

**UNIVERSIDADE DE CAXIAS DO SUL
ÁREA DO CONHECIMENTO DE CIÊNCIAS EXATAS E
ENGENHARIAS**

GUSTAVO DEBIASI

**RECONHECIMENTO DE ESTRESSE POR MEIO DE TÉCNICAS DE
DETECÇÃO DE PADRÕES**

CAXIAS DO SUL

2019

GUSTAVO DEBIASI

**RECONHECIMENTO DE ESTRESSE POR MEIO DE TÉCNICAS DE
DETECÇÃO DE PADRÕES**

Trabalho de Conclusão de Curso
apresentado como requisito parcial
à obtenção do título de Bacharel em
Ciência da Computação na Área do
Conhecimento de Ciências Exatas e
Engenharias da Universidade de Caxias
do Sul.

Orientador: Prof. Dr. André Gustavo
Adami

CAXIAS DO SUL

2019

GUSTAVO DEBIASI

**RECONHECIMENTO DE ESTRESSE POR MEIO DE TÉCNICAS DE
DETECÇÃO DE PADRÕES**

Trabalho de Conclusão de Curso
apresentado como requisito parcial
à obtenção do título de Bacharel em
Ciência da Computação na Área do
Conhecimento de Ciências Exatas e
Engenharias da Universidade de Caxias
do Sul.

Aprovado em 29/11/2019

BANCA EXAMINADORA

Prof. Dr. André Gustavo Adami
Universidade de Caxias do Sul - UCS

Prof. Dra. Adriana Miorelli Adami
Universidade de Caxias do Sul - UCS

Prof. Dr. André Luis Martinotto
Universidade de Caxias do Sul - UCS

Are you living your life or just waiting to die?

Steve Aoki

AGRADECIMENTOS

Gostaria de agradecer e dedicar essa dissertação às seguintes pessoas:

Minha família: em especial minha mãe Maria de Lourdes e meu pai Lourenço; Meu irmão Guilherme e minha cunhada Samara.

Todos os meus amigos: Guiga e Paula que estão comigo desde o princípio; Amanda, Babi, Fer e Lucas que entraram na minha vida não tão recentemente. Além do Anderson e do Marcelo, da galera do "reino das águas claras", do "terceirão" e todos os meus amigos que, de alguma forma, auxiliaram na vida universitária, pessoal e profissional.

Agradeço também aos meus colegas de faculdade, estamos juntos nessa!

Meu orientador pelas orientações e ensinamentos.

E por fim, não menos importante, agradeço a todos que colaboraram com este trabalho de alguma forma.

RESUMO

Depressão, ansiedade, raiva, úlcera, gastrite, psoríase, ataques cardíacos e diabetes tipo 2 são algumas das doenças que podem ser ocasionadas pelo excesso de estresse na vida do ser humano. Devido a isso, para se ter uma vida saudável, é importante que se tenha cuidado com a saúde. E o que pode ser feito para auxiliá-lo neste cuidado? Na computação existe uma área chamada detecção de padrões e, através dela, é possível treinar o computador para identificar um padrão de comportamento. Assim, é possível que seja utilizado este aprendizado para monitorar e detectar quando o indivíduo está sob situações estressantes, de forma a alertá-lo para que ele possa tomar alguma providência para reduzir ou controlar o nível de estresse. Embora o corpo humano apresente alterações fisiológicas que podem ser verificadas para a identificação do estresse, atualmente o diagnóstico é ainda realizado por meio de questionários e avaliação de especialista. Entretanto, é possível observar uma movimentação da comunidade acadêmica com estudos de um sistema de detecção automática através de um processo e técnicas de detecção de padrões sob as alterações fisiológicas. Neste contexto, um sistema multimodal de detecção automática de estresse foi desenvolvido neste trabalho, com a utilização de diversas características (como média, mediana, variância), redução de dimensionalidade com LDA e PCA e classificação utilizando SVM e *Random Forest*. Através da utilização da base de dados WESAD para avaliar o desempenho do software, conclui-se que não foi possível obter melhores resultados com a fusão de classificadores (acurácia de 84,6%) quando comparado à fusão de características do sistema tradicional de detecção de estresse multimodal (acurácia de 89,3% e 89,8%).

Palavras-chaves: Detecção de Padrão, Máquinas de Vetores de Suporte, Árvore de Decisão, Detecção automática de estresse, Detecção Multimodal

LISTA DE ILUSTRAÇÕES

Figura 1 – Exemplo de (a) alta e (b) baixa HRV	23
Figura 2 – Sensores EDA na mão e no pé	24
Figura 3 – Modelo de reconhecimento de estresse	28
Figura 4 – Processo dos sistemas de detecção de padrões	29
Figura 5 – Exemplo de (a) pouca quantidade de amostras e (b) boa quantidade de amostras. A linha pontilhada é a divisão determinada pelo sistema e a linha sólida é como a divisão das classes é de fato.	30
Figura 6 – Filtragem <i>Butterworth</i> com corte de frequência 3Hz	31
Figura 7 – Filtragem de valores atípicos de 5 segundos de sinal do BVP	32
Figura 8 – Extração dos dados originais em características	32
Figura 9 – Sinal original	34
Figura 10 – Diferentes frequências extraídas do sinal original	34
Figura 11 – (a) Hiperplano para separação das classes (b) Hiperplano ótimo para separação das classes	38
Figura 12 – Aumento da dimensionalidade com função kernel	39
Figura 13 – Exemplo da classificação do SVM conforme a utilização do parâmetro de erro. Margem restrita representado pelo $\gamma = 100$ e margem suave representado pelo $\gamma = 0,01$	40
Figura 14 – Exemplo da estrutura de uma árvore de decisão	41
Figura 15 – Inserção de amostra no espaço do algoritmo KNN	42
Figura 16 – Divisão de amostras da técnica de treinamento <i>Holdout</i>	43
Figura 17 – Divisão de amostras da técnica de treinamento <i>Stratified Holdout</i>	43
Figura 18 – Divisão de amostras da técnica de treinamento <i>K-Fold</i>	44
Figura 19 – Divisão de amostras da técnica de treinamento <i>Leave-one-out</i>	44
Figura 20 – Matriz de confusão para o problema de 2 classes na classificação do estresse do indivíduo	45
Figura 21 – Modelo multimodal de detecção de estresse	46
Figura 22 – Arquitetura do sistema multimodal de detecção automática de estresse	50
Figura 23 – Segmentação dos dados	50
Figura 24 – Representação do intervalo RR	51
Figura 25 – Ordem dos Experimentos	55
Figura 26 – Empatica E4 Wristband	56
Figura 27 – RespiBAN Professional	56
Figura 28 – Método de treinamento <i>Leave-One-Subject-Out</i>	59
Figura 29 – Comparação de janelas de tempo do ECG	62
Figura 30 – Comparação de deslocamento da janela de tempo	62

Figura 31 – Comparação de fusão de classificadores e fusão de características	63
Figura 32 – ECG - Percentual de variância explicada do PCA	77
Figura 33 – EDA - Percentual de variância explicada do PCA	78
Figura 34 – EMG - Percentual de variância explicada do PCA	78
Figura 35 – Respiração - Percentual de variância explicada do PCA	79

LISTA DE TABELAS

Tabela 1 – Classificação empírica de sensores para detectar o estresse	29
Tabela 2 – Funções Kernel SVM	39
Tabela 3 – Avaliação de desempenho de sistemas de detecção de estresse	46
Tabela 4 – Avaliação de desempenho de sistemas de detecção multimodal de estresse .	47
Tabela 5 – Quantidade de segmentos extraídos por paciente	60
Tabela 6 – Desempenho da detecção para diferentes classificadores e características . .	60
Tabela 7 – Resultado da detecção utilizando PCA e LDA	61
Tabela 8 – Quantidade de amostras por deslocamento	63

LISTA DE ABREVIATURAS E SIGLAS

ACC	Acurácia
AF	Alta Frequência
BF	Baixa Frequência
BVP	Volume Sanguíneo (<i>Blood Volume Pulse</i>)
DAE	Detecção Automática de Estresse
DT	Árvore de Decisão (<i>Decision Tree</i>)
ECG	Eletrocardiograma
EDA	Atividade Eletrodérmica (<i>Electrodermal Activity</i>)
EMG	Eletromiograma (<i>Electromyography</i>)
ESPEC	Especificidade
FN	Falso Negativo
FP	Falso Positivo
HRV	Variabilidade da Frequência Cardíaca (<i>Heart Rate Variability</i>)
KNN	K-ésimo vizinho mais próximo (<i>k-nearest neighbors</i>)
LDA	Análise Discriminante Linear (<i>Linear Discriminant Analysis</i>)
PANAS	Escala de Afeto Positivo e Negativo (<i>Positive and Negative Affect Schedule</i>)
PCA	Análise de Componente Principal (<i>Principal Component Analysis</i>)
PPG	Fotopletismograma (<i>Photoplethysmogram</i>)
RBF	<i>Radius Basis Function</i>
RF	Floresta Aleatória (<i>Random Forest</i>)
SENS	Sensitividade
SNA	Sistema Nervoso Autônomo
SNS	Sistema Nervoso Simpático
SSSQ	Questionário de Estado de Estresse (<i>Stress State Questionnaire</i>)

STAI	Inventário de Ansiedade Traço-Estado (<i>State-Trait Anxiety Inventory</i>)
SVM	Máquinas de Vetores de Suporte (<i>Support vector machines - SVM</i>)
TCC	Trabalho de Conclusão de Curso
UCS	Universidade de Caxias do Sul
VP	Verdadeiro Positivo
VN	Verdadeiro Negativo
WESAD	Vestíveis de Detecção de Estresse e Afeto (<i>Wearable Stress and Affect Detection</i>)

SUMÁRIO

1	INTRODUÇÃO	19
1.1	OBJETIVOS	20
1.2	ORGANIZAÇÃO DO TRABALHO	20
2	ESTRESSE	21
2.1	Definição	21
2.1.1	Alterações hormonais	22
2.1.2	Alterações psicológicas	22
2.1.3	Alterações fisiológicas	22
2.1.3.1	Variabilidade da Frequência Cardíaca	23
2.1.3.2	Pressão arterial e volume sanguíneo	23
2.1.3.3	Propriedades elétricas da pele	24
2.1.3.4	Padrão de respiração	24
2.2	Problemas ocasionados e patologias	25
2.3	Detecção clínica de estresse nos dias de hoje	25
3	SISTEMAS DE DETECÇÃO AUTOMÁTICA DE ESTRESSE	27
3.1	Detecção Automática de Estresse	27
3.1.1	Coleta de Dados	29
3.1.2	Pré-processamento	30
3.1.3	Extração de características	32
3.1.4	Seleção de características	33
3.1.4.1	Análise de Componentes Principais	35
3.1.4.2	Análise Discriminante Linear	36
3.1.5	Classificação	37
3.1.5.1	Máquinas de Vetores de Suporte	37
3.1.5.2	Árvore de Decisão	40
3.1.5.3	K-vizinhos mais próximos	41
3.2	Treinamento dos classificadores	42
3.3	Avaliação de Desempenho	43
3.4	Detecção Multimodal	45
4	SISTEMA MULTIMODAL PARA DETECÇÃO AUTOMÁTICA DE ESTRESSE	49
4.1	Método Proposto	49
4.1.1	Pré-processamento	50

4.1.2	Extração das características	51
4.1.3	Seleção das características	53
4.1.4	Classificação	53
4.1.5	Decisão	54
4.2	Base de dados	54
4.2.1	Experimentos	54
4.2.2	Coleta de dados e avaliação dos sensores	56
4.2.3	Avaliação via questionários	57
4.3	Configuração dos Experimentos	58
4.3.1	Treinamento dos Classificadores	58
4.3.2	Avaliação de Desempenho	58
4.4	Resultados e Discussões	59
4.4.1	Redução de dimensionalidade	59
4.4.2	Definição da janela de tempo	61
4.4.3	Comparação de resultados entre a fusão de classificadores e a fusão de características	63
5	CONSIDERAÇÕES FINAIS	65
	REFERÊNCIAS	67
	APÊNDICES E ANEXOS	75
	APÊNDICE A – VARIÂNCIA EXPLICADA DO LDA E DO PCA	77
	ANEXO A – QUESTIONÁRIO PANAS	81
	ANEXO B – QUESTIONÁRIO STAI	83
	ANEXO C – QUESTIONÁRIO SELF-ASSESSMENT MANIKINS	85
	ANEXO D – SHORT STRESS STATE QUESTIONNAIRE	87

1 INTRODUÇÃO

Os seres humanos estão cada dia mais empenhados em ter uma vida bem-sucedida, confortável e segura. Segundo ELZEINY; QARAGE (2008), devido às altas demandas da sociedade, os humanos estão se sujeitando a hábitos prejudiciais à saúde, como por exemplo cargas de trabalho excessivas, poucas horas de sono, má alimentação, pouco exercício físico e conflitos sociais. Estes hábitos têm causado efeitos negativos como fadiga, estresse e depressão.

O estresse tem sido um dos transtornos que causa um grande impacto na economia. Gastos anuais relacionados a doenças associadas a ele são estimadas em mais de 300 bilhões de dólares nos Estados Unidos da América (The American Institute Of Stress, 2013), e mais de 617 bilhões de euros no continente Europeu (European Agency for Safety and Health at Work, 2014). Devido aos grandes impactos que o estresse traz, torna-se indispensável evitá-lo quando exacerbado, podendo assim ter uma vida mais tranquila e saudável física e mentalmente.

Muitas pessoas sofrem diariamente com o excesso de estresse (ALBERDI; AZTIRIA; BASARAB, 2016). Esse mau hábito pode causar doenças físicas (como a gastrite, a úlcera, doenças cardiovasculares e baixa imunidade) (GREENE; THAPLIYAL; CABAN-HOLT, 2016; SHARMA; GEDEON, 2012) e distúrbios mentais (como depressão, falta de motivação ou propósito, ansiedade e irritabilidade) (THAPLIYAL; KHALUS; LABRADO, 2017). Quanto mais as pessoas sofrem com este mal, mais vulnerável seu organismo fica perante infecções, e dificulta a recuperação em processos corporais (SHARMA; GEDEON, 2012). Apesar dos problemas causados, nem todo estresse é negativo e um pouco dele na vida dos seres humanos faz com que o corpo libere adrenalina causando impacto positivo (ELZEINY; QARAGE, 2008) gerando motivação, necessidade de organização, ou ainda, como um alerta para armadilhas do dia-a-dia.

Por mais que os impactos do estresse sejam grandes na sociedade, o seu diagnóstico ainda é complexo. Atualmente, a detecção do estresse no Brasil é realizada através de análises clínicas, muitas vezes subjetivas ao ser humano. O método utilizado em diversas pesquisas (JUNIOR *et al.*, 2014; RAMIRO *et al.*, 2014; ROSSETTI *et al.*, 2008) é o inventário de sintomas de *stress* para adultos de Lipp (ISSL), que consiste em três questionários onde o paciente deve responder se houveram, ou não, determinados sintomas no último mês (RAMIRO *et al.*, 2014). Entretanto, a avaliação do questionário é complexa e incerta (NOBLE, 2002) pois depende da individualidade de cada paciente (ELZEINY; QARAGE, 2008) e da interpretação do avaliador (SHARMA; GEDEON, 2012).

Com o objetivo de realizar uma avaliação mais consistente, prática e longitudinal, métodos alternativos baseados em sensores vêm sendo desenvolvidos por diversos pesquisadores (THAPLIYAL; KHALUS; LABRADO, 2017; ALBERDI; AZTIRIA; BASARAB, 2016; SYSOEV *et al.*, 2014). Estas pesquisas possibilitam o desenvolvimento de dispositivos inteligentes (*smart wearable de-*

vices) que permitem analisar e detectar alterações fisiológicas em seres humanos com o objetivo de identificar o estresse.

Diante deste cenário, este trabalho busca identificar e avaliar diferentes informações biológicas, capturadas por meio de sensores, que permitam detectar o estresse de forma automática. O desenvolvimento deste trabalho é baseado em estudos já realizados com a utilização da base de dados *WESAD (Wearable Stress and Affect Detection)* (UC Irvine Machine Learning Respository, 2018).

1.1 OBJETIVOS

Este trabalho apresentou como objetivo desenvolver um sistema (*software*) para detectar automaticamente o estresse humano utilizando sinais de múltiplos sensores.

1.2 ORGANIZAÇÃO DO TRABALHO

Este trabalho está organizado de forma que inicia com a conceituação clínica do estresse através do Capítulo 2, percorrendo desde a sua definição até a sua forma de detecção, além do detalhamento das alterações causadas pelo estresse no corpo humano e doenças relacionadas. No Capítulo 3, é realizada a definição de como os sistemas de detecção de estresse são desenvolvidos, detalhando todo o processo realizado (desde a coleta de dados até a classificação e avaliação dos resultados). Por fim, no Capítulo 4, a arquitetura do sistema proposto é detalhada e os resultados são apresentados.

2 ESTRESSE

“Eu devia sorrir mais. Abraçar meus pais. Viajar o mundo e socializar. Nunca reclamar. Só agradecer. Tudo o que vier eu fiz por merecer.”

Supercombo - Piloto Automático

Antes de abordar as técnicas de detecção, este capítulo tem como objetivo conceituar e apresentar informações sobre o estado clínico do estresse. Na Seção 2.1, o estresse é contextualizado e definido. Na Seção 2.2, as principais doenças e problemas que podem ser causados são listadas. Na Seção 2.3, são apresentados os métodos de detecção utilizados atualmente.

2.1 DEFINIÇÃO

Embora o estresse esteja presente na sociedade desde os primórdios, ainda existem discussões para a sua definição. De acordo com SELYE (1984), o estresse é "uma resposta não específica do corpo para qualquer necessidade de mudança"¹. Além disso, MCEWEN (2000) define como "eventos que são interpretados como ameaçadores para o indivíduo e que provocam respostas psicológicas e comportamentais"². Estes eventos definidos por McEwen são geralmente relacionados a situações negativas.

Embora não existam comprovações científicas de que a sociedade sofre mais de estresse nos dias atuais, pode-se considerar que as mudanças são realizadas mais rapidamente e intensamente do que antigamente (WEBER *et al.*, 2012). Segundo SELYE (1984), o estresse é ocasionado por mudanças e, hoje em dia, os humanos estão mais vulneráveis a eventos que trazem alterações na rotina e que, conseqüentemente, podem ocasionar mais estresse.

Segundo BAKKER; PECHENIZKIY; SIDOROVA (2011), pode-se classificar o estresse em três tipos:

1. Agudo: considerado não prejudicial, é a resposta instintiva a situações estressantes de curta duração. Geralmente este tipo coloca os seres humanos em sinal de alerta;
2. Episódico: é ocasional. Situações estressantes mais frequentes são relacionadas a uma vida caótica;

¹ Texto original: *"the non-specific response of the body to any demand for change"*

² Texto original: *"events that are interpreted as threatening to an individual and which elicit physiological and behavioral responses"*

3. Crônico: quando as situações estressantes são longas e duradouras, como problemas relacionados a trabalho, pobreza, ou ainda, problemas familiares.

