

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Vanessa Cassenote

**UMA METODOLOGIA PARA DETECÇÃO DE SONOLÊNCIA EM TEMPO
REAL COM EEG VESTÍVEL COM DUAS DERIVAÇÕES**

Santa Maria, RS
2020

Vanessa Cassenote

**UMA METODOLOGIA PARA DETECÇÃO DE SONOLÊNCIA EM TEMPO REAL COM
EEG VESTÍVEL COM DUAS DERIVAÇÕES**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação, Área de Concentração em Microeletrônica e Processamento de Sinais, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Mestre em Ciência da Computação**.

ORIENTADOR: Prof. Cesar Ramos Rodrigues

COORIENTADOR: Prof. Cesar Augusto Prior

Santa Maria, RS
2020

This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Finance Code 001

Cassenote, Vanessa

Uma metodologia para detecção de sonolência em tempo real com EEG vestível com duas derivações / Vanessa Cassenote.- 2020.

62 p.; 30 cm

Orientador: Cesar Ramos Rodrigues

Coorientador: Cesar Augusto Prior

Dissertação (mestrado) - Universidade Federal de Santa Maria, Centro de Tecnologia, Programa de Pós-Graduação em Ciência da Computação , RS, 2020

1. EEG Vestível 2. Processamento de Sinais 3. Aprendizado de Máquina I. Ramos Rodrigues, Cesar II. Prior, Cesar Augusto III. Título.

Sistema de geração automática de ficha catalográfica da UFSM. Dados fornecidos pelo autor(a). Sob supervisão da Direção da Divisão de Processos Técnicos da Biblioteca Central. Bibliotecária responsável Paula Schoenfeldt Patta CRB 10/1728.

Declaro, VANESSA CASSENOTE, para os devidos fins e sob as penas da lei, que a pesquisa constante neste trabalho de conclusão de curso (Dissertação) foi por mim elaborada e que as informações necessárias objeto de consulta em literatura e outras fontes estão devidamente referenciadas. Declaro, ainda, que este trabalho ou parte dele não foi apresentado anteriormente para obtenção de qualquer outro grau acadêmico, estando ciente de que a inveracidade da presente declaração poderá resultar na anulação da titulação pela Universidade, entre outras consequências legais.

Vanessa Cassenote

**UMA METODOLOGIA PARA DETECÇÃO DE SONOLÊNCIA EM TEMPO REAL COM
EEG VESTÍVEL COM DUAS DERIVAÇÕES**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação, Área de Concentração em Microeletrônica e Processamento de Sinais, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Mestre em Ciência da Computação**.

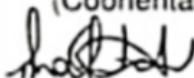
Aprovado em 20 de fevereiro de 2020:



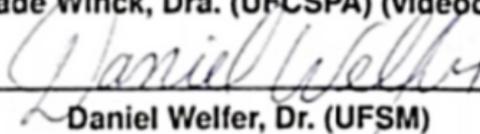
Cesar Ramos Rodrigues, Dr. (UFSC)
(Presidente/Orientador)



Cesar Augusto Prior, Dr. (UFSM)
(Coorientador)



Ana Trindade Winck, Dra. (UFCSPA) (videoconferência)



Daniel Welfer, Dr. (UFSM)

Santa Maria, RS
2020

AGRADECIMENTOS

Agradeço a todos que fizeram parte da minha vida em algum momento durante esses dois anos e que com certeza contribuíram para o meu crescimento de uma forma ou de outra. Em especial ao professor Cesar Ramos Rodrigues pela orientação neste trabalho, pela paciência e por me corrigir quando necessário e, ao professor Cesar Augusto Prior pela coorientação, apoio e incentivo desde a graduação. Agradeço também aos professores Ana Trindade Winck e Daniel Welfer por aceitarem fazer parte da banca de avaliação deste trabalho e contribuir para o aperfeiçoamento do mesmo.

Agradeço ainda, aos meus colegas da sala 286, especialmente ao Cesar Abascal e ao Victor O. Costa, pelas discussões e parceria. Agradeço também, ao Rafael Follmann Faccenda e ao Vinícius Lopes por todas as conversas, risadas e parceria nas sextas e sábados enriquecedores do PEG e, a Maira Bolfe e o Fabrício M. Bottega pelos bolos, companheirismo e amizade durante todos os anos que moramos juntos.

Por fim, agradeço as pessoas que mais me motivaram e me apoiaram para que eu conseguisse chegar até a finalização deste trabalho, meus pais: Marilene Felipetto Cassenote e Otacilio Manuel Cassenote e, o meu namorado Sandro Sartori Meneghetti. Agradeço ainda, a Capes pelo apoio financeiro.

RESUMO

UMA METODOLOGIA PARA DETECÇÃO DE SONOLÊNCIA EM TEMPO REAL COM EEG VESTÍVEL COM DUAS DERIVAÇÕES

AUTOR: Vanessa Cassenote
ORIENTADOR: Cesar Ramos Rodrigues
COORIENTADOR: Cesar Augusto Prior

A vida moderna exige, muitas vezes, que o sujeito modifique seu ciclo circadiano devido a sua profissão. Esta mudança implica em baixa no desempenho, mau humor e, principalmente, redução da capacidade de atenção e sonolência em horários inoportunos. Segundo a OMS, cerca de 1.35 milhões de pessoas morrem por ano em acidentes no trânsito. Assim, neste trabalho foi proposta uma metodologia para detecção de sonolência em tempo real, com o objetivo de ajudar a minimizar o problema citado. A metodologia proposta extrai Alfa, Teta, Beta e Gama através da transformada Wavelet de Haar e compara performances dos classificadores: MLP, KNN, LDA, RF, SVM e um *Threshold*. Todas as análises realizadas utilizaram sinais de um banco de dados público. Para que se possa avaliar a metodologia em um ambiente mais realista, parte dos sinais foram separados e através de um experimento, foram adquiridos por um EEG vestível. A partir disso, analisou-se o sinal adquirido e as performances dos classificadores para estes sinais. Além disso, foram avaliadas também as performances dos classificadores para todas as amostras (sem a leitura pelo EEG) e diferentes tamanhos de épocas, sendo uma época de 10 s com janela deslizante de 3 s a melhor, onde obteve-se sensibilidade de 95% com uma SVM.

