gokalgandhi, D., Mehendale, N. Walking pattern analysis using deep learning for energy harvesting smart shoes with IoT. *bioRxiv* 2020.05.10.087197; doi: <https://doi.org/10.1101/2020.05.10.087197>

M. Umair, N. Chalabianloo, C. Sas and C. Ersoy, "HRV and Stress: A Mixed-Methods Approach for Comparison of Wearable Heart Rate Sensors for Biofeedback," in *IEEE Access*, vol. 9, pp. 14005-14024, 2021, doi: 10.1109/ACCESS.2021.3052131.

K. Wang and P. Guo, "An Ensemble Classification Model With Unsupervised Representation Learning for Driving Stress Recognition Using Physiological Signals," in *IEEE Transactions on Intelligent Transportation Systems*, doi: 10.1109/TITS.2020.2980555.

Li, R., Liu, Z. Stress detection using deep neural networks. *BMC Med Inform Decis Mak* 20, 285 (2020). <https://doi.org/10.1186/s12911-020-01299-4>

W. Li, Z. Zhang and A. Song, Physiological-signal-based emotion recognition: An odyssey from methodology to philosophy, *Measurement* (2020), doi: <https://doi.org/10.1016/j.measurement.2020.108747>

Chen, J.; Abbod, M.; Shieh, J.-S. Pain and Stress Detection Using Wearable Sensors and Devices—A Review. *Sensors* 2021, 21, 1030. <https://doi.org/10.3390/s21041030>

Hernandez, N., Castro, L., Medina-Quero, J. *et al.* Scoping Review of Healthcare Literature on Mobile, Wearable, and Textile Sensing Technology for Continuous Monitoring. *J Healthc Inform Res* (2021). <https://doi.org/10.1007/s41666-020-00087-z>

American Psychological Association (2017). Stress in America: The State of Our Nation. Stress in America™ Survey

Goldberger, A., et al. (2000) "PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals". Circulation [Online]. Vol. 101 N. 23, Pg. e215–e220

Schmidt, P., et al. (2018) "Introducing WESAD, a multimodal dataset for wearable stress and affect detection". In: Proceedings of the 20th ACM International Conference on Multimodal Interaction, ICMI 2018, Pg. 400–408. ACM, New York.

C. Setz, B. Arnrich, J. Schumm, R. La Marca, G. Tröster, and U. Ehlert. 2010. Discriminating stress from cognitive load using a wearable EDA device. IEEE Transactions on Information Technology in Biomedicine 14, 2 (2010), 410–417.

J. Choi, B. Ahmed, and R. Gutierrez-Osuna. 2012. Development and evaluation of an ambulatory stress monitor based on wearable sensors. IEEE Transactions on Information Technology in Biomedicine 16, 2 (2012).

Schmidt, P., Reiss, A., Duerichen, R., Marberger, C. and Van Laerhoven, K.. 2018. Introducing WESAD, a multimodal dataset for Wearable Stress and Affect Detection. In 2018 International Conference on Multimodal Interaction (ICMI18), October, 2018, Boulder, CO, USA. ACM, New York, NY, USA, 9 pages.

Goldberger, A., Amaral, L., Glass, L., Hausdorff, J., Ivanov, P. C., Mark, R., ... & Stanley, H. E. (2000). PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. Circulation [Online]. 101 (23), pp. e215–e220.

Malik, M. (1996) "Task force of the European society of cardiology and the north American society of pacing and electrophysiology. Heart rate variability". Standards of measurement, physiological interpretation, and clinical use. Eur Heart J., 354–381.

Wijnsman, J. et al. (2010) "Trapezius muscle EMG as predictor of mental stress". Wireless Health 2010 - WH '10. ACM, New York, NY, USA, 155-163.

M. Haak, et al., Detecting stress using eye blinks and brain activity from EEG signals, in: Proceeding of the 1st Driver Car Interaction and Interface (DCII 2008), Chez Technical University, Prague, 2008.

Z. Dharmawan, Analysis of computer games player stress level using EEG data, Master of Science Thesis Report, Faculty of Electrical Engineering, Mathematics and Computer Science, Delft University of Technology, Netherlands, 2007.

J.A. Healey, R.W. Picard, Detecting stress during real-world driving tasks using physiological sensors, IEEE Transactions on Intelligent Transportation Systems 6 (2005) 156–166.