Quando os seres humanos estão sob influência do estresse (principalmente crônico) são identificadas alterações hormonais, psicológicas e fisiológicas (SHARMA; GEDEON, 2012).

2.1.1 Alterações hormonais

Uma das respostas do corpo humano ao estresse são mudanças do sistema endócrino com liberação de hormônios como cortisol e adrenalina (ALBERDI; AZTIRIA; BASARAB, 2016; SHARMA; GEDEON, 2012). Nos seres humanos, principalmente nos antepassados, a adrenalina teve um papel importante para a sobrevivência, onde em momentos de perigo (estresse), o corpo liberava este hormônio (ELZEINY; QARAGE, 2008) e, dessa forma, eles podiam agir rapidamente para ficarem seguros. Além disso, o nível de cortisol possui um ciclo ao longo do dia, iniciando com altos índices e diminuindo gradativamente até que o seu menor nível seja atingido durante a noite (ALBERDI; AZTIRIA; BASARAB, 2016). Entretanto, pessoas com estresse crônico permanecem durante todo o dia com altos níveis deste hormônio, inclusive à noite.

2.1.2 Alterações psicológicas

O sistema nervoso autônomo (SNA) dos seres humanos é formado pelo sistema nervoso simpático (SNS) e sistema nervoso parassimpático (SHARMA; GEDEON, 2012). Eles são responsáveis pela regulação de alguns sistemas fisiológicos e quando as pessoas estão sob situações estressantes, pode-se identificar alterações no SNA e conseqüentemente na regulação do corpo. Mudanças fisiológicas são causadas por essa desregulação, tais como, variabilidade da frequência cardíaca (*Heart Rate Variability - HRV*), propriedades elétricas da pele (resposta galvânica), diâmetro da pupila e tensão muscular (THAPLIYAL; KHALUS; LABRADO, 2017; ALBERDI; AZTIRIA; BASARAB, 2016), bem como, pressão arterial, temperatura corporal e o ritmo da respiração (KUMAR *et al.*, 2007). Além destas, respostas psicológicas também são identificadas através da raiva, irritação, ansiedade ou depressão (ALBERDI; AZTIRIA; BASARAB, 2016).


2.1.3 Alterações fisiológicas

Além das alterações fisiológicas causadas pelo SNA, entonação da voz, postura e movimentos corporais também possuem comportamentos diferentes quando sob estresse (ALBERDI; AZTIRIA; BASARAB, 2016). Entretanto, existem algumas dificuldades para detectar o padrão de todas essas variáveis. A variabilidade da frequência cardíaca, por exemplo, pode ser diferente dependendo de cada indivíduo devido às características únicas de cada um, como gênero, idade, condição física e estado emocional (KUMAR *et al.*, 2007).

2.1.3.1 Variabilidade da Frequência Cardíaca

A variabilidade da frequência cardíaca é uma medida realizada através da diferença de tempo (em milissegundos) entre um batimento e outro do coração humano, normalmente analisado pelos registros do eletrocardiograma³ (ECG) (KUMAR *et al.*, 2007). Estudos têm mostrado que a alta variabilidade é um sinal de bom condicionamento físico e saúde (THAPLIYAL; KHALUS; LABRADO, 2017) (Figura 1a). Por outro lado, a baixa variabilidade é ocasionada por sobrecarga mental, estresse e fadiga (GHAMARI *et al.*, 2016) (Figura 1b). Além disso, é possível afirmar que, no avançar da idade, o HRV não sofre grandes alterações e que a maior variabilidade é durante períodos de sono ou em indivíduos que praticam exercícios físicos regularmente (BANSAL; KHAN; SALHAN, 2009).

Figura 1: Exemplo de (a) alta e (b) baixa HRV



Fonte: THAPLIYAL; KHALUS; LABRADO (2017)

2.1.3.2 Pressão arterial e volume sanguíneo

A pressão arterial é a pressão exercida pelo sangue sobre as paredes dos vasos sanguíneos (ALBERDI; AZTIRIA; BASARAB, 2016). Ela é uma das medidas realizadas para verificar a saúde do paciente e é mensurada a partir das pressões sistólica⁴ e diastólica⁵ (SHARMA; GEDEON, 2012). Geralmente, a pressão arterial de uma pessoa normal varia entre 90-120 mmHg para a sistólica e 60-80 mmHg para a diastólica (AKMANDOR; JHA, 2017).

O volume sanguíneo é a quantidade de sangue presente no tecido sanguíneo (ALBERDI; AZTIRIA; BASARAB, 2016), e é medido através da quantidade de luz refletida na pele, normalmente captado pelo *Blood Volume Pulse* (BVP) (SHARMA; GEDEON, 2012). Para que o corpo realize mudanças no volume é necessário que os vasos sejam dilatados ou contraídos alterando, dessa forma, a pressão arterial (GREENE; THAPLIYAL; CABAN-HOLT, 2016).

³ Eletrocardiograma é um aparelho que registra a atividade do coração.

⁴ Sistólica é a pressão exercida nas paredes das artérias quando o sangue está sendo bombeado.

⁵ Diastólica é a pressão de quando o coração está relaxado aguardando pelo reabastecimento do coração.

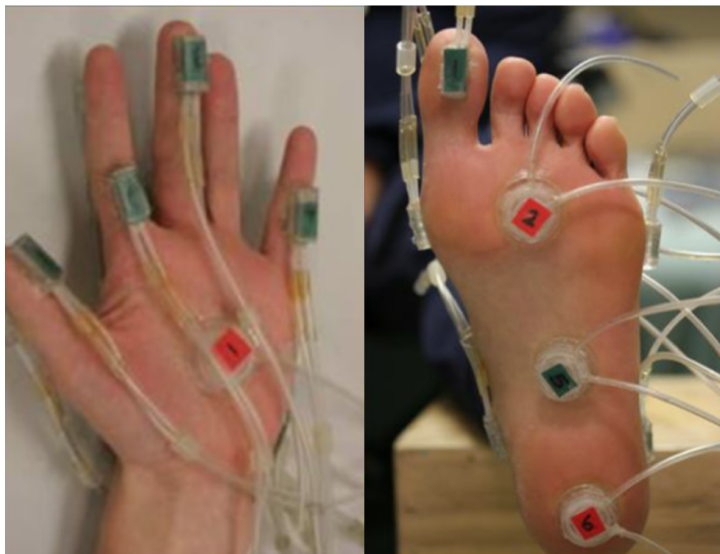
Alto índice de estresse está associado ao aumento da pressão arterial (FERNANDES *et al.*, 2014). Uma das formas de monitorar as alterações de pressão e volume é por meio de um sensor chamado fotopleletismograma (*photoplethysmogram* - PPG) (TAMURA *et al.*, 2014).

2.1.3.3 Propriedades elétricas da pele

As mudanças de propriedades elétricas da pele perante o suor são chamadas de atividade eletrodérmica (*Electrodermal Activity* - EDA) (DOOREN; VRIES; JANSSEN, 2012). Sob estresse esta propriedade corporal aumenta significativamente (SHARMA; GEDEON, 2012), e pode-se medir essas mudanças por meio de um sensor denominado resposta galvânica da pele (ALBERDI; AZTIRIA; BASARAB, 2016; ELZEINY; QARAGE, 2008).

As glândulas sudoríparas écrinas são as mais envolvidas nas alterações de propriedade da pele em momentos de mudanças emocionais (DOOREN; VRIES; JANSSEN, 2012). Essas glândulas existem em todo o corpo humano, mas sua maior concentração encontra-se nos pés e nas mãos (TAYLOR; MACHADO-MOREIRA, 2013), conforme ilustrado na Figura 2.

Figura 2: Sensores EDA na mão e no pé



Fonte: Adaptado de TAYLOR; MACHADO-MOREIRA (2013)

2.1.3.4 Padrão de respiração

Conforme os diversos níveis de estresse, a profundidade da respiração do ser humano é diferente (ALBERDI; AZTIRIA; BASARAB, 2016). A maioria dos sistemas de monitoramento de respiração requerem que o indivíduo use uma cinta ao redor do peito para realizar a medição (SHARMA; GEDEON, 2012). Entretanto, este tipo de equipamento pode restringir as atividades do paciente. É questionável o quanto essa medida é relevante pois análises realizadas através da

variação de frequência cardíaca e atividade eletrodérmica possuem maiores comprovações de alteração em situações estressantes (SHARMA; GEDEON, 2012).

2.2 PROBLEMAS OCASIONADOS E PATOLOGIAS

Existem muitos estudos que buscam identificar as doenças que podem ser causadas pelo estresse (principalmente crônico): dor de cabeça (SCHMIDT *et al.*, 2018), dor e tenção muscular, dor nas costas e de estômago (GREENE; THAPLIYAL; CABAN-HOLT, 2016). Entretanto, o quadro pode ser agravado e pode-se adquirir doenças mais severas como gastrite, úlcera, psoríase (ROSSETTI *et al.*, 2008), obesidade, ataques cardíacos, diabetes tipo 2, infecção na próstata e problemas no ciclo menstrual feminino (ELZEINY; QARAGE, 2008). O estresse pode também ocasionar severos impactos no sistema imunológico e diminuição dos processos de recuperação do corpo (SHARMA; GEDEON, 2012). Além destes, doenças psicológicas como depressão, ansiedade, fadiga (ALBERDI; AZTIRIA; BASARAB, 2016), raiva, problemas de memória e dificuldades cognitivas (THAPLIYAL; KHALUS; LABRADO, 2017).

Além das doenças que podem ser ocasionadas diretamente pelo estresse, é possível que elas acabem desencadeando outras doenças ou distúrbios. Pacientes estressados e com depressão possuem maior propensão ao uso de drogas ilícitas, álcool e tabaco, alterações no padrão de sono, redução nutricional e de atividade física (REICHE; NUNES; MORIMOTO, 2005). Todos estes problemas impactam diretamente na economia mundial. Devido a elas, são estimados gastos anuais maiores que 300 milhões de dólares nos Estados Unidos (The American Institute Of Stress, 2013), e mais de 617 bilhões de euros em todo o continente Europeu (European Agency for Safety and Health at Work, 2014).

2.3 DETECÇÃO CLÍNICA DE ESTRESSE NOS DIAS DE HOJE

Atualmente, o método mais encontrado na literatura brasileira para detecção de estresse é o inventário de sintomas de *stress* para adultos de Lipp (JUNIOR *et al.*, 2014; RAMIRO *et al.*, 2014; ROSSETTI *et al.*, 2008). Este método é utilizado para identificar os sintomas apresentados pelo ser humano, para posterior análise e determinação da fase em que o indivíduo está enquadrado (JUNIOR *et al.*, 2014). As possíveis fases do estresse determinadas por Lipp são (RAMIRO *et al.*, 2014):

1. Alerta: fase positiva, onde o corpo libera adrenalina;
2. Resistência: fase onde há uma resistência do ser humano para lidar com as situações estressantes;
3. Quase-exaustão: fase onde as defesas do indivíduo começam a ceder, e também o corpo já começa a sentir sintomas do estresse;

4. Exaustão: fase onde o indivíduo apresenta exaustão física e mental, além do aparecimento de doenças mais graves.

Mundialmente, existem diversos outros métodos utilizados tais como escala de estresse percebido (WARTTIG *et al.*, 2013), escala de reajustamento social, transtorno de estresse pós-traumático (NOBLE, 2002), além do inventário de ansiedade traço-estado (*State-Trait Anxiety Inventory - STAI*) (SCHMIDT *et al.*, 2018). Todos estes métodos utilizam questionários para identificar qual o nível de estresse que o paciente se encontra (EZZATI *et al.*, 2014). No caso da escala de estresse percebido, por exemplo, o paciente deve mensurar o seu estresse respondendo apenas catorze perguntas sobre a frequência em que situações estressantes ocorreram (WARTTIG *et al.*, 2013). Normalmente, a frequência é determinada através de uma escala de zero a cinco onde zero significa "nunca" e cinco significa "quase sempre". Ainda, estudos têm mostrado que estes métodos tradicionais (como o STAI) são eficazes para a identificação de níveis baixos ou altos de estresse no momento atual (METZGER, 1976).

Além dos questionários e avaliação psicológica, pode-se realizar o exame de cortisol (NOBLE, 2002). A irregularidade do hormônio é verificada pela análise clínica de amostras de sangue, saliva, urina ou cabelo (GREENE; THAPLIYAL; CABAN-HOLT, 2016). Geralmente, exames com pessoas sob níveis normais de cortisol resultam em 25 mg/d, e pessoas sob estresse podem apresentar níveis maiores chegando até 300 mg/d (NOBLE, 2002).

O problema destes métodos é que são multifatoriais e complexos, e avaliam apenas o estado atual (NOBLE, 2002), pois o paciente responde às questões com base na sua percepção de conceitos subjetivos (tais como, bom ou mal, rápido ou lento), interpretando-as à sua maneira (CARNEIRO *et al.*, 2018). Além disso, corre-se o risco do paciente mentir ou omitir informações relevantes. Então, surge a necessidade de aliar a avaliação das alterações fisiológicas causadas pelo estresse à avaliação clínica já realizada através de questionários, tornando-a assim, mais consistente, eficaz, longitudinal e em tempo real.

3 SISTEMAS DE DETECÇÃO AUTOMÁTICA DE ESTRESSE

“Let’s go invent tomorrow instead of worrying about what happened yesterday.”

Steve Jobs

O desenvolvimento de um sistema de detecção automática de estresse de forma não invasiva, contínua e automática é uma tarefa não trivial (ALBERDI; AZTIRIA; BASARAB, 2016). Este capítulo tem por objetivo é detalhar como tais sistemas são estruturados. Na Seção 3.1, a arquitetura e forma como os sistemas funcionam são definidos. Na Seção 3.2, é especificado como o treinamento e teste dos classificadores podem ser realizados. Na Seção 3.3, é descrito como avaliar os resultados obtidos pelos sistema. Por fim, na Seção 3.4, são apresentados como os sistemas podem utilizar a complementaridade de informações para realizar melhores detecções.

3.1 DETECÇÃO AUTOMÁTICA DE ESTRESSE

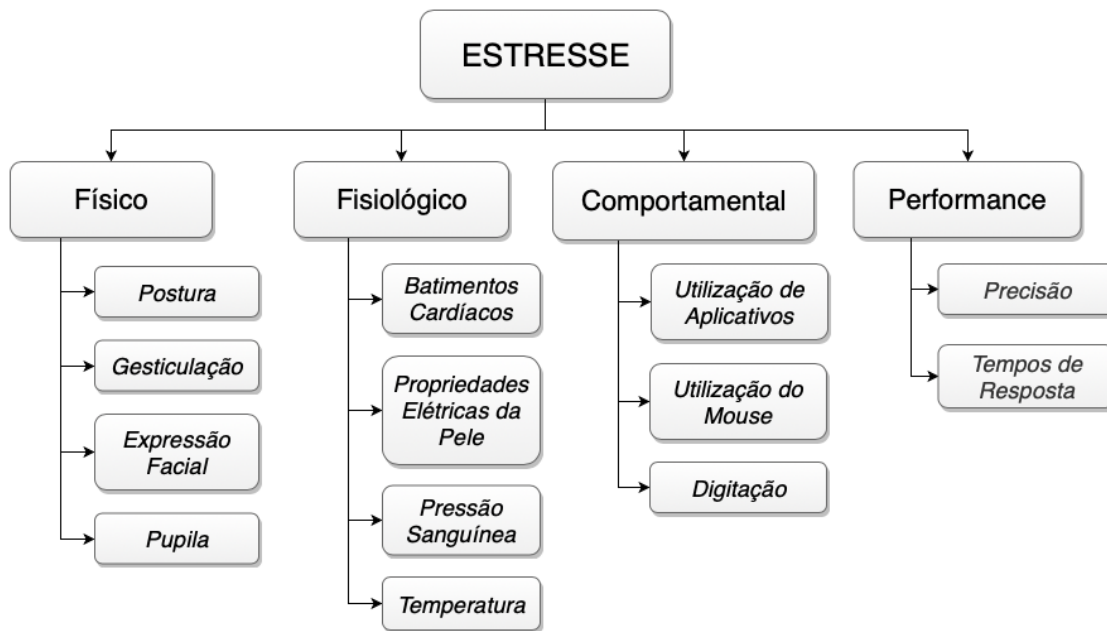
A tarefa de detecção automática de estresse (DAE) tem como objetivo identificar se um indivíduo está em um estado estressante em um determinado instante. Para que este processo ocorra de forma automática, é necessário que as alterações (hormonais, psicológicas e fisiológicas) causadas pelo estresse sejam monitoradas (CARNEIRO *et al.*, 2018) e estimadas de forma objetiva e independente (sem a intervenção humana) a fim de obter respostas em tempo real. Dessa forma, em um cenário automatizado, medidas subjetivas baseadas em questionários e testes psicológicos não são necessários para a detecção de estresse.

As alterações decorrentes do estresse que podem ser medidas de forma objetiva podem ser divididas em quatro tipos (Figura 3) (CARNEIRO *et al.*, 2018):

- Físico: movimentos corporais como atividades oculares e faciais, postura e gesticulação;
- Fisiológico: alterações fisiológicas do corpo como batimentos cardíacos (coletados pelo ECG) (SHARMA; GEDEON, 2012), pressão sanguínea, temperatura, propriedades elétricas da pele, tensão muscular (coletado pelo Eletromiograma (EMG) geralmente acoplado ao músculo trapézio) (HEALEY; PICARD, 2005), entre outros;
- Comportamental: de forma não invasiva, pode-se verificar o comportamento do indivíduo por meio do monitoramento da utilização de aplicativos de um *smartphone*, digitação e utilização do mouse de um computador;

- Performance: relacionado a precisão das atividades realizadas e ao tempo que o indivíduo levou para desempenhá-las.

Figura 3: Modelo de reconhecimento de estresse



Fonte: Elaborado pelo autor (2019)

Dentre os diversos dados que podem ser utilizados, SHARMA; GEDEON (2012) criaram uma tabela empírica¹ (Tabela 1) com a ordenação de prioridade dos sinais captados para a utilização no problema de detecção de estresse. Ela foi definida por meio da análise da quantidade de utilizações que constam na literatura e do nível de invasibilidade dos sensores.

Assumindo que todos os indivíduos estão em estado normal (sem estresse), o objetivo de um sistema de DAE é detectar em que momento o estado é alterado para estressante por meio das alterações do corpo. Dessa forma, a tarefa de detecção pode ser formulada como um problema de classificação de duas classes (DUDA; HART; STORK, 2000): estado normal e estado estressante.

A arquitetura de um sistema tradicional de detecção de padrões pode ser dividida em 5 etapas (Figura 4): coleta de dados, pré-processamento, extração de características, seleção de características e classificação (AKMANDOR; JHA, 2017; ALBERDI; AZTIRIA; BASARAB, 2016; DUDA; HART; STORK, 2000).


¹ Empírica significa que não possui comprovação científica, mas que foi constatada por meio de experimentos.