Palavras-chave: EEG Vestível, Processamento de Sinais, Aprendizado de Máquina

ABSTRACT

A METHODOLOGY FOR DROWSINESS DETECTION IN REAL-TIME WITH WEARABLE EEG WITH TWO DERIVATIONS

AUTHOR: Vanessa Cassenote
ADVISOR: Cesar Ramos Rodrigues
CO-ADVISOR: Cesar Augusto Prior

Modern life often requires the subject to modify his circadian cycle due to his profession. This change implies low performance, bad mood and, mainly, reduced attention and, drowsiness at unsuitable times. According to the WHO, about 1.35 million people die each year in traffic accidents. Thus, this work proposes a methodology for detecting drowsiness in real time, with the aim of helping to minimize the problem mentioned. The proposed methodology extracts Alpha, Theta, Beta and Gamma through the Haar Wavelet transform and compares performances of the classifiers: MLP, KNN, LDA, RF, SVM and a *Threshold*. All analyzes performed used signals from a public database. In order to be able to evaluate the methodology in a more realistic environment, part of the signals were separated and through an experiment, they were acquired by a wearable EEG. From there, the acquired signal and the classifier performances for these signals were analyzed. In addition, the performances of the classifiers for all samples (without EEG acquisition) and different epoch sizes were also evaluated, being a 10 s epoch with a sliding window of 3 s the best, where a sensitivity of 95% was obtained with an SVM.

Keywords: Wearable EEG, Signal Processing, Machine Learning

LISTA DE FIGURAS

Figura 2.1 – Sistema 10-20 de posicionamento de eletrodos pela Federação Internacional de Neurofisiologia Clínica. (A), (B) e (C) ilustram três mudanças distintas no EEG associadas à redução da vigília e a caixa rosa ilustra as alterações observadas pelos picos nas membranas neuronais, quando adquiridas por eletrodos intra-célula, em direção à superfície do escalpo.	14
Figura 2.2 – Parte do sinal da segunda noite de gravação do sujeito 00, com anotações de hipnogramas (W - acordado, 1 - primeiro estágio de sono, 2 - segundo estágio de sono, 3 - terceiro estágio de sono, 4 - quarto estágio de sono).	17
Figura 2.3 – EEG Vestível.	18
Figura 2.4 – Tipos de funções Wavelet.	20
Figura 2.5 – DWT de Haar para um sinal em 4 níveis de decomposição. <i>A</i> são os vetores de médias ou aproximação e <i>D</i> os vetores de detalhes.	22
Figura 2.6 – Fluxo geral de um problema de classificação.	24
Figura 2.7 – Redes Neurais - <i>feed-forward multi-layer perceptron</i> (MLP).	25
Figura 2.8 – Maximização da margem com as Máquinas de Vetores de Suporte (SVM).	26
Figura 2.9 – Mudança de dimensão das Máquinas de Vetores de Suporte (SVM).	27
Figura 2.10 – Classificador k-Vizinhos mais Próximos.	28
Figura 2.11 – Classificador florestas aleatórias.	29
Figura 2.12 – Exemplo de um problema com duas classes, considerando um problema desbalanceado. Amostras oriundas do Physionet, sendo a classe P amostras anotadas como "S1" e "S2" e a classe N como "W". São calculadas a Sensibilidade (Sen), Especificidade (Esp) e Acurácia (Acc).	30
Figura 4.1 – Fluxograma com a separação dos dados utilizados e as análises realizadas.	37
Figura 4.2 – Fluxograma geral de processamento com EEG vestível.	39
Figura 4.3 – Fluxograma geral de processamento para comparação com sinais adquiridos pelo EEG vestível.	39
Figura 5.1 – A figura mostra os resultados de sensibilidade, especificidade e acurácia para os sinais do grupo de teste e validação para cada classificador. Os resultados com o sufixo "_EEG" correspondem ao experimento TPEEG.	42
Figura 5.2 – A figura mostra parte do sinal do primeiro dia de gravação do sujeito 5. O primeiro gráfico compara a FFT do sinal original e, este após ser lido pelo EEG vestível. O segundo gráfico mostra o sinal no domínio do tempo. E o último gráfico mostra uma aproximação do anterior.	44
Figura 5.3 – A figura mostra os ritmos cerebrais Teta, Alfa, Beta e Gama, para parte do sinal do primeiro dia de gravação do sujeito 5. A primeira linha de gráficos mostra cada ritmo para o sinal original do banco de dados e a segunda, o mesmo sinal após aquisição pelo EEG vestível.	44
Figura 5.4 – As figuras mostram os resultados de sensibilidade, especificidade e acurácia para cada um dos classificadores, com todas as amostras dos grupos de teste e validação.	46

LISTA DE TABELAS

Tabela 2.1 – Filtros não-normalização e normalizados para a DWT de Haar.	22
Tabela 2.2 – Principais características dos estudos revisados.	32
Tabela 4.1 – Especificações de software usados em Python 2.7 e biblioteca sklearn 0.20.4.	40
Tabela 5.1 – Tempo médio de processamento para cada época de 30 segundos.	45
Tabela 5.2 – Tempo médio de processamento para cada época de 10 s com janela deslizante de 5s.	45
Tabela 5.3 – A tabela mostra os resultados de acurácia, sensibilidade e especificidade para uma época de 10 segundos com uma janela deslizante de 5 segundos.	47
Tabela 5.4 – São apresentadas as principais características dos trabalhos relacionados e, os resultados encontrados para RF, SVM e o <i>Threshold</i> , utilizando uma época de 10 s com janela deslizante de 5 s.	49
Tabela A.1 – Resultados de acurácia, sensibilidade e especificidade para todos os classificadores e todos dados.	57
Tabela B.1 – A tabela mostra os resultados de acurácia, sensibilidade e especificidade para cinco tamanhos de épocas diferentes, utilizando o RF.	60
Tabela B.2 – A tabela mostra os resultados de acurácia, sensibilidade e especificidade para cinco tamanhos de épocas diferentes, utilizando a SVM.	61
Tabela B.3 – A tabela mostra os resultados de acurácia, sensibilidade e especificidade para cinco tamanhos de épocas diferentes, utilizando o <i>Threshold</i>	62