Tabela 1: Classificação empírica de sensores para detectar o estresse

Classificação	Sensor
1	HRV
2	EDA
3	Eletroencefalografia (EEG)
4	Diâmetro da Pupila
5	Voz
6	Foco do olhar
7	Expressão facial
8	Pressão Sanguínea
9	Temperatura
10	BVP
11	Piscar do olho
12	Respiração
13	EMG

Fonte: Adaptada de SHARMA; GEDEON (2012)

Figura 4: Processo dos sistemas de detecção de padrões



Fonte: Elaborado pelo Autor (2019)

3.1.1 Coleta de Dados


A primeira etapa para um sistema de detecção é a coleta de dados, onde deve-se realizar um trabalho minucioso para ter alta qualidade (MARÉE, 2017). Além do mais, segundo WYATT; LIU (2002), os dados precisam ser completos, relevantes, precisos, suficientemente detalhados e devem possuir informações contextuais para uma possível tomada de decisão. Não menos importante, é necessário uma grande quantidade de amostras coletadas dos experimentos para que se possa ter diversas variações das classes de dados (MARÉE, 2017).

No intuito de coletar informações, medidas e alterações do meio físico, são utilizados equipamentos chamados sensores (National Research Council, 1997). Eles são responsáveis pela geração de algum tipo de sinal (geralmente elétrico) através da interação entre o sensor e o ambiente físico em que está inserido. Alguns sensores podem ser simples e prover a leitura direta de informações (como um termômetro), outros podem ser mais complexos (como um radar, onde precisa propagar sinais conhecidos para que na reflexão do sinal possa encontrar o

alvo). Sensores são utilizados, neste trabalho, para a coleta de sinais relevantes ao problema de detecção de estresse.

Dois problemas comuns podem ocorrer na coleta: quantidade insuficiente de dados para estimar os modelos (falta de dados) e grande diferença entre a quantidade de amostras de uma classe para a outra (classes não balanceadas) (NGUYEN; BOUZERDOUM; PHUNG, 2009). Estes problemas farão com que não seja obtida uma boa modelagem na etapa de classificação, de forma a identificar majoritariamente a classe que mais possui amostras (Figura 5a) (DUDA; HART; STORK, 2000). No entanto, quando se possui grande quantidade de amostras, o problema do balanceamento pode ser minimizado (Figura 5b) (NGUYEN; BOUZERDOUM; PHUNG, 2009).

Figura 5: Exemplo de (a) pouca quantidade de amostras e (b) boa quantidade de amostras. A linha pontilhada é a divisão determinada pelo sistema e a linha sólida é como a divisão das classes é de fato.



Fonte: Adaptado de NGUYEN; BOUZERDOUM; PHUNG (2009)

3.1.2 Pré-processamento

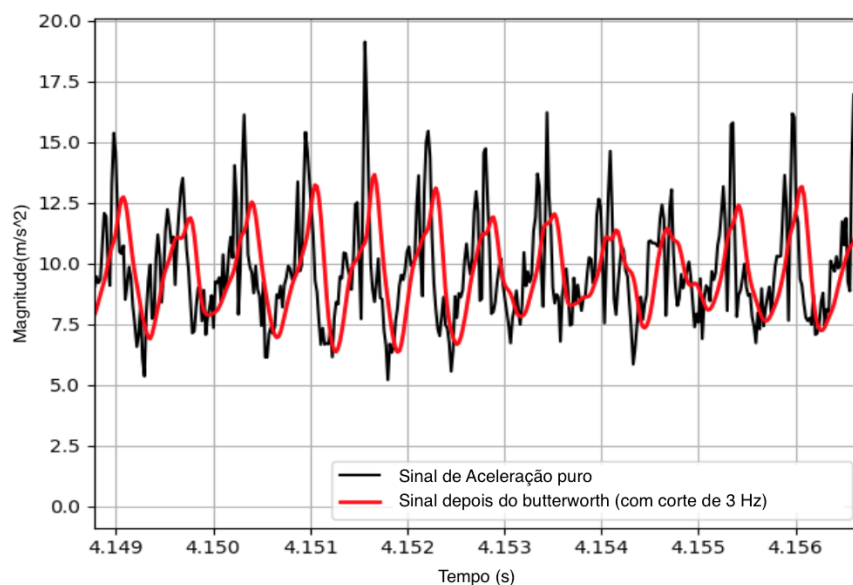
Nesta etapa, o objetivo é o tratamento dos dados coletados pelos sensores para simplificar as próximas etapas do processo (DUDA; HART; STORK, 2000). Contudo, diferentes métodos e técnicas são utilizadas no pré-processamento para diferentes tipos de sinais. Em imagens, por exemplo, a luz e as sombras que incidem sobre o objeto podem variar (essas variações são chamadas de ruídos) de forma a influenciar negativamente nos resultados, se realizado tratamento inadequado dos dados. Ainda, segundo DUDA; HART; STORK (2000), os ruídos de um sinal são "qualquer propriedade do padrão captado, que devido a aleatoriedade do mundo ou dos sensores, não representam o verdadeiro modelo fundamental. Todos os problemas de reconhecimento de padrões não triviais envolvem ruído em alguma forma"².

² Texto original: "any property of the sensed pattern due not to the true underlying model but instead to randomness in the world or the sensors. All non-trivial decision and pattern recognition problems involve noise in some form".

Para a etapa de pré-processamento, pode-se considerar dois processos correlacionados:

- **Segmentação:** consiste em separar os dados em janelas de tempo de qualquer tamanho (ZHANG *et al.*, 2017). Estas janelas são analisadas e quando os dados não correspondem logicamente aos valores possíveis, essas janelas podem ser descartadas ou corrigidas através da filtragem (GJORESKI *et al.*, 2017). Por exemplo, sabe-se que a temperatura corporal geralmente é em torno de 36°C. Assim, é logicamente impossível uma pessoa possuir temperatura 36°C em um segundo, no outro possuir 5°C e, logo após, voltar aos 36°C. Neste caso, pode-se considerar que houve um ruído nos dados e a janela que contém estes dados pode ser descartada.
- **Filtragem:** consiste em remover os ruídos identificados nos conjuntos de dados coletados (SHARMA; GEDEON, 2012). Neste processo, pode ser feita a remoção de dados que não condizem com a realidade ou realizar o ajuste dos mesmos. Uma técnica de filtragem pode ser utilizada quando há a necessidade de extrair informações de alguma frequência específica (BANSAL RITU SHARMA, 2010). Neste caso, pode-se utilizar o filtro *Butterworth* (AKMANDOR; JHA, 2017; ALBERDI; AZTIRIA; BASARAB, 2016) que seleciona uma banda de frequência (Figura 6) (também chamado de *low-pass filter*³) (ELLIS, 2012; BANSAL RITU SHARMA, 2010). Outra técnica estatística utilizada para a filtragem é a *Winsorization* onde, com base em um percentual informado como parâmetro, são removidos os valores atípicos (Figura 7) (GJORESKI *et al.*, 2017).

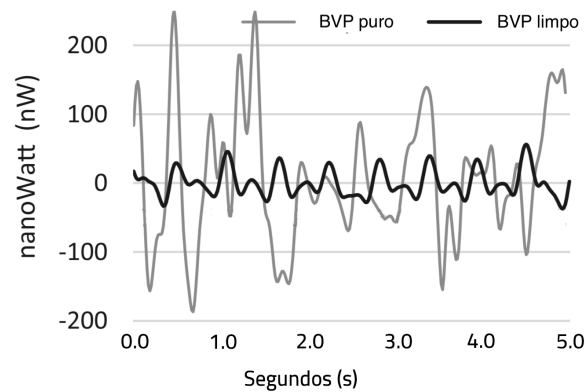
Figura 6: Filtragem *Butterworth* com corte de frequência 3Hz



Fonte: Adaptado de WANG *et al.* (2019)

³ Filtro de extração das frequências abaixo de uma frequência de corte específica.

Figura 7: Filtragem de valores atípicos de 5 segundos de sinal do BVP




Fonte: Adaptado de GJORESKI *et al.* (2017)

3.1.3 Extração de características

Segundo WEBB; COPSEY (2011), pode-se definir extração de características como "a transformação dos dados originais (utilizando todas as variáveis) em dados com um número de variáveis reduzidas"⁴. Com a redução conceituada, a quantidade de dados que será passada ao classificador posteriormente será menor (DUDA; HART; STORK, 2000). Em um exemplo de extração, considere 3500 dados (x_p) que foram gerados através da coleta de um sinal à uma frequência de 700Hz durante 5 segundos. Através do processo de extração, é possível diminuir os 3500 dados em um conjunto de características (f_n) que representam estes 5 segundos (Figura 8). A dimensionalidade do conjunto gerado depende da quantidade de características extraídas, mas normalmente é de 3 à 20 no problema de detecção de estresse (MONTESINOS *et al.*, 2019; AKMANDOR; JHA, 2017; REN *et al.*, 2014; SETZ *et al.*, 2010; ZHAI; BARRETO, 2006).

Figura 8: Extração dos dados originais em características



Fonte: Adaptado de WEBB; COPSEY (2011)

⁴ Texto original: "the transformation of the original data (using all variables) to a dataset with a reduced number of variables".

Para cada sensor utilizado no problema de detecção automática de estresse, é possível realizar a extração de diferentes características que podem ser separadas em duas categorias (ALBERDI; AZTIRIA; BASARAB, 2016):

- Medidas estatísticas: a partir dos dados originais, é possível estimar a média (SIERRA *et al.*, 2011), mediana, valor mínimo e máximo, desvio padrão, variância, simetria, curtose e extensão, entre outras (AIGRAIN *et al.*, 2018; SCHMIDT *et al.*, 2018; AKMANDOR; JHA, 2017; WANG; LIN; YANG, 2013; ZHAI; BARRETO, 2006; HEALEY; PICARD, 2005);
- Frequência: são as características extraídas do conjunto de dados no domínio da frequência. Podem ser utilizados dados de baixa (BF) e alta frequência (AF), a razão entre BF e AF, a frequência média, entre outras (SCHMIDT *et al.*, 2018; GJORESKI *et al.*, 2017; AKMANDOR; JHA, 2017; WANG; LIN; YANG, 2013; HEALEY; PICARD, 2005).

É comum a utilização de algoritmos para a transformação dos dados para extração de mais características relevantes. Uma transformação utilizada na tarefa de detecção de estresse é a conversão do domínio de tempo para o domínio da frequência (ou vice-versa). Este processo tem como objetivo extrair dados que podem ser significativos no outro domínio (SHARMA; GEDEON, 2012). As duas técnicas mais utilizadas são: Transformada de Fourier (CAN; ARNRICH; ERSOY, 2019; GREENE; THAPLIYAL; CABAN-HOLT, 2016; HOU *et al.*, 2015; KUMAR *et al.*, 2007) e Transformada de Wavelet (CAN; ARNRICH; ERSOY, 2019; KUMAR *et al.*, 2007). Utilizando a Transformada de Fourier, por exemplo, pode-se decompor o sinal original (Figura 9) nas frequências puras que o constituem (Figura 10) (GONZALEZ; WOODS, 2006). Além disso, através da soma dos senos e/ou cossenos das diferentes frequências que foram encontradas é possível retornar ao sinal original (GONZALEZ; WOODS, 2006).


3.1.4 Seleção de características

Após a extração, as características mais discriminativas (relevantes ao problema em questão) podem ser selecionadas. Este processo tem como objetivo selecionar os subconjuntos das variáveis originais (WEBB; COPSEY, 2011) e remover as que são correlacionadas ou que possuam baixo nível de informações (GJORESKI *et al.*, 2017). Ainda, segundo WEBB; COPSEY (2011), pode-se definir essa etapa como "o processo de selecionar as características que são importantes para a classificação, removendo as que são irrelevantes e redundantes"⁵.

O fato de descartar características extraídas fará com que não seja desperdiçado tempo e custo computacional na etapa de classificação (devido aos cálculos realizados sob as variáveis fornecidas). Dessa forma, não será feito o processamento de informações desnecessárias sem

⁵ Texto original: "the process of selecting from the original features (or variables) those features that are important for classification, removing irrelevant and redundant variables."


Figura 9: Sinal original



Fonte: Adaptada de Mathworks^a

^a <<https://www.mathworks.com/help/matlab/ref/fft.html>>. Acesso em: 8 de Junho de 2019

Figura 10: Diferentes frequências extraídas do sinal original



Fonte: Adaptada de Mathworks^a

^a <<https://www.mathworks.com/help/matlab/ref/fft.html>>. Acesso em: 8 de Junho de 2019

obter resultados melhores (KHALID; KHALIL; NASREEN, 2014). Além disso, a redução da dimensionalidade permite a utilização de modelos mais simples que requerem menos amostras para treinamento (WEBB; COPSEY, 2011).

Os métodos utilizados para seleção de características podem ser organizados em três categorias (WEBB; COPSEY, 2011):

- Filtro: utiliza os dados estatísticos das características para descartar os que possuem menos informações (WEBB; COPSEY, 2011). Possui rápido processamento e custo computacional baixo se comparado às demais categorias. Nessa categoria é possível identificar diversas técnicas utilizadas, como a análise de componentes principais (*Principal Component Analysis* - PCA) (BUGDOL; MITAS, 2014; WANG; LIN; YANG, 2013), *Joint Mutual Information* (MUAREMI *et al.*, 2014), *Wilcoxon* e *Spearman Correlation* (MONTESINOS *et al.*, 2019), além da análise discriminante linear (*Linear Discriminant Analysis* - LDA) (WANG; LIN; YANG, 2013);
- Empacotamento (*Wrapping*): depende de um classificador para a aplicação da seleção. Os subconjuntos de características são avaliados e selecionados através dos resultados apresentados no classificador (acurácia) (WEBB; COPSEY, 2011). Normalmente possuem resultados melhores que a categoria de filtro. Além disso, é possível identificar a utilização dos seguintes empacotadores: seleção direta flutuante sequencial (*sequential forward floating selection*) (SANO; PICARD, 2013), seleção retroativa sequencial (*sequential backward selection*) (GIAKOUMIS; TZOVARAS; HASSAPIS, 2013) e melhor combinação (SETZ *et al.*, 2010);
- Embarcado: também possui dependência de um classificador. Portanto, nesta categoria, a seleção das características é realizada juntamente com o processo de classificação. Um exemplo de técnica para a detecção de estresse é a *Random Forest* (SCHMIDT *et al.*, 2018; REN *et al.*, 2014), que realiza a seleção das características que possuem maior pureza na criação dos nodos (DUDA; HART; STORK, 2000).

Neste trabalho, serão avaliados os métodos baseados na categoria filtro: PCA e LDA.

3.1.4.1 Análise de Componentes Principais

Segundo HONGYU; SANDANIELO; JUNIOR (2016), a análise de componentes principais é "uma técnica estatística de análise multivariada que transforma linearmente um conjunto original de variáveis, inicialmente correlacionadas entre si, num conjunto substancialmente menor de variáveis não correlacionadas que contém a maior parte da informação do conjunto original". Neste contexto, a PCA realiza projeções de eixos ortogonais que caracterizam os dados do conjunto original, porém, utilizando menos dimensões através da criação de novas variáveis

(componentes principais) compondo a matriz de projeção (SANTO, 2012). Neste cenário, a PCA tem como objetivo criar os componentes principais que representam a direção de maior variação dos dados (DUDA; HART; STORK, 2000).

A análise de componentes principais é aplicada através das seguintes etapas (DUDA; HART; STORK, 2000; JAIN; DUIN; MAO, 2000):

1. Normalizar os dados removendo a sua média;
2. Calcular a matriz de covariância dos dados (Σ);
3. Estimar os autovetores (e_n) e autovalores (λ_n);
4. Calcular o percentual de variância explicada⁶ de cada autovetor (VICINI, 2005);
5. Ordenar e selecionar os k autovetores de forma decrescente (para que os resultados sejam apresentados do autovetor que projetou no eixo a maior variância), gerando a matriz de projeção. Normalmente, são selecionados os autovetores que suprem 95% da variância total explicada (JACKSON, 1993);
6. Realizar a transformação linear das amostras ($Y = XH$, onde H é a matriz de projeção (autovetores são as colunas), X é a matriz de amostras e Y é a matriz dos dados projetados).

3.1.4.2 Análise Discriminante Linear

A técnica de análise discriminante linear tem como objetivo maximizar a separação entre as classes e minimizar a variação entre os dados da classe (WEBB; COPSEY, 2011; THEODORIDIS; KOUTROUMBAS, 2009). Ela é muito semelhante à PCA, mas realiza a estimação das direções de maior variabilidade com base em matrizes de espalhamento em vez da matriz de covariância. As matrizes de espalhamento são calculadas conforme a seguir (WEBB; COPSEY, 2011; JAIN; DUIN; MAO, 2000; VARELLA, 2002):

1. Calcular a matriz de dispersão entre as classes (s_b), sendo C o número de classes, n_i o número de amostras na classe i , n o número total de amostras, m_i a média das amostras da classe i e \bar{m} a média das médias das classes:

$$s_b = \sum_{i=1}^C \frac{n_i}{n} (m_i - \bar{m})(m_i - \bar{m})^T \quad (3.1)$$

2. Calcular a matriz de dispersão de cada classe (s_w), sendo k o número de amostras da classe e Σ_i a matriz de covariância da classe w_i :

$$s_w = \sum_{i=1}^k \frac{n_i}{n} \Sigma_i \quad (3.2)$$

⁶ O percentual de variância explicada é o percentual de variância (relevância) que o autovalor tem sobre os dados originais.

3. Calcular a matriz de dispersão para ser utilizada no lugar da matriz de covariância ($S_w^{-1}S_b$).

3.1.5 Classificação

A etapa de classificação consiste na utilização de técnicas de detecção de padrões (classificadores) com o objetivo de diferenciar os estados do indivíduo (normal e estressado) (SANSONE *et al.*, 2013). Segundo WEBB; COPSEY (2011), o processo de classificação é realizado através da aplicação de "um algoritmo de aprendizagem para a busca através do espaço de parâmetros para encontrar o modelo que melhor descreve a relação entre as características e a classe associada"⁷.

Dentre os diversos tipos de classificadores, pode-se dividi-los em dois grupos (WEBB; COPSEY, 2011; DUDA; HART; STORK, 2000):

- Paramétricos: classificadores baseados na distribuição da probabilidade estatística conhecida das classes. Classificadores paramétricos utilizados no problema de detecção de estresse incluem a Análise Discriminante Linear (*Linear Discriminant Analysis*) (HEALEY; PICARD, 2005), Classificação de Bayes (GJORESKI *et al.*, 2017; REN *et al.*, 2014) e Redes Neurais Artificiais (*Artificial Neural Network*) (SANSONE *et al.*, 2013);
- Não paramétricos: métodos que não realizam suposições sobre a distribuição das classes. Classificadores não paramétricos utilizados no problema de detecção de estresse incluem Máquina de vetores de suporte (*Support Vector Machine - SVM*) (AKMANDOR; JHA, 2017; GJORESKI *et al.*, 2017; ZHANG *et al.*, 2017; SANSONE *et al.*, 2013; SIERRA *et al.*, 2011; ZHAI; BARRETO, 2006), K-vizinhos mais próximos (*K-Nearest Neighbors - KNN*) (AKMANDOR; JHA, 2017; GJORESKI *et al.*, 2017; SIERRA *et al.*, 2011), Lógica Fuzzy (*Fuzzy Logic*) (SIERRA *et al.*, 2011) e Árvore de Decisão (*Decision Tree - DT*) (GJORESKI *et al.*, 2017; REN *et al.*, 2014).

As técnicas mais utilizadas nos últimos 5 anos na tarefa de detecção automática de estresse são SVM, DT e KNN, nesta ordem. Utilizando o Google Acadêmico, foi realizada uma pesquisa com os termos ["*stress detection*" OU "*stress recognition*"] E "[técnica]". Foram obtidos 1390 resultados (artigos) para SVM, 656 para DT e 580 para KNN.

3.1.5.1 Máquinas de Vetores de Suporte

Em uma situação onde é necessário dividir duas classes distintas em uma projeção de 2 dimensões, pode-se utilizar uma reta (com mais dimensões é utilizado um hiperplano) para realizar essa separação. Entretanto, pode-se criar a reta em diversos ângulos que as classes ainda

⁷ Texto original: *we employ a learning algorithm to search through the parameter space to find the model that best describes the relationship between the measurements and class labels for the training set*


seriam separadas corretamente (Figura 11a). Neste contexto, o objetivo do SVM é encontrar o hiperplano que realize a separação das classes com a maior margem⁸ possível entre elas (Figura 11b) (WEBB; COPSEY, 2011).

A classificação de amostras rotuladas com as classes w_1 e w_2 é realizada através da função linear $g(x)$ resultando em $y_i = \pm 1$, onde y_i identifica de qual lado do hiperplano a amostra foi adicionada. Considere x como as novas amostras, w vetor de pesos e w_0 como a constante inicial, a função linear é representada por:

$$g(x) = w^T x + w_0 \begin{cases} > 0 & w_1 \text{ com resultado } y_i = +1 \\ < 0 & w_2 \text{ com resultado } y_i = -1 \end{cases} \quad (3.3)$$

onde o hiperplano é representado por $g(x) = 0$.

Figura 11: (a) Hiperplano para separação das classes (b) Hiperplano ótimo para separação das classes



Fonte: (a) Adaptado de WEBB; COPSEY (2011). (b) Adaptado de DUDA; HART; STORK (2000)

Por mais que a classificação do SVM é realizada de forma linear, existem casos em que as amostras não são linearmente separáveis. Dessa forma, para que o SVM realize a classificação e a separação das classes são realizados 2 processos (WEBB; COPSEY, 2011; DUDA; HART; STORK, 2000; JAIN; DUIN; MAO, 2000):

1. **Escolha da função Kernel:** quando as amostras não são linearmente separáveis, a função *Kernel* é responsável por projetar as características, através de n-dimensões, até que a separação seja possível por meio de um hiperplano.

⁸ Margem é o espaço de separação entre o hiperplano definido e os vetores de suporte.

As funções mais utilizadas são: polinomial, função de base radial (*Radial Basis Function* - RBF) e Sigmoidal. Para cada uma das funções é necessário que sejam definidos os parâmetros conforme a Tabela 2 (THEODORIDIS; KOUTROUMBAS, 2009).


Tabela 2: Funções Kernel SVM

Kernel	Função $K(x_i, x_j)$	Parâmetros
Polinomial	$\delta(x_i x_j) + c)^d$	$\delta, c =$ termo independente, $d =$ grau do polinômio
RBF	$e^{(-\sigma \ x_i - x_j\ ^2)}$	σ
Sigmoidal	$\tanh(\delta(x_i x_j) + c)$	$\delta, c =$ termo independente

Fonte: Elaborado pelo autor (2019)

Em um problema onde os dados estão distribuídos de forma com que não é possível a separação por meio de um hiperplano (Figura 12a) pode ser utilizada, por exemplo, a função *kernel* polinomial de grau 2. Dessa forma, será gerada uma nova dimensão realizando o cálculo de cada amostra com a função *kernel*. Após o aumento da dimensionalidade, é possível determinar um hiperplano para a separação das amostras (Figura 12b).

Figura 12: Aumento da dimensionalidade com função kernel




Fonte: Towards Data Science^a

^a <<https://towardsdatascience.com/the-kernel-trick-c98cdbcaeb3f>>. Acesso em: 3 de Novembro de 2019

- Definição dos vetores de suporte e hiperplano:** os vetores de suporte são as amostras de diferentes classes mais próximas, mais difíceis de serem classificadas e que definem o início da margem entre as classes (DUDA; HART; STORK, 2000). Elas são selecionadas através da análise realizada sob todas as amostras, buscando a minimização do erro de classificação e a maximização da margem. É possível definir um erro tolerável na separação das classes, tornando a margem suave (*soft margin*), ou realmente definir que

não é possível ter erros de classificação (Figura 13). Este problema de otimização para encontrar o hiperplano ótimo é resolvido através do sistema de otimização de Lagrange (WEBB; COPSEY, 2011). Após a seleção dos vetores de suporte o hiperplano é definido no meio entre os dois vetores.

Figura 13: Exemplo da classificação do SVM conforme a utilização do parâmetro de erro. Margem restrita representado pelo $\gamma = 100$ e margem suave representado pelo $\gamma = 0,01$.



Fonte: Towards Data Science^a

^a <<https://towardsdatascience.com/understanding-support-vector-machine-part-2-kernel-trick-mercercs-theorem-e1e6848c6c4d>>. Acesso em: 3 de Novembro de 2019

3.1.5.2 Árvore de Decisão

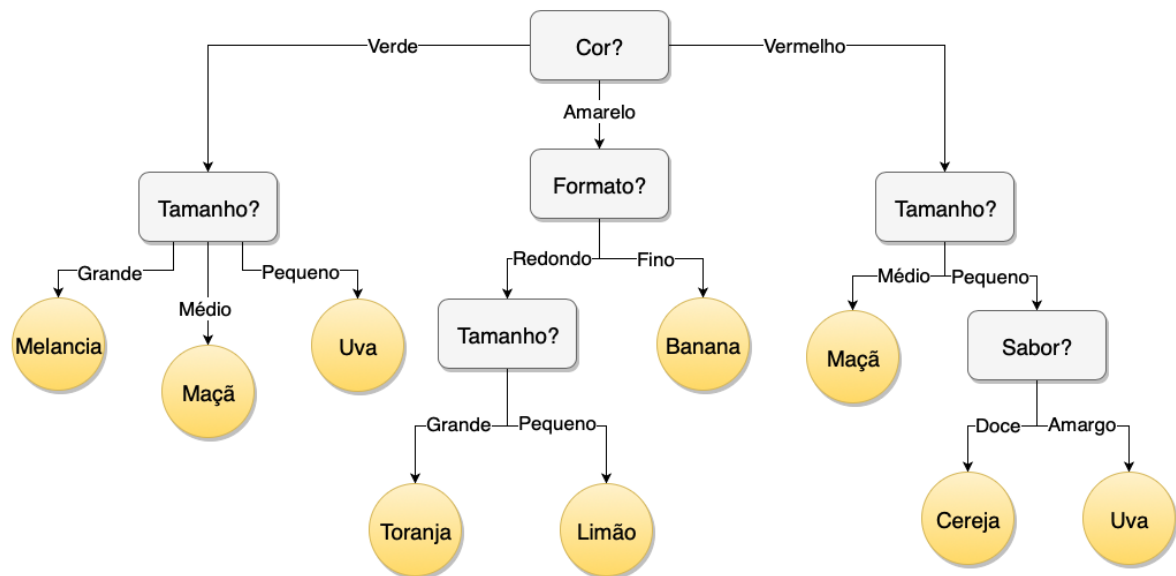
A árvore de decisão é representada por uma estrutura de dados em formato de nodos (DUDA; HART; STORK, 2000). O nodo raiz e os nodos intermediários são as características (uma única característica pode ser dividida em mais que um nodo). As ligações entre os nodos são os valores respostas, indicando para qual lado o algoritmo irá seguir conforme a resposta da característica. As folhas (ou nodos terminais) são os resultados encontrados pelo fluxo da árvore de decisão (WEBB; COPSEY, 2011). Além disso, este método possui uma seleção de características embarcada, portanto a árvore de decisão é criada apenas com as características mais discriminativas para que o resultado esperado seja obtido (JAIN; DUIN; MAO, 2000). A construção das árvores de decisão possui três etapas (WEBB; COPSEY, 2011):

1. Definir uma regra de divisão de nodos intermediários: ou seja, como será realizada a divisão das características e seus valores. Portanto, para cada nodo é realizado o cálculo de impureza e o objetivo deste cálculo é que a cada nível da árvore os nodos sejam mais puros (sem erros);
2. Definir quais nodos são terminais (ou folhas): o objetivo é definir se será realizada a divisão de mais um nodo ou será definido como nodo terminal. Essa decisão é feita através da escolha da opção que possuir a menor taxa de erro de classificação;

- Determinar os resultados dos nodos terminais: no problema de classificação de estresse, os resultados terminais serão os estados "Estressante" e "Normal";

Assuma um problema no qual o objetivo é classificar os diferentes tipos de frutas através das variáveis que podem ser extraídas como cor, tamanho, formato e sabor (Figura 14). Primeiro, os nodos (raiz e intermediários) que correspondem as características mais discriminativas são criados. No caso da classificação de uma banana, por exemplo, sabe-se que ela possui cor amarela e formato fino então, pode-se criar uma sequência de nodos intermediários para estas duas características e um nodo terminal para a classe banana (DUDA; HART; STORK, 2000). Este processo é realizado sucessivamente para as classes e características do problema.

Figura 14: Exemplo da estrutura de uma árvore de decisão



Fonte: Adaptado de DUDA; HART; STORK (2000)

Com o objetivo de melhorar a classificação deste algoritmo, é possível utilizar diversas árvores de decisão. Neste método, conhecido como *Random Forest* - RF (WEBB; COPSEY, 2011), são criadas n árvores diferentes a partir de amostragens do conjunto dos dados originais (*bootstrap*). A decisão é realizada através dos votos da maioria das árvores.

3.1.5.3 K-vizinhos mais próximos

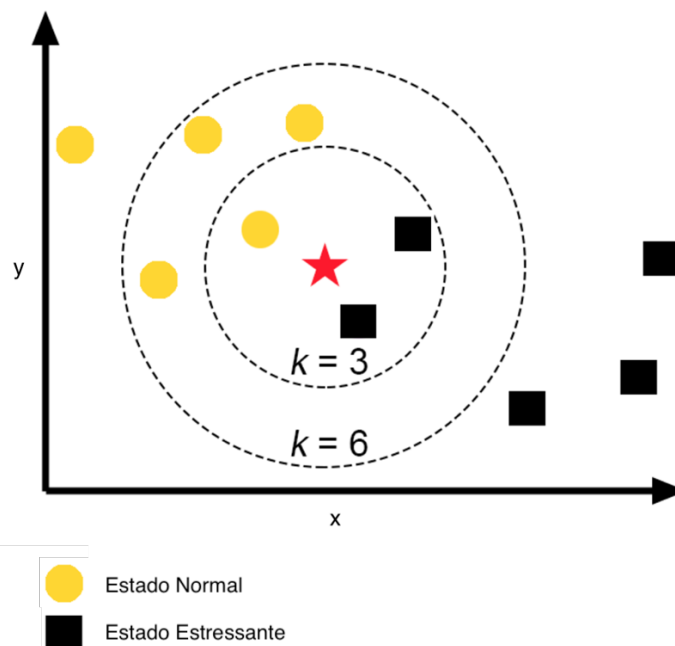
Esta técnica é baseada no conceito de similaridade e proximidade. Quando houver a inserção de uma nova amostra, o algoritmo irá identificá-la pertencente a classe da maioria das amostras mais próximas (conforme parâmetro de quantas amostras serão avaliadas) (TRIGUERO *et al.*, 2016). Para o funcionamento do KNN é necessário que algumas especificações iniciais sejam realizadas (WEBB; COPSEY, 2011):

1. Medida de Distância: geralmente a distância euclidiana é utilizada para determinar o espaço entre a nova amostra e todas as amostras do modelo. Sendo N a quantidade de amostras de referência, a distância é calculada conforme fórmula:

$$d_{Euclidiana} = \sqrt{\sum_{i=1}^N (x_i - y_i)^2} \quad (3.4)$$

2. Número de vizinhos (k): define quantos pontos mais próximos conforme a medida de distância devem ser utilizados para definir a classe da nova amostra. No problema de classificação de duas classes mostrado na Figura 15, se assumirmos que $k = 3$, a nova amostra representada pela estrela seria classificada como estresse pois é realizada a votação da maioria através das amostras mais próximas (onde existem duas amostras da classe "estresse"). No caso da parametrização $k = 6$, a nova amostra seria classificada como "normal" devido a maioria das amostras próximas serem desta classe.

Figura 15: Inserção de amostra no espaço do algoritmo KNN



Fonte: Adaptado de Medium^a

^a Disponível em: <<https://medium.com/brasil-ai/knn-k-nearest-neighbors-1-e140c82e9c4e>>. Acesso em 13 de Junho de 2019.


3.2 TREINAMENTO DOS CLASSIFICADORES

Para que os classificadores consigam realizar a identificação correta de quando o indivíduo está estressado e quando não está, é necessário que seja realizado um treinamento do sistema.

Para a realização deste processo, as amostras são divididas entre amostras de treinamento e amostras de testes. A separação pode ser realizada das seguintes formas (JAIN; DUIN; MAO, 2000):

- *Holdout*: é realizada a divisão em dois grupos ("amostras de treinamento" e "amostras de teste"), normalmente utilizando 2/3 dos dados para treinamento e 1/3 para testes (Figura 16);


Figura 16: Divisão de amostras da técnica de treinamento *Holdout*



Fonte: Elaborado pelo autor (2019)

- *Stratified Holdout*: utiliza do mesmo princípio do *Holdout*. Entretanto, neste método os dados são divididos igualmente conforme cada classe. Dessa forma, são utilizados exclusivamente 2/3 dos dados da classe estresse e 2/3 da classe normal para treinamento. E também, 1/3 da classe estresse e 1/3 da classe normal para testes (Figura 17);

Figura 17: Divisão de amostras da técnica de treinamento *Stratified Holdout*




Fonte: Elaborado pelo autor (2019)

- *K-Fold*: é realizada a divisão de k subconjuntos das amostras. Após, é separado um destes subconjuntos para teste e o restante para treinamento. Este processo é repetido k vezes para que cada subconjunto passe pelo papel de "subconjunto de teste" (Figura 18));
- *Leave-one-out*: neste método são utilizadas $(n - 1)$ amostras para treinamento e a que não foi selecionada como teste. Este processo é repetido n vezes alterando a amostra selecionada para teste (Figura 19).

3.3 AVALIAÇÃO DE DESEMPENHO

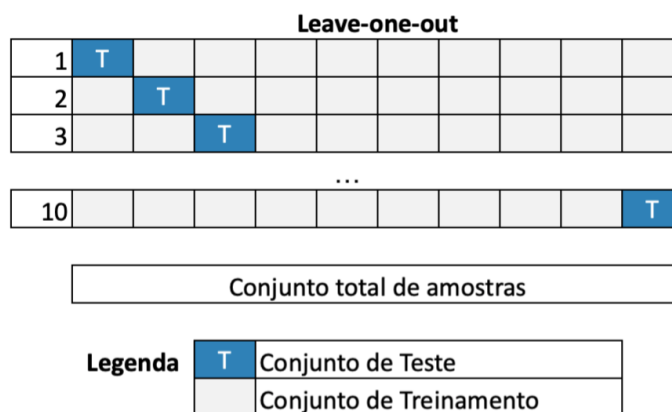
Uma das formas de avaliar o desempenho é por meio da matriz de confusão, que é construída através dos acertos e erros que o sistema de classificação produziu (DUDA; HART;

Figura 18: Divisão de amostras da técnica de treinamento *K-Fold*



Fonte: Elaborado pelo autor (2019)

Figura 19: Divisão de amostras da técnica de treinamento *Leave-one-out*



Fonte: Elaborado pelo autor (2019)

STORK, 2000). Em um problema de 2 classes (estado estressante e estado normal), a diagonal principal é preenchida com a quantidade de acertos realizados, enquanto que nas demais células é preenchida com a quantidade de erros (Figura 20) (HOSSIN; M.N, 2015; SOKOLOVA; LAPALME, 2009). Os elementos da matriz são:

- Verdadeiro Positivo (VP): quando o algoritmo acerta. O indivíduo foi classificado como normal;
- Falso Positivo (FP): quando o algoritmo erra. Neste caso, o indivíduo foi classificado incorretamente como estressado;
- Verdadeiro Negativo (VN): quando o algoritmo acerta. O indivíduo foi classificado como estressado;
- Falso Negativo (FN): quando o algoritmo erra. Neste caso, o indivíduo foi classificado incorretamente como normal.

Figura 20: Matriz de confusão para o problema de 2 classes na classificação do estresse do indivíduo

		Valores encontrados pelo Algoritmo		Legenda	
		Estado Normal	Estado Estressante		
Valores Esperados	Estado Normal	Verdadeiro Positivo (VP)	Falso Positivo (FP)	Acerto	
	Estado Estressante	Falso Negativo (FN)	Verdadeiro Negativo (VN)	Erro	

Fonte: Elaborada pelo autor (2019)

Algumas das métricas que podem ser estimadas a partir da matriz de confusão utilizadas na classificação de estresse são (WEBB; COPSEY, 2011; SOKOLOVA; LAPALME, 2009):

- Acurácia (ACC): fornece o percentual de amostras classificadas corretamente, estimado por:

$$ACC = \frac{VP + VN}{VP + FP + FN + VN} \quad (3.5)$$

- Sensitividade (SENS): tem como objetivo responder a pergunta: dentre todos os indivíduos que foram diagnosticados em estado normal, quantos o sistema avaliou corretamente? Esta medida é estimada por:

$$SENS = \frac{VP}{VP + FN} \quad (3.6)$$

- Especificidade (ESPEC): tem como objetivo responder a pergunta: dentre todos os indivíduos que foram diagnosticados em estado estressante, quantos o sistema avaliou corretamente? Esta medida é estimada por:

$$ESPEC = \frac{VN}{VN + FP} \quad (3.7)$$

A Tabela 3 mostra os resultados de diversos trabalhos em detecção de estresse. Pode-se observar que apenas a utilização do EDA pelo REN *et al.* (2014) não teve resultados elevados. Os demais resultados foram superiores à 80%.