LISTA DE QUADROS

Quadro 2.1 – Os 5 principais ritmos cerebrais e as faixas de frequência correspondentes.	16
Quadro 2.2 – Matriz de confusão para duas variáveis (positivo (P) e negativo (N)). ...	30
Quadro 5.1 – Número de épocas de 30 s para os grupos de teste e validação.	45

LISTA DE ABREVIATURAS E SIGLAS

<i>EEG</i>	Eletoencefalograma/eletoencefalografia
<i>PSG</i>	Polissonógrafo/polissonografia
<i>R&K</i>	Rechtschaffen e Kales
<i>REM</i>	Movimento rápido dos olhos
<i>NREM</i>	Movimento não-rápido dos olhos
<i>S1</i>	Estágio de sono 1
<i>S2</i>	Estágio de sono 2
<i>S3</i>	Estágio de sono 3
<i>S4</i>	Estágio de sono 4
<i>W</i>	Estágio acordado
<i>DWT</i>	Transformada <i>wavelet</i> discreta
<i>PSD</i>	Espectro de frequência
<i>MLP</i>	<i>Multi-layer perceptron</i>
<i>KNN</i>	K-vizinhos mais próximos
<i>LDA</i>	<i>Linear discriminant analysis</i>
<i>RF</i>	Florestas aleatórias
<i>SVM</i>	Máquinas de vetores de suporte
<i>OMS</i>	Organização mundial da saúde

SUMÁRIO

1	INTRODUÇÃO	11
2	FUNDAMENTAÇÃO TEÓRICA	13
2.1	SINAIS DE EEG	13
2.2	BASE DE DADOS SLEEP EDF [EXPANDED]	16
2.3	EEG VESTÍVEL	17
2.4	PRÉ-PROCESSAMENTO	18
2.5	TRANSFORMADA <i>WAVELET</i> DISCRETA (DWT)	19
2.5.1	Transformada <i>wavelet</i> de HAAR discreta	20
2.6	EXTRAÇÃO DE ATRIBUTOS	22
2.7	CLASSIFICAÇÃO	23
2.7.1	Redes Neurais Artificiais (ANN)	24
2.7.2	Máquinas de Vetores de Suporte (SVM)	26
2.7.3	k-Vizinhos mais Próximos (kNN)	26
2.7.4	LDA	28
2.7.5	Florestas Aleatórias (RF)	28
2.7.6	Threshold	29
2.7.7	Métricas de Avaliação	30
3	REVISÃO DE LITERATURA	33
3.1	ESTUDOS UTILIZANDO BASES DE DADOS PÚBLICAS	33
3.2	ESTUDOS QUE INCLUEM A AQUISIÇÃO DE DADOS	34
3.3	TRABALHOS RELACIONADOS E PROPOSTA DO TRABALHO	36
4	MATERIAIS E MÉTODOS	37
4.1	EXPERIMENTO PARA AQUISIÇÃO	38
4.2	ESPECIFICAÇÕES DE HARDWARE E SOFTWARE	40
5	RESULTADOS	41
5.1	PERFORMANCE EM TEMPO REAL	41
5.2	ANÁLISE DO SINAL DO EEG VESTÍVEL	43
5.3	PERFORMANCE PARA TODAS AS AMOSTRAS E TAMANHOS DE ÉPOCAS	43
5.4	DISCUSSÃO	47
6	CONCLUSÃO	50
6.1	TRABALHOS FUTUROS	50
	REFERÊNCIAS BIBLIOGRÁFICAS	51
	APÊNDICE A – RESULTADOS PARA TODAS AS AMOSTRAS	57
	APÊNDICE B – RESULTADOS PARA DIFERENTES TAMANHOS DE ÉPOCAS	60

1 INTRODUÇÃO

O estudo moderno do sono vem sendo realizado desde 1930, sendo a principal razão da sua evolução, a invenção do eletroencefalograma (EEG), equipamento o qual faz a leitura de sinais elétricos do cérebro. A partir deste equipamento pode-se fazer o diagnóstico de diversas doenças neurológicas como: epilepsia, apneia, narcolepsia, insônia e muitas outras (ŠUŠMÁKOVÁ, 2004). A análise do sinal de EEG para diagnóstico de condições neurológicas é uma tarefa que consome tempo e exige profissionais treinados (ACHARYA et al., 2012). Devido a isso, estão sendo realizados diversos estudos buscando automatizar a detecção de padrões nestes sinais, com o objetivo de auxiliar o profissional da saúde. Bajaj e Pachori (2013), Zhu, Li e Wen (2014), Rodríguez-Sotelo et al. (2014), Hassan, Bashar e Bhuiyan (2015), Diykh e Li (2016) desenvolveram metodologias para detecção dos estágios do sono, o que auxilia na caracterização de diversos distúrbios do sono.