3.4 DETECÇÃO MULTIMODAL

CARNEIRO *et al.* (2018) sugere que uma abordagem multimodal para a tarefa de DAE seja considerada, visto que estudos têm mostrado que a utilização de dados multimodais têm aumentado a acurácia da classificação (LIAO *et al.*, 2005). Entretanto, para ser considerado multimodal, devem ser utilizados diferentes tipos de equipamentos e técnicas de coleta de dados (LAHAT; ADALI; JUTTEN, 2014), por exemplo, utilizar um ECG - dados do coração, um EDA -

Tabela 3: Avaliação de desempenho de sistemas de detecção de estresse

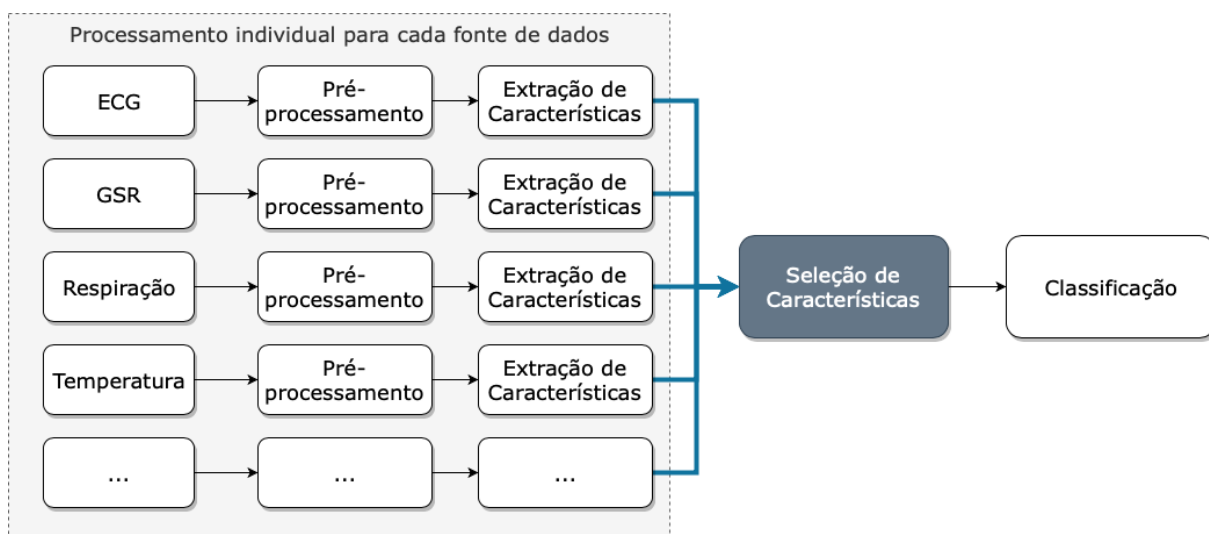
Referência Bibliográfica	Sinais Coletados	Indivíduos	Número de características	Técnica de redução	Acurácia
MONTESINOS <i>et al.</i> (2019)	ECG	42	9	<i>Wilcoxon</i> e <i>Spearman</i>	SVM = 88,0% DT = 94,0%
REN <i>et al.</i> (2014)	EDA	31	3	-	KNN = 53,2% DT = 43,3%
REN <i>et al.</i> (2014)	Diâmetro da Pupila	31	3	-	KNN = 87,1% DT = 86,6%
SETZ <i>et al.</i> (2010)	EDA	33	16	Melhor combinação	SVM = 81,3%

Fonte: Elaborada pelo Autor (2019)

dados da pele e um sensor para respiração (LIAO *et al.*, 2005). Ainda segundo LAHAT; ADALI; JUTTEN (2014), a multimodalidade fornece redundância à base de dados e essa abordagem pode ajudar a distinguir estados de estresse ou não pois, segundo LIAO *et al.* (2005), alguns sintomas como batimentos cardíacos e respiração acelerados não são observados apenas para o estresse.

Em um modelo de multimodalidade, o processo de detecção é realizado diferente de uma detecção com uma única fonte de dados (KOLDIJK; NEERINCX; KRAAIJ, 2018; AKMANDOR; JHA, 2017). Alguns estudos foram realizados onde o processo desde a coleta dos dados até a extração das características foi praticado de forma separada para cada informação coletada. Após, todas as características foram concatenadas para que a etapa de seleção fosse realizada de forma unificada (Figura 21).

Figura 21: Modelo multimodal de detecção de estresse



Fonte: Elaborado pelo autor (2019)

Por mais que o modelo multimodal pode tornar a tarefa mais complexa devido ao aumento de dimensionalidade das características, estudos realizados por KOLDIJK; NEERINCX; KRAAIJ

(2018) produziram melhores resultados se comparado à unimodalidade. Neste experimento, foram utilizadas mais de 140 características de diversas modalidades e o resultado foi melhor devido a utilização da seleção das melhores características de cada modalidade. O melhor desempenho utilizando apenas uma modalidade (40 características) foi 80,91% de acurácia, enquanto que foram necessárias apenas 25 características de diferentes modalidades para ter um desempenho relativo 4% melhor. Neste cenário, as diferentes modalidades fizeram com que o sistema obtivesse melhores resultados com menor custo computacional (na etapa de classificação, devido à menor dimensionalidade das características), demonstrando também, a importância da etapa de seleção das características deste modelo. O desempenho obtido na tarefa detecção de estresse da literatura multimodal é apresentado na Tabela 4. Pode-se observar que (REN *et al.*, 2014) (REN *et al.*) conseguiu resultados melhores na utilização da multimodalidade se comparado à Tabela 3.

Tabela 4: Avaliação de desempenho de sistemas de detecção multimodal de estresse

Referência Bibliográfica	Sinais Coletados	Indivíduos	Número de características	Técnica de redução	Acurácia
AKMANDOR; JHA (2017)	ECG, EDA, respiração, pressão e oxigenação do sangue	33	18	PCA	SVM = 86,7% KNN = 94,5%
MOZOS <i>et al.</i> (2017)	EDA e PPG	18	18	-	SVM = 93,0% KNN = 87,0%
MUAREMI <i>et al.</i> (2014)	ECG, temperatura, EDA, postura, acelerometria, respiração	10	12	<i>Joint Mutual Information</i>	SVM = 73,0% KNN = 60,0% DT = 71,0%
REN <i>et al.</i> (2014)	EDA e diâmetro da pupila	31	6	-	KNN = 83,9% DT = 87,1%
ZHAI; BARRETO (2006)	EDA, pressão arterial e volume sanguíneo, diâmetro da pupila e temperatura	32	11	-	SVM = 90,1% DT = 88,0%
ZHANG <i>et al.</i> (2017)	ECG, EDA e EMG	12	18	-	SVM = 87,2%

Fonte: Elaborada pelo Autor (2019)

4 SISTEMA MULTIMODAL PARA DETECÇÃO AUTOMÁTICA DE ESTRESSE

“Quanto mais você suar nos treinos, menos irá sangrar na batalha.”

George S. Patton

Este capítulo tem como objetivo descrever o sistema multimodal de detecção automática de estresse desenvolvido. Na Seção 4.1, a arquitetura do sistema é detalhada. Na Seção 4.2, a base de dados utilizada para avaliar o sistema proposto é descrita. Na Seção 4.3, as configurações de treinamento e as medidas de desempenho que foram utilizadas na avaliação do sistema são detalhadas. Na Seção 4.4, os resultados são apresentados e discutidos.

4.1 MÉTODO PROPOSTO

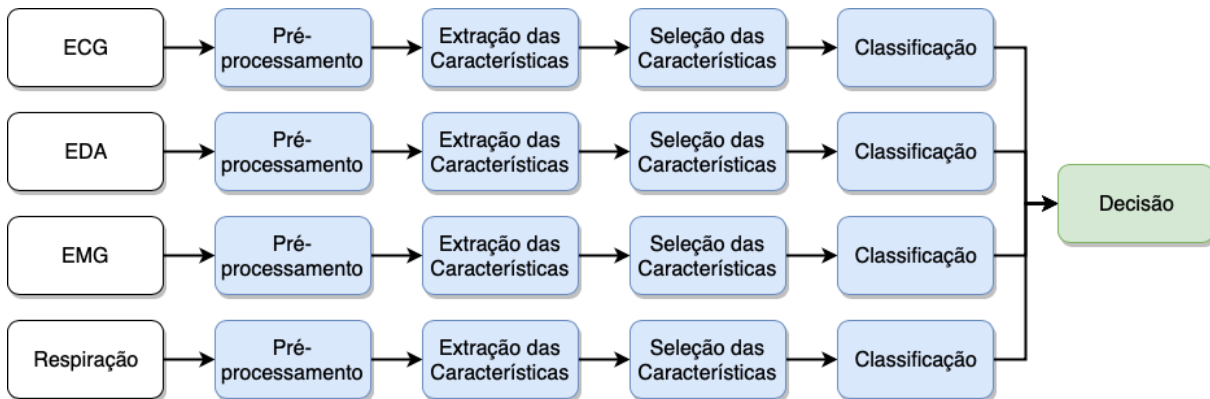
O modelo multimodal de detecção de estresse apresentado na Seção 3.4 depende da qualidade do resultado da extração e seleção de características. Um problema é que a alta dimensionalidade da concatenação das características demanda um custo computacional maior. Além disso, confiar em um único algoritmo de classificação nem sempre produz o melhor resultado. Por isso tudo, deve-se avaliar com cautela este modelo (SALAPPA; DOUMPOS; ZOPOUNIDIS, 2007).

O modelo proposto¹ visa realizar a seleção de características no domínio das características extraídas de um determinado sensor e classificar para utilizar em um sistema de votação (Figura 22). Assim, a dimensionalidade das características é consideravelmente reduzida. Além disso, a decisão é resultado pela combinação do resultado de diferentes classificadores (*weak classifiers*) (THEODORIDIS; KOUTROUMBAS, 2009) permitindo explorar a complementaridade das informações.

O método proposto pode ser dividido em 5 etapas: pré-processamento dos dados, extração das características, seleção das características, classificação e decisão (fusão dos classificadores).

¹ Disponível em: <<https://github.com/gustavodebiasi/stressDetectionWithWesad>>. Acesso em: 10 de novembro de 2019.

Figura 22: Arquitetura do sistema multimodal de detecção automática de estresse



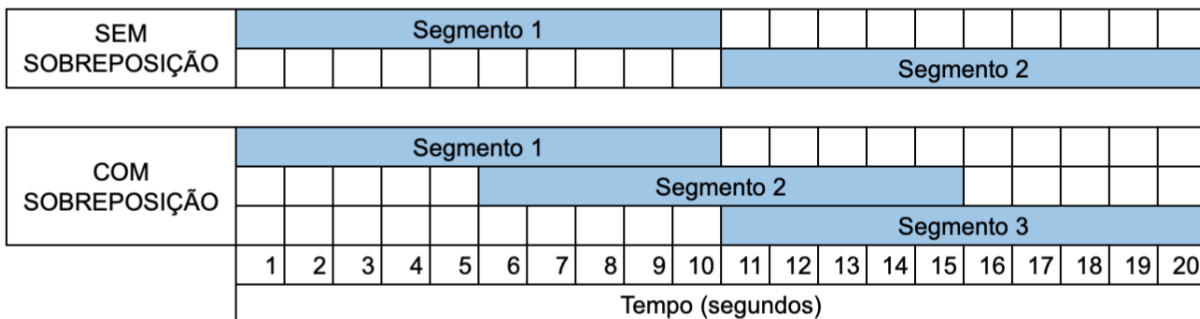
Fonte: Elaborado pelo autor (2019)

4.1.1 Pré-processamento

Primeiramente foram selecionados os dados referente ao eletrocardiograma, atividade eletrodérmica, eletromiografia e respiração. Para o processo de filtragem, foram selecionados os sinais que correspondiam aos rótulos dos estados normal e estressado. Dessa forma, o restante dos sinais foram ignorados por não se tratar destas duas classes.

Os sinais foram segmentados utilizando janelas móveis. Assim, os parâmetros são: o tamanho da janela e o seu deslocamento. Por exemplo, a Figura 23 apresenta duas configurações de janelas com tamanho de janela de 10 segundos, mas diferentes tempos para deslocamento. A primeira segmentação utilizou um deslocamento de 10 segundos e a segunda um deslocamento de 5 segundos, gerando sobreposição de janelas.

Figura 23: Segmentação dos dados



Fonte: Elaborado pelo autor (2019)

Por mais que o tempo de segmentação é definido, foi necessário determinar o que seria feito quando uma mesma janela de tempo possuir os dois estados do paciente (estressado e normal). Neste caso, as segmentações são removidas pois a janela não permaneceria com o


tamanho definido. Essa mesma abordagem foi realizada quando a segmentação chega ao final da base de dados e não foi possível obter dados suficientes para preencher a janela definida.

4.1.2 Extração das características

Para cada sinal são extraídas as seguintes características básicas: média aritmética, mínima, máxima, intervalo (diferença entre o máximo e o mínimo), mediana, variância, desvio padrão, curtose e simetria. Além destas, com o auxílio do módulo *Python Neurokit*² para cada sinal foram extraídas características específicas:

- Eletrocardiograma: características relacionadas à variabilidade da frequência cardíaca (HRV) foram extraídas. Sendo o intervalo RR a diferença de tempo entre os picos dos batimentos cardíacos (Figura 24), as seguintes características foram extraídas (VOSS *et al.*, 2015; SMITH; OWEN; REYNOLDS, 2013; MALIK, 1996):

Figura 24: Representação do intervalo RR



Fonte: Adaptado de WANG; LIN; WANG (2019)

- Desvio padrão do intervalo RR (sdNN);
- Média do intervalo RR (MeanNN);
- Raiz quadrada da média do quadrado das diferenças entre intervalos RR (RMSSD);
- Coeficiente da variação das diferenças sucessivas, calculado através da razão do RMSSD pelo MeanNN;
- Coeficiente da variação, calculado através da razão do sdNN pelo MeanNN;

² Disponível em: <<https://neurokit.readthedocs.io/en/latest/>>. Acesso em: 9 de Novembro de 2019.

- Mediana dos valores absolutos das diferenças sucessivas do intervalo RR (medianNN);
 - Desvio absoluto mediano do intervalo RR (madNN);
 - Coeficiência de variação baseado na mediana, calculado através da razão do madNN pelo medianNN;
 - Proporção derivada da divisão do número NN50 (quantidade de diferenças sucessivas do intervalo RR maiores que 50 ms) pela quantidade total de intervalos RR;
 - Proporção derivada da divisão do número NN20 (quantidade de diferenças sucessivas do intervalo RR maiores que 20 ms) pela quantidade total de intervalos RR;
 - Número de todos os valores dos intervalos RR dividido pelo distribuição da densidade (valores distribuídos a cada 8 ms);
 - Variação no HRV referente à baixa frequência (0.04 até 0.15 Hz) (LF);
 - Variação no HRV referente à alta frequência (0.15 até 0.40 Hz) (HF);
 - Variação no HRV referente à altíssima frequência (0.40 até 0.50 Hz);
 - Força total da densidade espectral (Total_Power);
 - Razão do LF pelo HF;
 - LF normalizado, calculado através da fórmula: $LFn = LF / (LF + HF)$;
 - HF normalizado, calculado através da fórmula: $HF_n = HF / (LF + HF)$;
 - Razão do LF pelo Total_Power;
 - Razão do HF pelo Total_Power.
- Respiração: características da variabilidade da respiração (NABIAN *et al.*, 2018):
 - Desvio padrão da largura do ciclo da respiração;
 - Raiz quadrada da média da largura dos ciclos da respiração elevado ao quadrado (RMSSD);
 - Logaritmo do resultado do RMSSD.
 - Atividade Eletrodermal: para o sinal do EDA foram extraídas as seguintes características extras (NABIAN *et al.*, 2018):
 - Média da amplitude das respostas da pele;
 - Número de picos do sinal analisado dividido pelo número total de sinais do segmento.
 - Eletromiograma: para o sinal do EMG foram exportadas as seguintes características extras (MELLO; SCHMIELE; SOARES, 2018):

- Raiz quadrada da média dos sinais do EMG elevado ao quadrado (RMS);
- Logaritmo do resultado de RMS;
- Média dos valores absolutos;
- Quantidade de sinais que mudam a direção do sinal;
- Quantidade de sinais que cruzam o eixo zero.

4.1.3 Seleção das características

Com o auxílio do pacote *Scikit-learn*³, 2 técnicas de seleção de características foram utilizadas para reduzir a quantidade de características: análise de componentes principais e análise de discriminantes lineares. A redução foi realizada mantendo-se as dimensões dos dados projetados que explicassem até 95% das informações explicadas dos dados originais, conforme utilizado nos sistemas de detecção de padrões (JACKSON, 1993).

4.1.4 Classificação

Nesta etapa, com o auxílio do pacote *Scikit-learn* foram utilizados e avaliados 3 classificadores normalmente utilizados na tarefa. Cada parâmetro utilizado nos classificadores foi selecionado com base em diversos testes, sendo que, os selecionados apresentaram melhores resultados:

- Para o classificador *Random Forest*, foram determinados os seguintes parâmetros:
 1. O número de árvores da floresta foi limitada para a utilização de até 100 árvores;
 2. Critério para definir a divisão de um nodo;
 3. A profundidade máxima da árvore utilizada foi de 5;
 4. Quantidade mínima de amostras para realizar a divisão do nodo foi definida como 2;
 5. Quantidade mínima para nodos folha foi determinado como 1;
 6. Número máximo de características para criação da floresta foi definida como \sqrt{n} , sendo n o número de características de entrada;
 7. Não foi definido número máximo de nodos para criação da árvore;
- Para as Máquinas de Vetores de Suporte os seguintes parâmetros foram selecionados:
 1. RBF *Kernel*;
 2. Sendo n o número de características e X a variância, δ foi definido como $1/(n * X)$;
 3. Penalidade de erro igual a 4;

³ Disponível em: <<https://scikit-learn.org/stable/>>. Acesso em: 10 de novembro de 2019.

- Para os K-vizinhos mais próximos, os seguintes parâmetros foram selecionados:

1. 11 vizinhos avaliados;
2. Para medir a distância entre os vizinhos foi utilizada a distância euclidiana.

4.1.5 Decisão

Para a etapa de decisão, foi realizada uma combinação dos resultados obtidos de cada classificador com objetivo de utilizar a complementaridade dos classificadores. A decisão foi realizada através da técnica de votação da maioria (*majority voting*) (THEODORIDIS; KOUTROUMBAS, 2009).

4.2 BASE DE DADOS

O sistema desenvolvido utilizou a base de dados *Wearable Stress and Affect Detection (WESAD)* (UC Irvine Machine Learning Respository, 2018). Nesta base constam dados multimodais de 15 indivíduos que foram coletados de diversos sensores captados por dois dispositivos, além de resultados de quatro questionários respondidos por cada um.

Para a coleta dos dados dos indivíduos foi necessário realizar uma série de experimentos onde os mesmos sempre estavam sendo monitorados por sensores, a fim de captar as alterações fisiológicas durante todo o período. Além disso, foram utilizados questionários que o próprio indivíduo respondia com o objetivo de validar as informações captadas. Estes questionários serviam para gerar os rótulos de determinação do estado do indivíduo para os sinais fisiológicos na base de dados.

4.2.1 Experimentos

Cada indivíduo passou por uma preparação e foi submetido a cinco experiências com duração total de 2 horas:

1. Preparação: foi solicitado aos indivíduos que não consumissem caféina ou tabaco uma hora antes do experimento começar e, que não realizassem exercícios físicos rigorosos durante o dia. No período de preparação os dois dispositivos (Empatica E4 e RespiBAN Professional) e seus sensores foram colocados em locais pré-determinados no corpo do indivíduo e todos eles foram ligados.
2. Estado Inicial: é realizada uma leitura inicial dos sensores durante 20 minutos a fim de coletar dados do estado neutro do indivíduo. Neste estado, ele podia ficar sentado, em pé e ler revistas de conteúdo neutro;

3. Diversão: nesta experiência, o indivíduo foi exposto a 11 vídeos de humor. A cada vídeo existia uma pausa de 5 segundos, e a experiência durou 392 segundos para cada indivíduo;
4. Estresse: neste experimento foi utilizado o teste de estresse social (*Trier Social Stress Test - TSST*) (KIRSCHBAUM; PIRKE; HELLHAMMER, 1993). Este teste baseia-se em um discurso e realização de operações matemáticas em frente a um público. Nesta base de dados, o indivíduo precisava realizar um discurso de 5 minutos focando em seus defeitos e qualidades. Ainda, para aumentar a pressão, o discurso era realizado perante três especialistas de recursos humanos, e era dito a ele para tentar deixar a melhor impressão para uma possível promoção de trabalho. Após este primeiro teste, ele era encaminhado para o teste de Matemática, onde ele precisava contar do 2023 até o zero subtraindo 17 unidades por vez. Cada vez que o indivíduo errava, ele precisava reiniciar a contagem. Ambos os testes, no total, levavam no máximo 10 minutos, e após cada participante recebia 10 minutos de descanso;
5. Meditações 1 e 2: com o objetivo de distrair o indivíduo e neutralizar a excitação das experiências anteriores, o indivíduo era submetido a sessões de meditação guiada após os estados de diversão e estresse. Com olhos fechados e posicionado confortavelmente, ele era instruído via áudio para a realização de exercícios de controle da respiração. Cada sessão de meditação levava 7 minutos.

Todos os indivíduos foram divididos em dois grupos, onde o primeiro realizava as experiências na seguinte ordem: estado inicial, diversão, meditação, estresse, descanso e meditação. Para o outro grupo, a ordem das experiências foi alterado para evitar problemas de sequencialidade dos dados: estado inicial, estresse, descanso e meditação, diversão e meditação novamente. Além disso, no intervalo entre uma experiência e outra, o indivíduo precisou responder quatro questionários (Figura 25).

Figura 25: Ordem dos Experimentos



Fonte: Adaptado de SCHMIDT *et al.* (2018).

4.2.2 Coleta de dados e avaliação dos sensores


Dois dispositivos foram utilizados para coletar dados do sujeito. O Empatica E4 Wristband (Figura 26) é uma pulseira que permite coletar EDA e temperatura (com taxa de amostragem de 4 Hz), acelerometria (taxa de amostragem de 32 Hz), volume sanguíneo (BVP) (taxa de amostragem de 64 Hz) e intervalo entre batimentos (*Inter-beat interval* - IBI) que foi extraído do BVP (EMPATICA, 2019). O RespiBAN Professional (Figura 27) é uma cinta peitoral e permite coletar dados relacionados com a respiração (SCHMIDT *et al.*, 2018). Além disso, o RespiBAN foi complementado com alguns sensores, fazendo com que, além de realizar medições relacionadas com a respiração, o RespiBAN foi utilizado para coletar ECG, EDA, EMG, temperatura e acelerometria (todos com taxa de amostragem de 700 Hz).

Figura 26: Empatica E4 Wristband



Fonte: EMPATICA (2019)

Figura 27: RespiBAN Professional



Fonte: SCHMIDT *et al.* (2018)

O sinal obtido do RespiBAN deve ser processado a fim de obter as medidas nas unidades desejadas (SCHMIDT *et al.*, 2018). Sendo s o sinal coletado, n o número de bits do canal (padrão 16, podendo ser 12 ou 8 bits), v a voltagem de operação do sensor (3V), C_{min} o valor de calibração mínima e C_{max} o valor de calibração máxima, a fórmula de conversão de unidade para cada sensor é definida:

- O **ECG**, em mV, é calculado através de (BIOSIGNALPLUX, 2018b):

$$ECG = \left(\frac{s}{2^n} - \frac{1}{2}\right) \times v; \quad (4.1)$$

- O **EDA**, em μS , é calculado através de (BIOSIGNALPLUX, 2018c):

$$EDA = \frac{\frac{s}{2^n} \cdot v}{0.12}; \quad (4.2)$$

- O **EMG**, em mV, é calculado através de (BIOSIGNALPLUX, 2018d):

$$EMG = \left(\frac{s}{2^n} - \frac{1}{2}\right) \times v; \quad (4.3)$$

- A **temperatura**, em °C, é calculada através das equações (BIOSIGNALPLUX, 2018f):

$$T = \frac{1}{a_0 + a_1 \times \log(NTC) + a_2 \times [\log(NTC)]^3} - 273,15, \quad (4.4)$$

onde $a_0 = 1,12764514 \times 10^{-3}$, $a_1 = 2,34282709 \times 10^{-4}$, $a_2 = 8,77303013 \times 10^{-8}$,

$$NTC = \frac{s \times v}{2^n}, \quad (4.5)$$

$$NTC = \frac{1 \times 10^4 \times NTC}{v - NTC}; \quad (4.6)$$

- O **aceleração**, em unidade g, é calculada através de (BIOSIGNALPLUX, 2018a):

$$A = \frac{s - C_{min}}{C_{max} - C_{min}} \times 2 - 1; \quad (4.7)$$

- A **respiração**, em %, é calculada através de (BIOSIGNALPLUX, 2018e):

$$R = \left(\frac{s}{2^n} - \frac{1}{2}\right) \times 100. \quad (4.8)$$

4.2.3 Avaliação via questionários

A cada pausa de experimento, os indivíduos precisavam responder 4 questionários a fim de identificar o nível de estresse em cada experimento (SCHMIDT *et al.*, 2018). Estes questionários foram utilizados para a geração e validação da base de dados WESAD. Os 4 questionários são:

- Escala de Afeto Positivo e Negativo (*Positive and Negative Affect Schedule - PANAS*): consiste em 20 sentimentos divididos em 10 positivos e 10 negativos, onde o indivíduo deve responder em uma escala de 0 a 5, sendo 0 "não sente nada" e 5 "sente muito" (Anexo A);
- Inventário de Ansiedade Traço-Estado (*State-Trait Anxiety Inventory - STAI*): consiste em 6 perguntas de como o indivíduo está se sentindo. Este questionário possui uma escala de 1 a 4, sendo 1 "não estou me sentindo assim" e 4 "estou me sentindo muito assim" (Anexo B);
- Manequins de Autoavaliação (*Self-Assessment Manikins*): consiste em 2 sentimentos que o indivíduo deve responder em uma escala de 1 a 9, sendo 1 "pouco" e 9 "muito" (Anexo C);
- Questionário Curto de Estado de Estresse (*Short Stress State Questionnaire*): consiste em 6 perguntas de como o indivíduo estava se sentindo. Ele deve responder em uma escala de 1 a 5, sendo 1 "não sente nada" e 5 "sente muito" (Anexo D).

4.3 CONFIGURAÇÃO DOS EXPERIMENTOS

Utilizando a base de dados WESAD, são disponibilizados 15 indivíduos que foram submetidos à 10 minutos de experiência estressante e 20 minutos de estado normal. Através destes, foram realizados diversos experimentos para que os resultados pudessem ser avaliados. Além disso, para que o sistema consiga realizar o processo de detecção automática, é necessário que ele seja treinado e avaliado adequadamente.

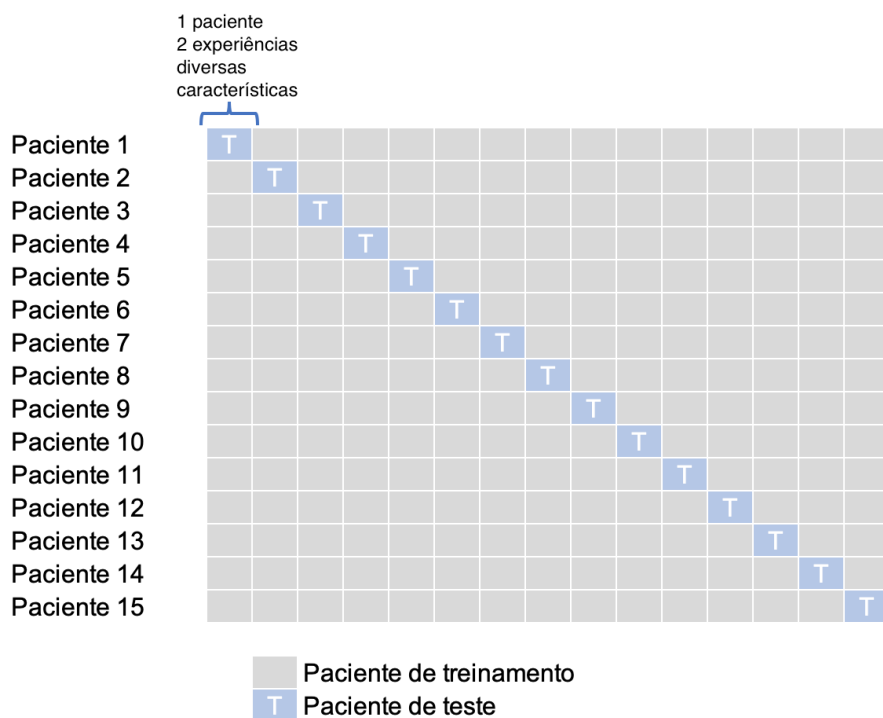
4.3.1 Treinamento dos Classificadores

Devido à pouca quantidade de pacientes, o treinamento do sistema foi realizado com o método *Leave-One-Subject-Out* (DAS *et al.*, 2018). Para este processo, são realizadas 15 execuções onde, em cada uma delas, são selecionados 14 pacientes para o treinamento e 1 para o teste (Figura 28). O objetivo do sistema é identificar neste paciente de teste o momento que ele estava estressado.

4.3.2 Avaliação de Desempenho

Para que fosse possível definir os parâmetros que seriam utilizados na arquitetura do sistema, diversos cenários e testes fossem realizados. Todos os resultados detalhados a seguir foram obtidos através da média de 100 execuções. Além disso, para avaliar o desempenho foram utilizadas as métricas de acurácia, sensibilidade e especificidade, extraídas da matriz de confusão, onde VP é o estado normal e VN o estado estressante.

Figura 28: Método de treinamento *Leave-One-Subject-Out*



Fonte: Elaborado pelo autor (2019)

4.4 RESULTADOS E DISCUSSÕES

Esta seção trata dos resultados obtidos pelo método proposto. Foram analisados os principais parâmetros dos métodos.

4.4.1 Redução de dimensionalidade

Um dos primeiros experimentos foi verificar se a redução de dimensionalidade melhoraria o desempenho do sistema. Assim, o tamanho da janela foi definido arbitrariamente com 30 segundos (similarmente a diversos trabalhos) com deslocamento de 30 segundos (ou seja, as janelas de análise não são sobrepostas). Utilizando estes parâmetros de segmentação, cada paciente produziu os números de segmentos descritos na Tabela 5 para as classes normal (580 segmentos) e estressante (327 segmentos).

A Tabela 6 mostra o desempenho do método proposto para cada classificador e a dimensionalidade de cada conjunto de características. Pode-se analisar que o SVM não teve boa performance na especificidade do ECG e do EMG. Este problema pode ser causado pela dificuldade de separação através de um hiperplano as diversas dimensões (características) que estes sinais possuem. Além disso, pode-se avaliar que, de forma individualizada, a Respiração obteve as melhores resultados em comparação com os demais sinais. Na maior parte dos resultados,

Tabela 5: Quantidade de segmentos extraídos por paciente

Paciente	Classe Normal	Classe Estressante
1	38	20
2	37	22
3	38	21
4	39	21
5	39	21
6	39	21
7	38	22
8	39	21
9	39	24
10	39	22
11	39	22
12	39	22
13	39	22
14	39	22
15	39	24
Total	580	327

Fonte: Elaborada pelo Autor (2019)

pode-se analisar que o KNN possui o pior desempenho dentre os 3 classificadores.

Tabela 6: Desempenho da detecção para diferentes classificadores e características

Sinal	Características	RF	SVM	KNN
ECG	29	Acc = 78,4% Sens = 78,6% Espec = 75,2%	Acc = 65,1% Sens = 65,1% Espec = 5,5%	Acc = 69,3% Sens = 72,5% Espec = 56,1%
EDA	11	Acc = 75,3% Sens = 82,1% Espec = 76,7%	Acc = 68,8% Sens = 72,0% Espec = 68,2%	Acc = 67,2% Sens = 72,1% Espec = 62,2%
EMG	14	Acc = 67,3% Sens = 70,8% Espec = 44,5%	Acc = 64,0% Sens = 64,0% Espec = 0,0%	Acc = 57,3% Sens = 65,6% Espec = 38,3%
Respiração	12	Acc = 84,4% Sens = 86,8% Espec = 85,4%	Acc = 79,1% Sens = 82,3% Espec = 82,4%	Acc = 78,3% Sens = 82,5% Espec = 78,6%

Fonte: Elaborada pelo Autor (2019)

Com o objetivo de reduzir a complexidade do processo de classificação, novos testes realizando a redução de dimensionalidade foram feitos (as análises de percentual explicado estão no Apêndice A). Melhores resultados foram atingidos ao utilizar o LDA para a projeção das características. A Tabela 7 mostra o desempenho do sistema proposto para as duas técnicas de redução de dimensionalidade. Pode-se analisar que o problema de classificação gerado na especificidade do ECG, foi minimizado de forma que foram obtidos melhores resultados em comparação ao primeiro experimento.

Considerando a arquitetura do sistema de detecção que utilizará a fusão dos classifica-

Tabela 7: Resultado da detecção utilizando PCA e LDA

Sinal	Técnica	Características	RF	SVM	KNN
ECG	PCA	13	Acc = 67,6% Sens = 71,1% Espec = 58,6%	Acc = 69,8% Sens = 66,4% Espec = 58,9%	Acc = 66,3% Sens = 70,0% Espec = 51,8%
	LDA	1	Acc = 79,4% Sens = 83,1% Espec = 82,7%	Acc = 81,4% Sens = 83,7% Espec = 86,6%	Acc = 78,1% Sens = 83,2% Espec = 78,6%
EDA	PCA	6	Acc = 72,3% Sens = 75,6% Espec = 65,2%	Acc = 72,6% Sens = 80,7% Espec = 68,0%	Acc = 69,4% Sens = 83,8% Espec = 62,5%
	LDA	1	Acc = 79,6% Sens = 83,4% Espec = 72,4%	Acc = 79,4% Sens = 81,1% Espec = 77,0%	Acc = 74,1% Sens = 80,2% Espec = 62,4%
EMG	PCA	5	Acc = 63,0% Sens = 67,9% Espec = 46,5%	Acc = 65,0% Sens = 72,0% Espec = 45,1%	Acc = 60,0% Sens = 66,6% Espec = 50,1%
	LDA	1	Acc = 68,8% Sens = 70,7% Espec = 61,5%	Acc = 69,6% Sens = 69,9% Espec = 44,6%	Acc = 64,5% Sens = 72,7% Espec = 48,9%
Respiração	PCA	6	Acc = 79,5% Sens = 84,9% Espec = 78,1%	Acc = 83,0% Sens = 86,8% Espec = 79,9%	Acc = 83,4% Sens = 86,3% Espec = 83,2%
	LDA	1	Acc = 81,2% Sens = 87,4% Espec = 78,5%	Acc = 81,9% Sens = 87,1% Espec = 81,0%	Acc = 79,3% Sens = 84,2% Espec = 75,7%

Fonte: Elaborada pelo Autor (2019)


dores e o resultado será definido pela votação da maioria, é necessário que sejam selecionados um número ímpar de sinais. Dessa forma, é possível utilizar o resultado da maioria simples e que não ocasione em "empates". Nesta etapa, os sinais foram avaliados e os 3 melhores resultados utilizando LDA foram selecionados: EDA, Respiração e ECG. O EMG foi eliminado dos próximos testes visto que não conseguiu obter resultados maiores que 70%, e os demais sinais conseguiram.

4.4.2 Definição da janela de tempo

Com o objetivo de estimar o tamanho da janela e o deslocamento na segmentação mais apropriados para a tarefa, foram realizados diversos experimentos variando tais parâmetros. Dessa forma, testes foram realizados com segmentação de 30 e 60 segundos, utilizando o sinal do ECG reduzido com o LDA e com o classificador SVM (Figura 29). Neste teste, pode-se verificar que a utilização de 60 segundos obteve o pior resultado de especificidade em relação ao de 30 segundos. Portanto, a opção de 30 segundos foi selecionada, por ser uma das segmentações utilizadas com frequência (GJORESKI *et al.*, 2017; ROJAS; HONG; DEY, 2014; KREIBIG, 2010) e por gerar menos amostras.

Em um segundo momento, testes perante o deslocamento dos dados (utilizando 10 e 30

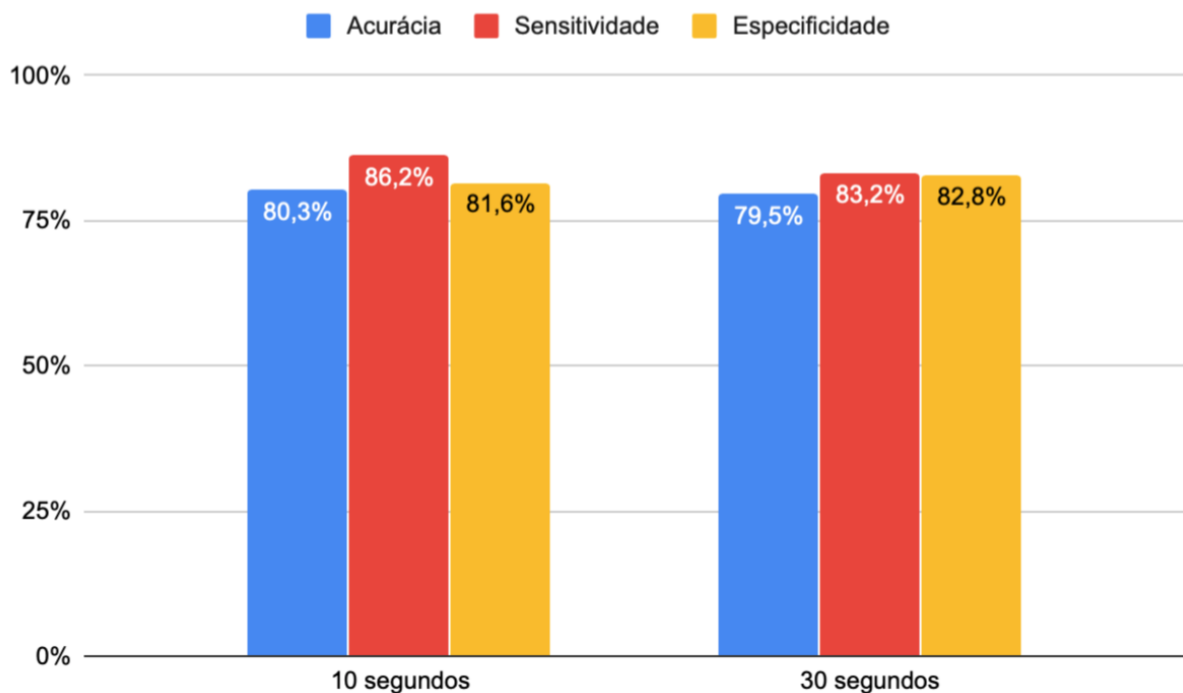
Figura 29: Comparação de janelas de tempo do ECG



Fonte: Elaborado pelo autor (2019)

segundos) foram realizados utilizando os sinais do ECG com redução pelo LDA e classificação com o SVM (Figura 30). Pode-se avaliar que o deslocamento de 10 e 30 segundos geraram resultados semelhantes. Dessa forma, será utilizado o deslocamento de 30 segundos devido ao menor número de amostras (Tabela 8).