Os estágios de sono e o estado acordado são regulados pelo ciclo circadiano, um processo interno que dura em torno de 24 horas. Estes estágios estão relacionados às mudanças fisiológicas na atividade cerebral, do sono mais leve ao sono mais profundo (JALILIFARD; PIZZOLATO, 2016). Porém, devido à vida moderna, algumas profissões da área de transporte, assistência médica, indústrias de manufatura, serviço militar, aviação e muitos outros serviços, exigem que o sujeito modifique seu ciclo circadiano devido aos turnos de trabalho. Essa mudança pode afetar o desempenho, o humor e, principalmente, a redução da atenção quando acordado. A sonolência em motoristas no ramo de transporte é uma situação muito séria e acredita-se que esteja ligada a diversos acidentes de trânsito (LAL; CRAIG, 2001). Segundo os dados da organização mundial da saúde, cerca de 1.35 milhões de pessoas morrem por ano em acidentes de trânsito (OMS, 2018). Entre 2011 e 2015, o *National Highway Traffic Safety Administration* (NHTSA) reportou que 2.3% a 2.5% de todos os acidentes de carro fatais, envolveram motoristas adormecidos (NHTSA, 2017). Esses números podem ser muito maiores em outros países, por exemplo, em torno de 20% no Brasil (ABN, 2017).

Assim, um sistema para monitoramento do motorista com o objetivo de identificar sonolência pode ajudar a minimizar este problema. Ao realizarmos uma revisão do tema, podemos identificar três abordagens principais. A primeira é baseada nos parâmetros do veículo, ou seja, na velocidade do carro, na posição do carro na pista, posição da direção, pressão no acelerador, etc (BALANDONG et al., 2018). Muitos estudos mostraram que esta técnica não é eficaz para detectar sonolência, já que as variações medidas não necessariamente foram causadas pela sonolência, mas podem ter sido causadas por outros fatores, como as características da própria rua, por exemplo (SAHAYADHAS; SUNDARAJ; MURUGAPPAN, 2012). A segunda técnica é através do monitoramento do motorista uti-

lizando câmeras. A partir do processamento das imagens são avaliadas a posição da cabeça, piscadas do olhos, bocejo, direção do olhar, etc. Apesar desta técnica ter melhorado muito nos últimos anos, a variação de luminosidade ainda é um grande problema na detecção de sonolência (BALANDONG et al., 2018). Além disso, o sistema tende a ter problemas também com pessoas que usam óculos ou que possuem barba (ASSARI; RAHMATI, 2011). O terceiro método se baseia na medição de sinais fisiológicos do sujeito. Equipamentos como o eletrocardiograma (ECG), eletrooculograma (EOG), eletroencefalograma (EEG) e a Espectrografia Funcional de Infravermelho Próximo (fNIRS) já foram investigados para detecção de sonolência (AHN et al., 2016). O EEG já vem sendo utilizado para diversas soluções de Interface Cérebro-Máquina (do inglês Brain Computer Interface - BCI) e tem se mostrado uma ótima ferramenta para solucionar alguns tipos de problemas, como o controle de próteses (GUGER et al., 2003; FABIANI et al., 2004) e pacientes com dificuldades motoras diversas (GUGER et al., 2001). O estudo baseado em sinais fisiológicos permite uma detecção da sonolência o mais próximo possível da fonte. Além de que, um sistema baseado nesta técnica pode ser utilizado em outros ambientes de trabalho que exigem atenção constante, não somente no trânsito.

Assim, este trabalho propõe uma técnica para detecção de sonolência utilizando sinais de EEG para uma aplicação em tempo real, tendo os seguintes objetivos específicos:

- Realizar uma revisão de literatura de estudos para detecção de sonolência que utilizem somente sinais de EEG;
- Buscar trabalhos que utilizem equipamentos portáteis para aquisição do sinal de EEG;
- Estabelecer um procedimento para simular aquisição e processamento do sinal de EEG em tempo real;
- Avaliar a performance dos sinais do banco de dados após serem adquiridos pelo EEG vestível;
- Comparar o desempenho dos principais algoritmos de aprendizado de máquina utilizados na classificação da sonolência;
- Apresentar análise dos resultados encontrados, utilizando métricas de avaliação e comparando com outros trabalhos.

O texto está organizado da seguinte forma: o capítulo 1 apresentou a introdução ao tema, em seguida o capítulo 2 apresenta a fundamentação teórica, sendo as técnicas para o pré-processamento, extração de atributos, classificação e métricas de avaliação. O capítulo 3 apresenta a revisão de literatura e a proposta do trabalho. Na sequência, são detalhados os materiais e métodos no capítulo 4, os resultados no capítulo 5 e, por fim as conclusões são expressas no capítulo 6.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 SINAIS DE EEG

O principal exame utilizado na investigação dos distúrbios do sono é a polissonografia (PSG), a qual é muito utilizada no diagnóstico e tratamento de doenças. A PSG consiste em realizar três medidas principais: a mudança gradual do tônus muscular com o eletromiograma (do inglês Electromyogram - EMG), o movimento dos olhos com o eletroculograma (do inglês Electrooculogram - EOG), e as variações dos ritmos cerebrais com o eletroencefalograma (do inglês Electroencephalogram - EEG) (CARSKADON; DEMENT et al., 2005).