Figura 30: Comparação de deslocamento da janela de tempo



Fonte: Elaborado pelo autor (2019)

Tabela 8: Quantidade de amostras por deslocamento

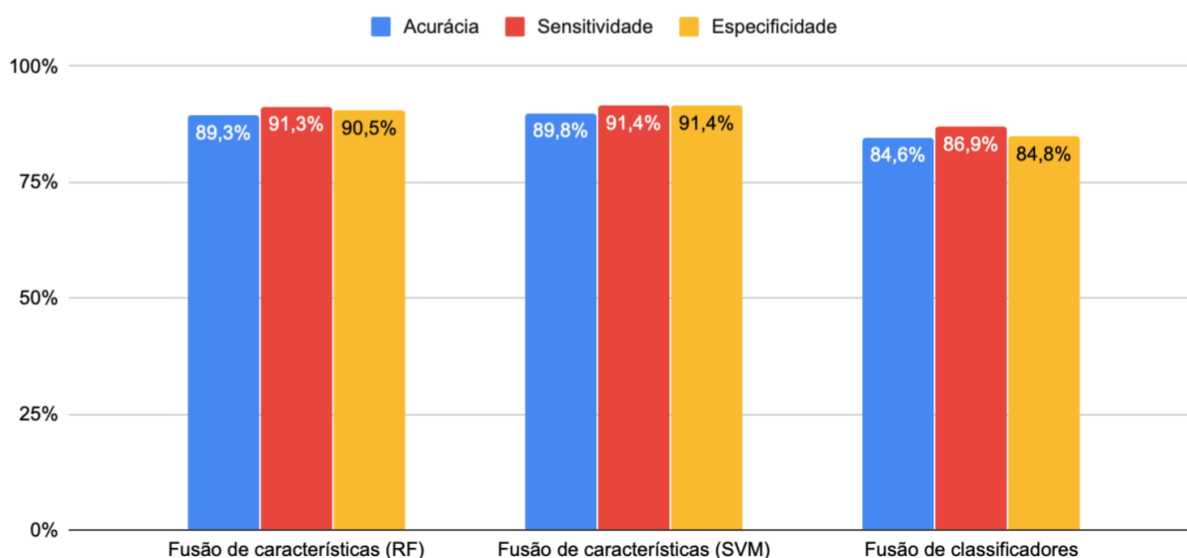
Deslocamento	Classe Normal	Classe Estressante
10	865	484
30	580	327

Fonte: Elaborada pelo Autor (2019)

4.4.3 Comparação de resultados entre a fusão de classificadores e a fusão de características

Na comparação dos sistemas de detecção de estresse multimodal existentes, foram obtidos resultados utilizando a fusão de características (como a maioria dos sistemas fazem) e a fusão dos resultados de classificadores (proposta deste trabalho). Para a fusão de características os resultados foram avaliados utilizando SVM e RF. Para a fusão de classificadores foi selecionado o melhor classificador de cada sinal individualmente e realizado o voto da maioria ao final (Figura 31). Os classificadores utilizados para os sinais de ECG e Respiração foi o SVM e para o EDA foi o RF.

Figura 31: Comparação de fusão de classificadores e fusão de características



Fonte: Elaborado pelo autor (2019)

Utilizando a arquitetura do sistema proposto, foi possível obter resultado de 84,6% de acurácia. O desempenho da fusão de características se mostrou superior perante a fusão dos classificadores, tanto com o SVM quanto com o RF. Pode-se concluir que a complementariedade dos classificadores não gerou melhores resultados.

5 CONSIDERAÇÕES FINAIS

O estresse é um dos causadores de doenças psicológicas e físicas que impacta diariamente na saúde dos seres humanos. Devido a isso, gastos milionários são realizados para o tratamento de doenças e complicações ocasionadas por ele. Entretanto, a identificação de estados de estresse dos seres humanos é algo específico, e hoje é necessário realizar avaliações com especialistas para que esse causador possa ser identificado e tratado adequadamente. Entretanto, essas avaliações são subjetivas e complexas pois dependem não só do sincero repasse das informações pelo paciente, como também da capacidade que o especialista possui para ter a correta condução e verificação das evidências que o paciente traz.

Nos últimos anos, pesquisadores propuseram diversas formas de detectar o estresse de forma automática através de um sistema, sem que sejam realizados exames invasivos ou avaliações psicológicas subjetivas. Estes sistemas buscam identificar os momentos em que o paciente está estressado por meio do monitoramento em tempo real das alterações fisiológicas causadas pelo estresse. Este aumento nas pesquisas e propostas relacionadas ao assunto demonstra uma preocupação cada vez maior com a saúde psicológica e o bem-estar da humanidade.

Neste trabalho, um sistema de detecção automática de estresse com as 5 etapas de um sistema tradicional foi criado¹. Inicialmente diversas características foram extraídas (tais como: média, mediana, curtose e simetria) e para analisar o desempenho do sistema, foi utilizada a base de dados WESAD e vários experimentos foram realizados e avaliados. Para o primeiro teste realizado não foram utilizadas técnicas de redução de dimensionalidade, resultando na acurácia de 65% na utilização do classificador SVM para o sinal do ECG. Para avaliar se a redução de dimensionalidade traria melhores resultados, as técnicas de PCA e LDA foram utilizadas. Neste segundo teste, foi possível obter melhores resultados com acurácia de 69,8% (PCA) e 81,4% (LDA) para o mesmo classificador e sinal.

Outro cenário de experimento, buscava avaliar se a o tamanho da janela de segmentação ou deslocamento resultariam em melhores resultados na classificação. Neste cenário, não foi possível adquirir resultados melhores e, assim, a janela de segmentação e o deslocamento foram escolhidos conforme utilizado na tarefa de detecção de estresse da literatura.

Por último, buscando comparar o sistema proposto com os sistemas tradicionais, foram realizados testes com a fusão de características (acurácia de 89,3% - SVM e 89,8% - RF) e a fusão de classificadores (acurácia de 84,6%). Neste cenário, também não foi possível obter melhores resultados com a arquitetura do sistema proposto no trabalho.

¹ O código fonte do sistema está disponível em plataforma online (Github) e pode ser acessado por meio do link <<https://github.com/gustavodebiasi/stressDetectionWithWesad>>.

REFERÊNCIAS

AIGRAIN, J. *et al.* Multimodal stress detection from multiple assessments. **IEEE Transactions on Affective Computing**, v. 9, n. 4, p. 491–506, 2018. ISSN 1949-3045.

AKMANDOR, A. O.; JHA, N. K. Keep the stress away with soda: Stress detection and alleviation system. **IEEE Transactions on Multi-Scale Computing Systems**, v. 3, n. 4, p. 269–282, out. 2017. ISSN 2332-7766.

ALBERDI, A.; AZTIRIA, A.; BASARAB, A. Towards an automatic early stress recognition system for office environments based on multimodal measurements: A review. **Journal of Biomedical Informatics**, v. 59, p. 49–75, 2016. ISSN 1532-0464. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1532046415002750>>.

BAKKER, J.; PECHENIZKIY, M.; SIDOROVA, N. What's your current stress level? detection of stress patterns from gsr sensor data. In: **2011 IEEE 11th International Conference on Data Mining Workshops**. [S.l.: s.n.], 2011. p. 573–580. ISSN 2375-9232.

BANSAL, D.; KHAN, M.; SALHAN, A. K. A review of measurement and analysis of heart rate variability. In: **2009 International Conference on Computer and Automation Engineering**. [S.l.: s.n.], 2009. p. 243–246.

BANSAL RITU SHARMA, P. G. M. Performance evaluation of butterworth filter for signal denoising. In: . [S.l.: s.n.], 2010. p. 59–62. ISSN 2230-710.

BIOSIGNALPLUX. **Accelerometer (ACC) Sensor Data Sheet**. 2018. Disponível em: <https://www.biosignalsplux.com/datasheets/ACC_Sensor_Datasheet.pdf>. Acesso em: 12 de Junho de 2019.

_____. **Electrocardiography (ECG) Sensor Data Sheet**. 2018. Disponível em: <https://www.biosignalsplux.com/datasheets/ECG_Sensor_Datasheet.pdf>. Acesso em: 12 de Junho de 2019.

_____. **Electrodermal Activity (EDA) Sensor Data Sheet**. 2018. Disponível em: <https://www.biosignalsplux.com/datasheets/EDA_Sensor_Datasheet.pdf>. Acesso em: 12 de Junho de 2019.

_____. **Electromyography (EMG) Sensor Data Sheet**. 2018. Disponível em: <https://www.biosignalsplux.com/datasheets/EMG_Sensor_Datasheet.pdf>. Acesso em: 12 de Junho de 2019.

_____. **Piezoelectric Respiration (PZT) Sensor Data Sheet**. 2018. Disponível em: <https://www.biosignalsplux.com/datasheets/PZT_Sensor_Datasheet.pdf>. Acesso em: 12 de Junho de 2019.

_____. **Temperature (NTC) Sensor Data Sheet**. 2018. Disponível em: <https://www.biosignalsplux.com/datasheets/TMP_Sensor_Datasheet.pdf>. Acesso em: 12 de Junho de 2019.

BUGDOL, M. D.; MITAS, A. W. Multimodal biometric system combining ecg and sound signals. **Pattern Recognition Letters**, v. 38, p. 107–112, 2014. ISSN 0167-8655. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0167865513004583>>.

CAN, Y. S.; ARNRICH, B.; ERSOY, C. Stress detection in daily life scenarios using smart phones and wearable sensors: A survey. **Journal of Biomedical Informatics**, v. 92, p. 103–139, 2019. ISSN 1532-0464. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1532046419300577>>.

CARNEIRO, D. *et al.* New methods for stress assessment and monitoring at the workplace. **IEEE Transactions on Affective Computing**, p. 1–1, 2018. ISSN 1949-3045.

DAS, D. *et al.* Eliminating individual bias to improve stress detection from multimodal physiological data. In: **2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)**. [S.l.: s.n.], 2018. p. 5753–5758. ISSN 1558-4615.

DOOREN, M. van; VRIES, J. G.-J. de; JANSSEN, J. H. Emotional sweating across the body: Comparing 16 different skin conductance measurement locations. **Physiology & Behavior**, v. 106, n. 2, p. 298–304, 2012. ISSN 0031-9384.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern Classification (2Nd Edition)**. 2. ed. New York, NY, USA: Wiley-Interscience, 2000. 738 p. ISBN 0471056693.

ELLIS, G. Chapter 9 - filters in control systems. In: **Control System Design Guide (Fourth Edition)**. Fourth edition. Boston: Butterworth-Heinemann, 2012. p. 165–183. ISBN 978-0-12-385920-4. Disponível em: <<http://www.sciencedirect.com/science/article/pii/B9780123859204000096>>.

ELZEINY, S.; QARAGE, M. Machine learning approaches to automatic stress detection: A review. In: **2018 IEEE/ACS 15th International Conference on Computer Systems and Applications (AICCSA)**. [S.l.: s.n.], 2008. p. 1–6. ISSN 2161-5330.

EMPATICA. **Differences between Embrace and E4**. 2019. Disponível em: <<https://empatica.app.box.com/v/E4-User-Manual>>. Acesso em: 13 de abril de 2019.

European Agency for Safety and Health at Work. **Calculating the cost of work related-stress and psychosocial risks**. 2014. Disponível em: <https://osha.europa.eu/en/tools-and-publications/publications/literature_reviews/calculating-the-cost-of-work-related-stress-and-psychosocial-risks>. Acesso em: 8 de Março de 2019.

EZZATI, A. *et al.* Validation of the perceived stress scale in a community sample of older adults. **International Journal of Geriatric Psychiatry**, Wiley Online Library, v. 29, n. 6, p. 645–652, 2014. ISSN 1099-1166.

FERNANDES, A. *et al.* Determination of stress using blood pressure and galvanic skin response. In: **2014 International Conference on Communication and Network Technologies**. [S.l.: s.n.], 2014. p. 165–168.

GHAMARI, M. *et al.* Design and prototyping of a wristband-type wireless photoplethysmographic device for heart rate variability signal analysis. In: **2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)**. [S.l.: s.n.], 2016. p. 4967–4970. ISSN 1558-4615.

GIAKOUMIS, D.; TZOVARAS, D.; HASSAPIS, G. Subject-dependent biosignal features for increased accuracy in psychological stress detection. **International Journal of Human-Computer Studies**, v. 71, n. 4, p. 425–439, 2013. ISSN 1071-5819. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1071581912001760>>.

- GJORESKI, M. *et al.* Monitoring stress with a wrist device using context. **Journal of Biomedical Informatics**, v. 73, p. 159–170, 2017. ISSN 1532-0464. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1532046417301855>>.
- GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing (3rd Edition)**. 3. ed. [S.l.]: Pearson Prentice Hall, 2006. ISBN 978-8576054016.
- GREENE, S.; THAPLIYAL, H.; CABAN-HOLT, A. A survey of affective computing for stress detection: Evaluating technologies in stress detection for better health. **IEEE Consumer Electronics Magazine**, v. 5, n. 4, p. 44–56, Oct 2016. ISSN 2162-2248.
- HEALEY, J. A.; PICARD, R. W. Detecting stress during real-world driving tasks using physiological sensors. **IEEE Transactions on Intelligent Transportation Systems**, v. 6, n. 2, p. 156–166, 2005. ISSN 1524-9050.
- HONGYU, K.; SANDANIELO, V. L. M.; JUNIOR, G. J. de O. Análise de componentes principais: teórico, aplicação e interpretação. v. 5, p. 83–90, 2016.
- HOSSIN, M.; M.N, S. A review on evaluation metrics for data classification evaluations. **International Journal of Data Mining & Knowledge Management Process**, v. 5, p. 01–11, 2015.
- HOU, X. *et al.* Eeg based stress monitoring. In: **2015 IEEE International Conference on Systems, Man, and Cybernetics**. [S.l.: s.n.], 2015. p. 3110–3115.
- JACKSON, D. A. Stopping rules in principal components analysis: A comparison of heuristical and statistical approaches. **Ecology**, Ecological Society of America, v. 74, n. 8, p. 2204–2214, 1993. ISSN 00129658, 19399170. Disponível em: <<http://www.jstor.org/stable/1939574>>.
- JAIN, A. K.; DUIN, R. P. W.; MAO, J. Statistical pattern recognition: a review. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 22, n. 1, p. 4–37, Jan 2000. ISSN 0162-8828.
- JUNIOR, E. G. *et al.* Trabalho e estresse: Identificação do estresse e dos estressores ocupacionais em trabalhadores de uma unidade administrativa de uma instituição pública de ensino superior (ies). **Revista Gestão Universitária na América Latina - GUAL**, Redalyc, p. 1–17, 2014. ISSN 1983-4535.
- KHALID, S.; KHALIL, T.; NASREEN, S. A survey of feature selection and feature extraction techniques in machine learning. In: **2014 Science and Information Conference**. [S.l.: s.n.], 2014. p. 372–378.
- KIRSCHBAUM, C.; PIRKE, K.; HELLHAMMER, D. The 'trier social stress test' – a tool for investigating psychobiological stress responses in a laboratory setting. **Neuropsychobiology**, v. 28, p. 76–81, 1993.
- KOLDIJK, S.; NEERINCX, M. A.; KRAAIJ, W. Detecting work stress in offices by combining unobtrusive sensors. **IEEE Transactions on Affective Computing**, v. 9, n. 2, p. 227–239, 2018. ISSN 1949-3045.
- KREIBIG, S. D. Autonomic nervous system activity in emotion: A review. **Biological Psychology**, v. 84, n. 3, p. 394–421, 2010. ISSN 0301-0511. The biopsychology of emotion: Current theoretical and empirical perspectives. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0301051110000827>>.

KUMAR, M. *et al.* Fuzzy evaluation of heart rate signals for mental stress assessment. **IEEE Transactions on Fuzzy Systems**, v. 15, n. 5, p. 791–808, 2007. ISSN 1063-6706.

LAHAT, D.; ADALI, T.; JUTTEN, C. Challenges in multimodal data fusion. In: **Zenodo**. [s.n.], 2014. Disponível em: <<https://doi.org/10.5281/zenodo.43933>>.

LIAO, W. *et al.* A real-time human stress monitoring system using dynamic bayesian network. In: **2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05) - Workshops**. [S.l.: s.n.], 2005. p. 70–70. ISSN 2160-7508.

MALIK, M. Heart rate variability: Standards of measurement, physiological interpretation, and clinical use. **Circulation**, v. 93, p. 1043–1065, 1996.

MARÉE, R. The need for careful data collection for pattern recognition in digital pathology. **Journal of Pathology Informatics**, v. 8, p. 19, 2017.

MCEWEN, B. S. The neurobiology of stress: from serendipity to clinical relevance11published on the world wide web on 22 november 2000. **Brain Research**, v. 886, n. 1, p. 172–189, 2000. ISSN 0006-8993. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0006899300029504>>.

MELLO, J.; SCHMIELE, E.; SOARES, A. Metodologia para classificação de movimentados da mão baseada em padrões eletromiográficos. In: **Congresso Brasileiro de Eletromiografia e Cinesilogia (COBEC) e o Simpósio de Engenharia Biomédica (SEB) - COBECSEB**. [S.l.: s.n.], 2018.

METZGER, R. A reliability and validity study of the state-trait anxiety inventory. **Journal of Clinical Psychology**, v. 32, p. 276–278, 1976.

MONTESINOS, L. *et al.* Ultra-short term hrv features as surrogates of short term hrv: a case study on mental stress detection in real life. **BMC Medical Informatics & Decision Making**, v. 19, n. 1, p. 1–13, 2019. ISSN 14726947.

MOZOS, O. M. *et al.* Stress detection using wearable physiological and sociometric sensors. **International Journal of Neural Systems**, v. 27, n. 2, p. 1650041, 2017. Disponível em: <<https://doi.org/10.1142/S0129065716500416>>.

MUAREMI, A. *et al.* Monitoring the impact of stress on the sleep patterns of pilgrims using wearable sensors. In: **IEEE-EMBS International Conference on Biomedical and Health Informatics (BHI)**. [S.l.: s.n.], 2014. p. 185–188. ISSN 2168-2194.

NABIAN, M. *et al.* An open-source feature extraction tool for the analysis of peripheral physiological data. **IEEE Journal of Translational Engineering in Health and Medicine**, v. 6, p. 1–11, 2018.

National Research Council. **Becoming a 21st-Century Force: Technology**. 2. ed. The National Academies Press, 1997. 2000-2035 p. ISBN 9780309083980. Disponível em: <<https://www.nap.edu/read/5863/chapter/6>>.

NGUYEN, G. H.; BOUZERDOUM, A.; PHUNG, S. L. Learning pattern classification tasks with imbalanced data sets. In: _____. [S.l.: s.n.], 2009. ISBN 978-953-307-014-8.

NOBLE, R. E. Diagnosis of stress. **Metabolism**, v. 51, n. 6, p. 37–39, 2002. ISSN 0026-0495.

- RAMIRO, F. de S. *et al.* Investigação do estresse, ansiedade e depressão em mulheres com fibromialgia: um estudo comparativo. **Revista Brasileira de Reumatologia**, Scielo, v. 54, p. 27–32, 2014. ISSN 0482-5004.
- REICHE, E. M. V.; NUNES, S. O. V.; MORIMOTO, H. K. Disfunções no sistema imune induzidas pelo estresse e depressão: Implicações no desenvolvimento e progressão do câncer. **Revista Brasileira de Oncologia Clínica**, v. 5, p. 19–28, 2005.
- REN, P. *et al.* Off-line and on-line stress detection through processing of the pupil diameter signal. **Annals of Biomedical Engineering**, v. 42, n. 1, p. 162–176, 2014. ISSN 1573-9686. Disponível em: <<https://doi.org/10.1007/s10439-013-0880-9>>.
- ROJAS, J. R.; HONG, J.-H.; DEY, A. Stress recognition: A step outside the lab. In: **PhyCS 2014 - Proceedings of the International Conference on Physiological Computing Systems**. [S.l.: s.n.], 2014.
- ROSSETTI, M. O. *et al.* O inventário de sintomas de stress para adultos de lipp (issl) em servidores da polícia ederal de são paulo. **Revista Brasileira de Terapias Cognitivas**, Scieloapsic, v. 4, p. 108–120, 2008. ISSN 1808-5687.
- SALAPPA, A.; DOUMPOS, M.; ZOPOUNIDIS, C. Feature selection algorithms in classification problems: an experimental evaluation. **Optimization Methods and Software**, Taylor & Francis, v. 22, n. 1, p. 199–212, 2007. Disponível em: <<https://doi.org/10.1080/10556780600881910>>.
- SANO, A.; PICARD, R. W. Stress recognition using wearable sensors and mobile phones. In: **2013 Humaine Association Conference on Affective Computing and Intelligent Interaction**. [S.l.: s.n.], 2013. p. 671–676. ISSN 2156-8111.
- SANSONE, M. *et al.* Electrocardiogram pattern recognition and analysis based on artificial neural networks and support vector machines: A review. **Journal of healthcare engineering**, v. 4, p. 465–504, 2013.
- SANTO, R. do E. Principal component analysis applied to digital image compression. **Einstein (São Paulo)**, Scielo, v. 10, p. 135–139, 2012. ISSN 1679-4508.
- SCHMIDT, P. *et al.* Introducing wesad, a multimodal dataset for wearable stress and affect detection. In: **Proceedings of the 20th ACM International Conference on Multimodal Interaction**. New York, NY, USA: ACM, 2018. p. 400–408. ISBN 978-1-4503-5692-3. Disponível em: <<http://doi.acm.org/10.1145/3242969.3242985>>.
- SELYE, H. **The stress of life**. McGraw-Hill, 1984. 515 p. (Schaum's Paperbacks). ISBN 9780070562127. Disponível em: <<https://books.google.com.br/books?id=hQOGtxen78YC>>.
- SETZ, C. *et al.* Discriminating stress from cognitive load using a wearable eda device. **IEEE Transactions on Information Technology in Biomedicine**, v. 14, n. 2, p. 410–417, 2010. ISSN 1089-7771.
- SHARMA, N.; GEDEON, T. Objective measures, sensors and computational techniques for stress recognition and classification: A survey. **Computer Methods and Programs in Biomedicine**, v. 108, n. 3, p. 1287–1301, 2012. ISSN 0169-2607. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0169260712001770>>.

SIERRA, A. de S. *et al.* Stress detection by means of stress physiological template. In: **2011 Third World Congress on Nature and Biologically Inspired Computing**. [S.l.: s.n.], 2011. p. 131–136.

SMITH, A.-L.; OWEN, H.; REYNOLDS, K. J. Heart rate variability indices for very short-term (30 beat) analysis. part 2: validation. **Journal of Clinical Monitoring and Computing**, v. 27, p. 577–585, 2013. ISSN 1573-2614. Disponível em: <<https://doi.org/10.1007/s10877-013-9473-2>>.

SOKOLOVA, M.; LAPALME, G. A systematic analysis of performance measures for classification tasks. **Information Processing & Management**, v. 45, n. 4, p. 427–437, 2009. ISSN 0306-4573. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0306457309000259>>.

SYSOEV, M. *et al.* Sensors classification for stress analysis: Toward automatic stress recognition. In: **2014 International Conference on Identification, Information and Knowledge in the Internet of Things**. [S.l.: s.n.], 2014. p. 117–121.

TAMURA, T. *et al.* Wearable photoplethysmographic sensors—past and present. **Electronics**, v. 3, Apr 2014.

TAYLOR, N. A.; MACHADO-MOREIRA, C. A. Regional variations in transepidermal water loss, eccrine sweat gland density, sweat secretion rates and electrolyte composition in resting and exercising humans. **Extreme Physiology & Medicine**, v. 2, p. 4, 2013.

THAPLIYAL, H.; KHALUS, V.; LABRADO, C. Stress detection and management: A survey of wearable smart health devices. **IEEE Consumer Electronics Magazine**, v. 6, n. 4, p. 64–69, 2017. ISSN 2162-2248.

The American Institute Of Stress. **Workplace Stress**. 2013. Disponível em: <<https://www.stress.org/workplace-stress>>. Acesso em: 21 de Março de 2019.

THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern Recognition**. 4. ed. Academic Press, 2009. ISBN 978-1-59749-272-0. Disponível em: <<http://www.sciencedirect.com/science/article/pii/B9781597492720500013>>.

TRIGUERO, I. *et al.* From big data to smart data with the k-nearest neighbours algorithm. In: **2016 IEEE International Conference on Internet of Things (iThings) and IEEE Green Computing and Communications (GreenCom) and IEEE Cyber, Physical and Social Computing (CPSCom) and IEEE Smart Data (SmartData)**. [S.l.: s.n.], 2016. p. 859–864.

UC Irvine Machine Learning Respository. **WESAD (Wearable Stress and Affect Detection) Data Set**. 2018. Disponível em: <<https://archive.ics.uci.edu/ml/datasets/WESAD+Wearable+Stress+and+Affect+Detection>>. Acesso em: 8 de Março de 2019.

VARELLA, C. A. A. **Análise Multivariada aplicada as ciências agrárias**. Rio de Janeiro, Brasil: [s.n.], 2002. Disponível em: <<http://www.ufrrj.br/institutos/it/deng/varella/Downloads/multivariada%20aplicada%20as%20ciencias%20agrarias/Aulas/ANALISE%20DISCRIMINANTE.pdf>>.

VICINI, L. **Análise multivariada da teoria à prática**. Santa Maria, Brasil: [s.n.], 2005.

VOSS, A. *et al.* Short-term heart rate variability—influence of gender and age in healthy subjects. **PLOS ONE**, v. 10, p. e0118308, 2015. ISSN 1932-6203.

- WANG, J.-S.; LIN, C.-W.; YANG, Y.-T. C. A k-nearest-neighbor classifier with heart rate variability feature-based transformation algorithm for driving stress recognition. **Neurocomputing**, v. 116, p. 136–143, 2013. ISSN 0925-2312. Advanced Theory and Methodology in Intelligent Computing. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0925231212007187>>.
- WANG, L.; LIN, Y.; WANG, J. A rr interval based automated apnea detection approach using residual network. **Computer Methods and Programs in Biomedicine**, v. 176, p. 93–104, 2019. ISSN 0169-2607. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0169260719300185>>.
- WANG, Q. *et al.* Pedestrian walking distance estimation based on smartphone mode recognition. **Remote Sensing**, v. 11, p. 1140, 2019.
- WARTTIG, S. L. *et al.* New, normative, english-sample data for the short form perceived stress scale (pss-4). **Journal of Health Psychology**, v. 18, n. 12, p. 1617–1628, 2013.
- WEBB, A.; COPSEY, K. **Statistical Pattern Recognition**. Wiley, 2011. 668 p. ISBN 9781119952961. Disponível em: <<https://books.google.com.br/books?id=WpV9Xt-h3O0C>>.
- WEBER, K. M. *et al.* Coping with a fast-changing world: Towards new systems of future-oriented technology analysis. **Science and Public Policy**, v. 39, n. 2, p. 153–165, 2012. ISSN 0302-3427. Disponível em: <<https://doi.org/10.1093/scipol/scs012>>.
- WYATT, J.; LIU, J. L. Y. Basic concepts in medical informatics. **Journal of epidemiology and community health**, v. 56, p. 808–12, 2002.
- ZHAI, J.; BARRETO, A. Stress detection in computer users based on digital signal processing of noninvasive physiological variables. In: **2006 International Conference of the IEEE Engineering in Medicine and Biology Society**. [S.l.: s.n.], 2006. p. 1355–1358. ISSN 1557-170X.
- ZHANG, B. *et al.* Reaction time and physiological signals for stress recognition. **Biomedical Signal Processing and Control**, v. 38, p. 100–107, 2017. ISSN 1746-8094. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1746809417300885>>.

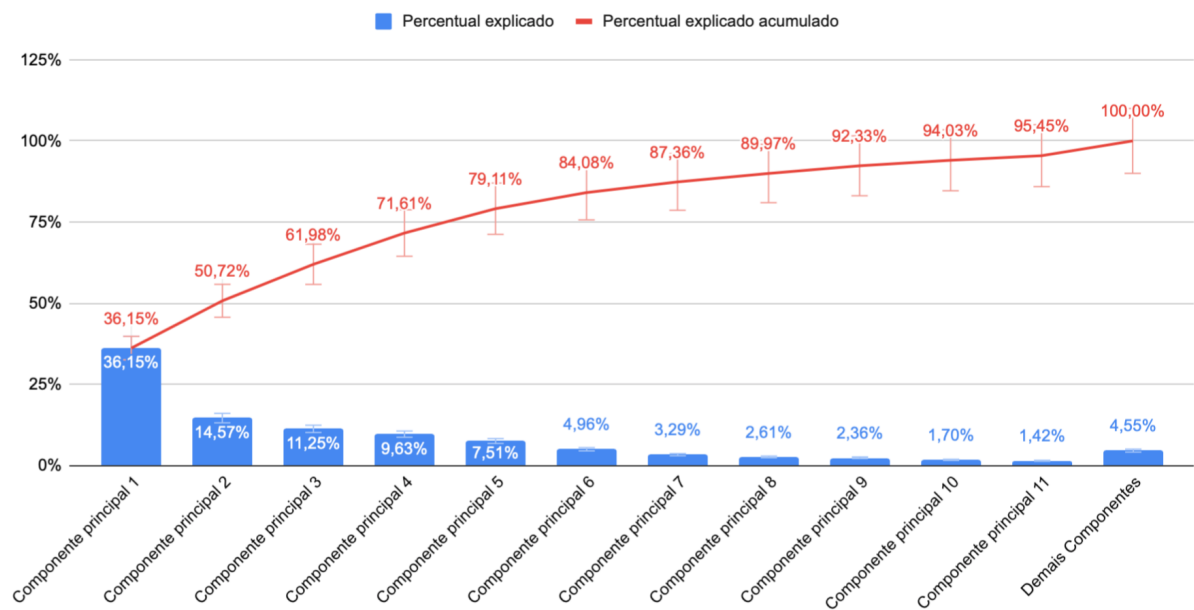
Apêndices e Anexos

APÊNDICE A – VARIÂNCIA EXPLICADA DO LDA E DO PCA

Para atingir 95% de variância explicada o LDA precisou apenas de 1 dimensão. Por outro lado, o PCA precisou de dimensões diferentes para cada sinal:

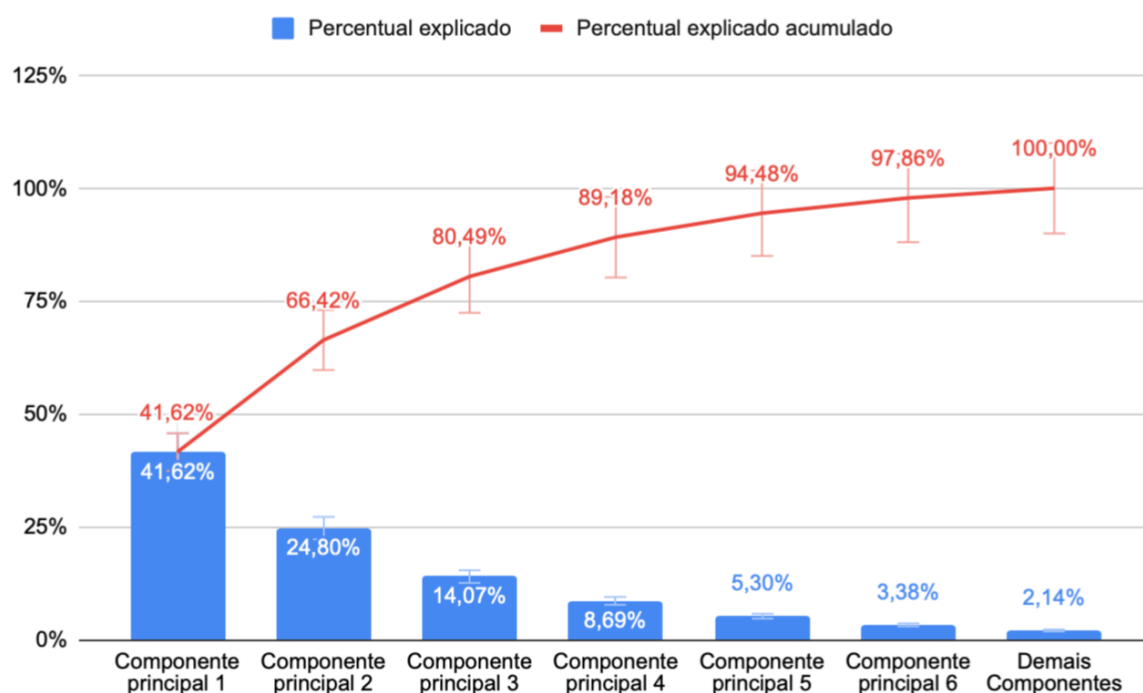
- ECG: foi necessário 13 dimensões (Figura 32);
- EDA: foi necessário 6 dimensões (Figura 33);
- EMG: foi necessário 5 dimensões (Figura 34);
- Respiração: foi necessário 6 dimensões (Figura 35);

Figura 32: ECG - Percentual de variância explicada do PCA




Fonte: Elaborado pelo autor (2019)

Figura 33: EDA - Percentual de variância explicada do PCA



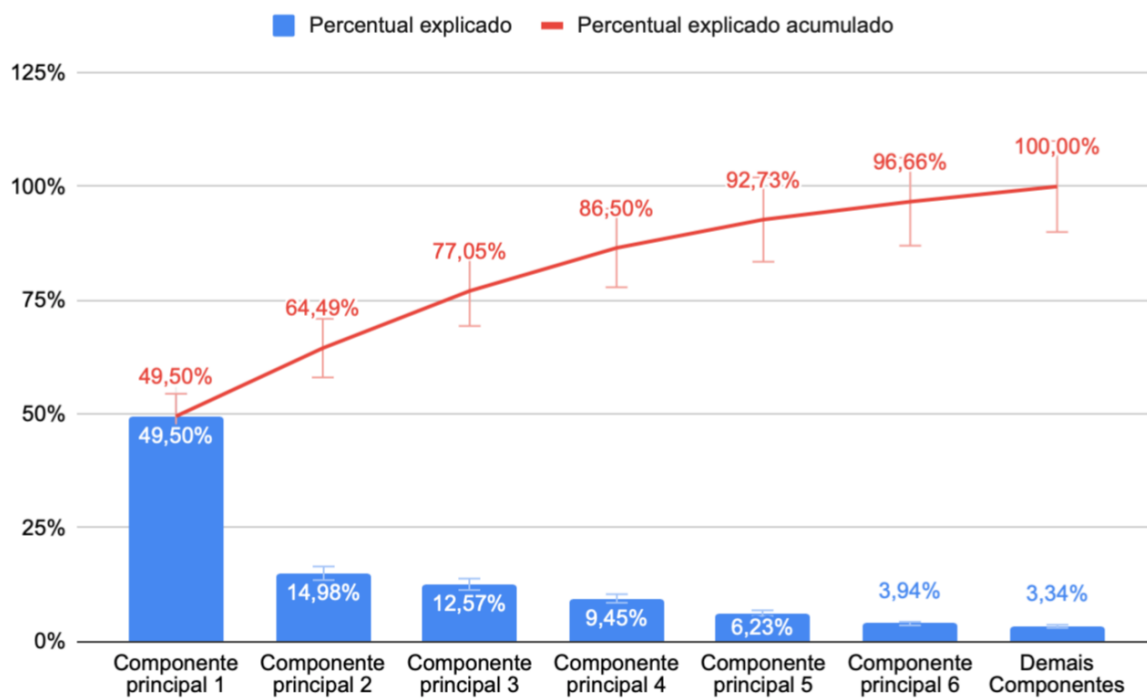
Fonte: Elaborado pelo autor (2019)

Figura 34: EMG - Percentual de variância explicada do PCA



Fonte: Elaborado pelo autor (2019)

Figura 35: Respiração - Percentual de variância explicada do PCA



Fonte: Elaborado pelo autor (2019)

ANEXO A – QUESTIONÁRIO PANAS

PANAS questionnaire items (the subject may answer each item with 1 for "Not at all", 2 for "A little bit", 3 for "Somewhat", 4 for "Very much" and 5 for "Extremely"). Two items (angry and irritated) were answered just on stress experiences:

- Active
- Distressed
- Interested
- Inspired
- Annoyed
- Strong
- Guilty
- Scared
- Hostile
- Excited
- Proud
- Irritable
- Enthusiastic
- Ashamed
- Alert
- Nervous
- Determined
- Attentive
- Jittery
- Afraid
- Stressed

- Frustrated
- Happy
- Angry
- Irritated
- Sad

ANEXO B – QUESTIONÁRIO STAI

STAI questionnaire items (the subject may answer each item with 1 for "Not at all", 2 for "Somewhat", 3 for "Moderately so" and 4 for "Very much so")

- I feel at ease
- I feel nervous I am jittery
- I am relaxed
- I am worried
- I feel pleasant

ANEXO D – SHORT STRESS STATE QUESTIONNAIRE

Short Stress State Questionnaire items (the subject may answer each item with 1 for "Not at all", 2 for "A little bit", 3 for "Somewhat", 4 for "Very much" and 5 for "Extremely"):

- I was committed to attaining my performance goals
- I wanted to succeed on the task
- I was motivated to do the task
- I reflected about myself
- I was worried about what other people think of me
- I felt concerned about the impression I was making