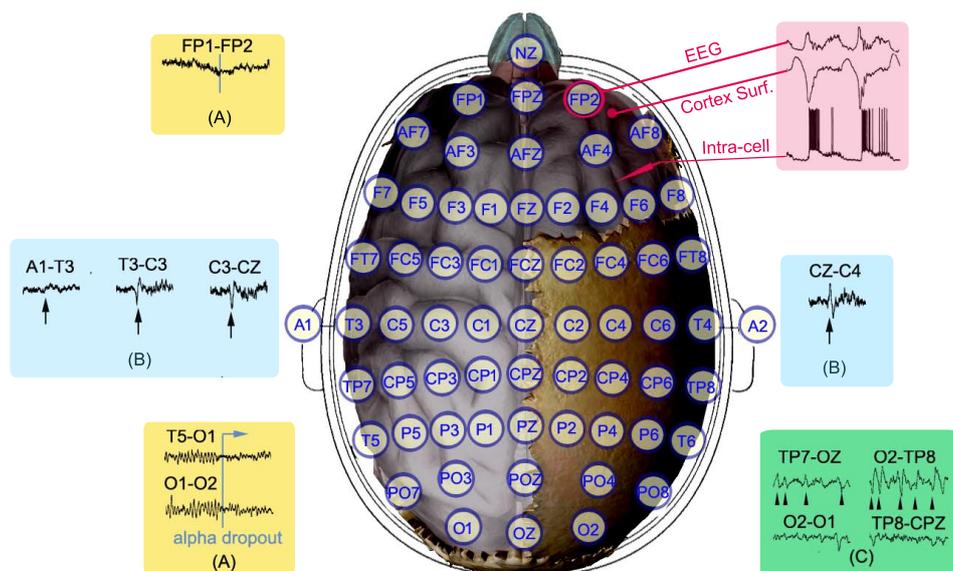
Sahayadhas, Sundaraj e Murugappan (2005) citam a descrição de mecanismos que mediam as transições entre o estado acordado e o sono como um flip-flop eletrônico. Grupos de neurônios localizados no hipotálamo interagem através de um mecanismo de equilíbrio direto inibitório. O núcleo pré-óptico ventrolateral (do inglês Ventrolateral Pre-optic Nucleous - VLPO), na região anterior do hipotálamo, desempenha o papel de inibir a atividade das células monoaminérgicas encontradas no terço posterior do hipotálamo (núcleo tuberomamilar). Os neurônios VLPO desencadeiam o estado de sono liberando GABA e galanina. Estes neurotransmissores têm o efeito de diminuir as taxas de disparo dos neurônios monoaminérgicos, cujos valores mais altos estão associados ao estado de alerta.

No entanto, o EEG é uma técnica que detecta a atividade elétrica geral nos grupos de células cerebrais mais externas, sendo incapaz de captar sinais gerados em suas estruturas internas. Assim, a identificação de sonolência por meio de eletrodos de EEG só é possível porque os núcleos intralaminar do tálamo contêm neurônios talamocorticais que enviam projeções por todo o córtex. Dessa forma, o cabo de guerra contínuo entre sono e excitação que ocorre no tronco cerebral controla o estado mental, modulando a ritmicidade dessas interações talamocorticais (PURVES et al., 2017). A ativação dos neurônios talamocorticais os leva a liberar aminoácidos excitatórios, como aspartato e glutamato, contribuindo assim para a excitação do córtex, que mantém o indivíduo acordado. Durante o estado acordado, esses neurônios geram potenciais de ação isolados em intervalos regulares, mas, à medida que o indivíduo adormece, esses neurônios começam a disparar em rajadas, fazendo com que o córtex exiba o padrão de EEG sincronizado típico do sono (PURVES et al., 2017). Quando vistos a partir de eletrodos de EEG, ou seja, vários milímetros acima da superfície cortical, a atividade de pico de conjunto dos neurônios da superfície cortical acumula potenciais de campo que são detectados pelos eletrodos no escalpo como as ondas e complexos característicos que orientam os eletroencefalógrafos

na interpretação do EEG. A correspondência da atividade neuronal captada por eletrodos de EEG no escalpo, superfície do córtex e no nível celular é mostrada no canto superior direito da Fig. 2.1. Esta figura mostra também o posicionamento dos eletrodos através do escalpo de acordo com o sistema 10-20 de posicionamento (regiões do cérebro: F-frontal, T-temporal, C-central, P-parietal, O-occipital).

Schomer e Silva (2011) apontam que o nível de vigília oscila durante os registros de vigília, onde episódios curtos e leves de sonolência são muito comuns. Como mostrado nas caixas amarelas (A) da Fig. 2.1, o início da sonolência em adultos é caracterizado por uma queda do ritmo alfa (marcado pelas linhas verticais azuis). Esse evento é mais proeminente na região occipital. Enquanto a sonolência se aprofunda, oscilações lentas começam a predominar em todas as regiões. A sonolência profunda é então descrita por duas características comuns, também representadas na Fig. 2.1 (B): As ondas do vértice (*spindles*), mostradas nas caixas azuis, têm magnitudes maiores nos eletrodos CZ e PZ (KIM et al., 2012) e (C) Os transitórios pontuais positivos do sono (do inglês Positive Occipital Sharp Transients of Sleep - POSTS), apresentados na caixa verde, são observados durante a sonolência profunda e o sono leve. Os POSTS foram descritos pela primeira vez por Gibbs e Gibbs (PURVES et al., 2017) como ondas positivas do tipo *spike* nas áreas occipitais.

Figura 2.1 – Sistema 10-20 de posicionamento de eletrodos pela Federação Internacional de Neurofisiologia Clínica. (A), (B) e (C) ilustram três mudanças distintas no EEG associadas à redução da vigília e a caixa rosa ilustra as alterações observadas pelos picos nas membranas neuronais, quando adquiridas por eletrodos intra-célula, em direção à superfície do escalpo.



O sinal de EEG tem largura de banda entre 0.5 e 150 Hz e amplitudes da ordem de 100 μ V (YAZICIOGLU et al., 2008). A Figura 2.1 mostra o posicionamento dos eletrodos pelo escalpo de acordo com o padrão do sistema 10-20. No estudo do sono existem duas principais regras para gravação e interpretação dos sinais de EEG. A primeira desenvolvida por Rechtschaffen and Kales (R&K) em 1968, diz que o sono é dividido em REM (do inglês, Rapid Eye Movement) e NREM (do inglês, Non-rapid Eye Movement), além do estado acordado e o "movement time". O REM é a fase onde acontecem os sonhos, o movimento rápido dos olhos e a perda do tônus muscular (LU et al., 2006). Já o NREM é dividido em 4 estágios de sono, do mais leve para o mais profundo (S1, S2, S3 e S4). Os estágios S3 e S4 são conhecidos como sono de ondas lentas (SWS) e o "movement time" representa os movimentos do corpo que não fazem parte dos estágios de sono (ŠUŠMÁKOVÁ, 2004). Em 2007, a American Academy of Sleep Medicine (AASM) realizou algumas mudanças nestas regras. Os estágios de sono mudaram para a nomenclatura de N1, N2 e N3, sendo que N3 é uma junção de S3 e S4, por terem características semelhantes, além de que, REM passou a se chamar R e o "movement time" foi abolido. Além disso, diversas outras recomendações para a aquisição da polissonografia também foram alteradas (MOSER et al., 2009).

Variações na atividade cerebral são expressas através de cinco principais ritmos cerebrais: Delta, Teta, Alfa, Beta e Gama. O ritmo delta é encontrado entre 0.5 Hz e 4 Hz e está presente principalmente em sono profundo, mas também pode aparecer no estado acordado. O teta aparece entre 4 Hz e 7.5 Hz, este representa a transição em direção a sonolência, meditação profunda e quando aparece em grande escala em um adulto acordado pode representar alguma patologia. Já o ritmo alfa varia entre as frequências de 8 Hz e 13 Hz. Este ritmo aparece na parte posterior da cabeça e esta ligado a falta de atenção e concentração, além de ser mais proeminente quando o sujeito esta com os olhos fechados. Este é o ritmo que mais aparece na atividade cerebral. Entre 14 e 26 Hz pode ser encontrado o ritmo beta, que ao contrário de alfa representa pensamento ativo, atenção, foco e resolução de problemas. Um nível muito alto de beta acontece quando o sujeito está em estado de pânico. Este ritmo aparece na região frontal e, principalmente, central da cabeça. As frequências acima de 30 Hz são chamadas de gama e são utilizadas no diagnóstico de certas doenças no cérebro, podendo ser um bom indicativo de sincronização associado a eventos (do inglês, Event-related Synchronization - ERS) (SANEI; CHAMBERS, 2007). O quadro 2.1 resume a associação das faixas de frequência e cada ritmo cerebral.

Quadro 2.1 – Os 5 principais ritmos cerebrais e as faixas de frequência correspondentes.

Ritmo	Faixas de Frequência
Delta (δ)	0.5 Hz - 4 Hz
Teta (θ)	4 Hz - 7.5 Hz
Alfa (α)	8 Hz - 13 Hz
Beta (β)	14 Hz - 26 Hz
Gama (γ)	30 Hz - 100 Hz

Fonte: (SANEI; CHAMBERS, 2007)

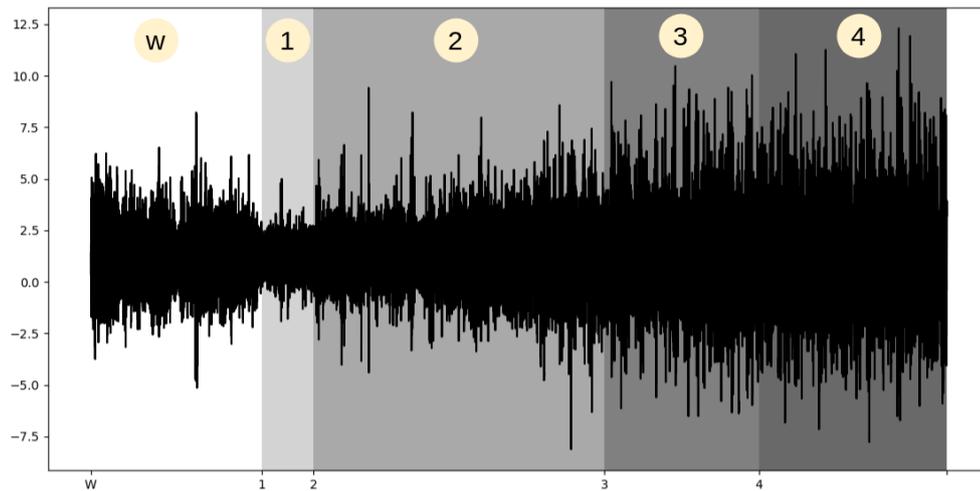
2.2 BASE DE DADOS SLEEP EDF [EXPANDED]

A plataforma *PhysioNet* disponibiliza sinais biomédicos com o intuito de estimular novas pesquisas. Muitas vezes os pesquisadores não tem acesso a dados de qualidade, corretamente validados por profissionais, além de que, a disponibilização de dados publicamente, possibilita que comparações entre trabalhos sejam realizadas, evitando pesquisas redundantes e contribuindo com o crescimento da pesquisa. Esta plataforma possui o banco de dados *PhysioBank* com mais de 75 bases de dados, sendo uma delas a *Sleep EDF [Expanded]*. Os dados contidos nesta base foram obtidos de 10 homens e 10 mulheres com idades entre 25 e 34 anos, sem uso de medicação relacionada ao sono. Os sinais foram adquiridos pelos canais Fpz-Cz e Pz-Oz com uma taxa de amostragem de 100 Hz. Nesse trabalho somente os dados da derivação Pz-Oz foram utilizados dado que ele fornece melhores resultados de classificação para problemas de análise de sonolência (ZHU; LI; WEN, 2014).

Para cada um dos 20 sujeitos foram gravadas duas noites de sono, resultando em 39 arquivos de sinais, sendo que a gravação da segunda noite do sujeito 13 foi perdida. Assim, para este estudo foram utilizados os arquivos de 19 voluntários para que se tenha aproximadamente a mesma quantidade de amostras para cada sujeito. Os arquivos são nomeados da seguinte forma: SC4**ssN**, sendo **ss** o número do sujeito e **N** a 1ª ou 2ª noite de gravação, cada noite de gravação possui em torno de 20 horas de sinal. Além dos arquivos de sinais, o *PhysioNet* também disponibiliza arquivos de anotações dos sinais, realizadas por profissionais. Estes arquivos são chamados hypnogramas e eles contém anotações dos estágios de sono do sujeito a cada faixa de tempo ou época de 30 segundos (s). Considerando a frequência de amostragem de 100 Hz, uma época de 30 s é equivalente a 3000 de dados, portando uma linha do arquivo de hypnograma corresponde a 3000 pontos de dados lidos pelo EEG. A aquisição foi realizada com base em R&K, assim as anotações que podem ser encontradas são: acordado (W), estágio 1 (S1), estágio 2 (S2), estágio 3 (S3), estágio 4 (S4), movimento rápido do olhos (REM), "tempo de mo-

vimento" ou "não classificado" (GOLDBERGER et al., 2000). A Fig. 2.2 mostra parte do sinal do sujeito 00 assim como os hipnogramas correspondentes para cada faixa do sinal.

Figura 2.2 – Parte do sinal da segunda noite de gravação do sujeito 00, com anotações de hipnogramas (W - acordado, 1 - primeiro estágio de sono, 2 - segundo estágio de sono, 3 - terceiro estágio de sono, 4 - quarto estágio de sono).



Fonte: Adaptado de (GOLDBERGER et al., 2000).

2.3 EEG VESTÍVEL

O equipamento da Myndplay é um EEG vestível com dois eletrodos frontais, os quais correspondem ao FP1 e FP2 e um eletrodo auricular (A1) para referência (Fig. 2.3). Com ele é possível captar o sinal *raw*, além das bandas filtradas em: delta, teta, *low* alfa, *high* alfa, *low* beta, *high* beta, *low* gama, *high* gama e *mid* gama. Através desses sinais, o equipamento também estima a atenção e meditação do usuário. Os sinais adquiridos a uma taxa de amostragem de 512 Hz são enviados via bluetooth, permitindo mobilidade ao usuário (MYNDPLAY, 2011).

Figura 2.3 – EEG Vestível.



Fonte: Autora.

2.4 PRÉ-PROCESSAMENTO

O processamento do sinal é realizado por épocas (ou faixas de tempo), e não do sinal completo. Como mencionado anteriormente, por R&K existem 4 estágios de sono além do estado acordado e do REM, e esta foi a metodologia empregada pelo *PhysioNet* para gravar os sinais utilizados neste trabalho. Existem variações entre os trabalhos para detecção de sonolência, quanto à escolha do estágio de sono que melhor representa a sonolência. (SILVEIRA; KOZAKEVICIUS; RODRIGUES, 2015) utilizou o primeiro estágio de sono (N1) e criou uma classe intermediária entre acordado e N1. Porém, grande parte dos trabalhos utiliza somente o primeiro estágio de sono (BELAKHDAR et al., 2018; CORREA; OROSCO; LACIAR, 2014; PATRICK et al., 2016). Ainda assim, S1 e S2 são ambos considerados sono leve, e segundo as novas regras criadas pela AASM, citadas anteriormente, muitas épocas anotadas previamente como S2 na nova regra se tornaram N1. Assim, neste trabalho o estágio de sonolência é composto pelos estágios S1 e S2, sendo então excluídas todas as épocas que não correspondem a estes estágios.

Além disso, considerando que o EEG vestível adquire os sinais a uma taxa de 512 Hz e o sinal original foi adquirido a 100 Hz, é necessário realizar uma re-amostragem do sinal após a aquisição, para que se possa utilizar a mesma transformada *wavelet*, na seção 2.5 são detalhadas as razões para isto. Esta etapa acaba adicionando uma parcela de erro aos dados, já que idealmente deveria-se ter uma nova amostra a cada 5,12 pontos. Ainda,

para um sistema de aplicação real, é necessário que haja um monitoramento periódico do sujeito e, em muitos casos, 30 segundos pode ser um tempo muito grande. Assim, foram realizados análises variando o tamanho da época, sendo estas: épocas de 10 s, de 5 s, épocas de 10 s com janela deslizante de 1 s e épocas de 10 s com janelas deslizantes de 5 s.

2.5 TRANSFORMADA WAVELET DISCRETA (DWT)

As *wavelets* são funções, seguindo alguns requisitos matemáticos, utilizadas como base para representação de outras funções, assim como os senos e cossenos são as bases para a decomposição por Fourier, ou seja, uma função pode ser escrita em termos de funções *wavelets*. Após definida a *mother wavelet* são calculadas as translações e dilatações desta *wavelet*, a partir de

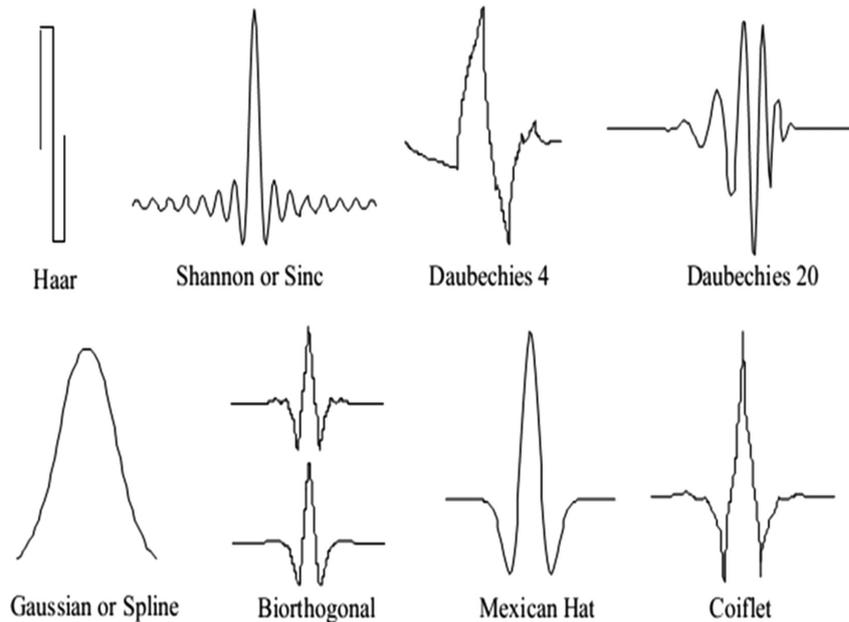
$$\psi(x) = \psi\left(\frac{x-b}{a}\right), (a, b) \in R^+ \times R,$$

variando a e b . Estas escolhas conectam as *wavelets* com análise de multirresolução em processamento de sinais.

A transformada de Fourier é localizada em frequência mas não no tempo, pequenas mudanças do sinal em frequência geram grandes mudanças do sinal no tempo. Já as *wavelets* são localizadas tanto no tempo (translações) quanto em frequência/escala (dilatações), o que é uma vantagem para diversos casos, já que é possível saber "quando" no tempo aquelas frequências estão acontecendo. O fator de escala representa o processo de alongar ou encolher uma função no tempo e ele é inversamente proporcional à frequência. Uma *wavelet* alongada ajuda a encontrar mudanças que variam lentamente em um sinal, enquanto a *wavelet* comprimida ajuda a capturar mudanças abruptas. Já a translação é quando o início da função é atrasado ou adiantado para que a *wavelet* fique alinhada com uma característica específica que se está buscando no sinal.

Além disso, as *wavelets* tendem a ser mais eficientes em relação à Fourier na análise de sinais não-periódicos e que contenham mudanças abruptas, como é o caso dos sinais de EEG, e a representação destes picos normalmente utiliza uma quantidade maior de senos e cossenos do que de funções *wavelets* para atingir uma aproximação semelhante. Estas características fazem das *wavelets* excelentes ferramentas para problemas de compressão de imagens, por exemplo (VIDAKOVIC; MUELLER, 1994). A Fig. 2.4 mostra vários tipos de *wavelets*.

Figura 2.4 – Tipos de funções Wavelet.



Fonte: (AL-GEELANI; PIAH; BASHIR, 2015)

2.5.1 Transformada *wavelet* de HAAR discreta

A *Wavelet* de Haar é a primeira e, por isso, a mais simples das *wavelets*, além de, possuir baixo custo computacional. Esta, é muito utilizada para compressão de imagens (MULCAHY, 1997; RAVIRAJ; SANAVULLAH, 2007; BHARDWAJ; ALI, 2009), mas também já foi utilizada para diagnóstico e detecção de epilepsia (FAUST et al., 2015), apneia do sono (KERMIT et al., 2000) e detecção de sonolência (LEE; LEE; CHUNG, 2014). A transformada *wavelet* discreta de Haar (do inglês Haar Discrete Wavelet Transform - Haar DWT), é ilustrada a partir do exemplo a seguir.

Considerando um vetor unidimensional de tamanho $2^j = 2^2$,

$$C_j = C_2 = [2 \ 0 \ 1 \ 9].$$

São calculados os valores médios, dois a dois, de acordo com,

$$C_{j-1,i} = \frac{C_{j,2i} + C_{j,2i+1}}{2}, \quad (2.1)$$

sendo $i = 0, 1, 2, \dots, 2^{j-1}$ a posição do novo vetor de informações médias (C_{j-1}). Para este exemplo tem-se $C_{j-1} = C_1 = [1 \ 5]$. Recuperar o vetor C_2 a partir de C_1 é impossível, devido a isso são guardadas também, as variações dos valores de C_2 em

relação a C_1 . Assim, D_{j-1} é o vetor que guarda informações de variações entre C_j e C_{j-1} , através de

$$D_{j-1,i} = C_{j,2i} - C_{j-1,i}, \quad i = 0, 1, 2, \dots, 2^{j-1}. \quad (2.2)$$

Neste exemplo $D_{j-1} = D_1 = [1 \ -4]$. Este processo de encontrar C_1 e D_1 se dá o nome de transformada Haar de um nível. O segundo nível é calculado a partir de C_1 e assim sucessivamente, sendo assim $C_{j-2} = C_0 = [3]$ e o vetor de detalhes fica $D_{j-2} = D_0 = [-2]$. Dessa forma, o vetor C_2 pode ser representado através do último valor de média, seguido por todas as informações de detalhe, sendo $[3 \ -2 \ 1 \ -4]$.

Além disso, para se realizar a recuperação do vetor C_j a partir de $[3 \ -2 \ 1 \ -4]$, utiliza-se

$$C_{j,2i} = C_{j-1,i} + D_{j-1,i}, \quad i = 0, 1, 2, \dots, 2^{j-1} \quad (2.3)$$

e

$$C_{j,2i+1} = C_{j-1,i} + D_{j-1,i}, \quad i = 0, 1, 2, \dots, 2^{j-1}. \quad (2.4)$$

O processo de decomposição de um sinal é visto como um conjunto de filtros passa-baixa e passa-alta, as frequências vão sendo filtradas a cada nível. Assim, para um sinal adquirido a 100 Hz, pelo teorema de Nyquist, que diz que só se pode representar frequências até a metade da frequência de amostragem, neste trabalho a frequência máxima é 50 Hz. As equações 2.5 e 2.6 representam formalmente o algoritmo para decomposição de um sinal em suas médias e detalhes, onde D é quantidade de filtros associados a *wavelet*, o qual é calculado por $D = 2 * M$, sendo que M representa a quantidade de momentos nulos da *wavelet* utilizada. A Haar *wavelet* possui apenas um momento nulo, portanto $D = 2$. Além disso, estes filtros podem ser não-normalizados ou normalizados (Tab. 2.1), o exemplo no início da seção utiliza filtros não-normalizados. A vantagem dos filtros normalizados é possibilidade de monitorar a quantidade de energia através dos níveis de decomposição que mais contribuem para a energia total do sinal, assim por este e outros benefícios este trabalho utiliza filtros normalizados (VIDAKOVIC; MUELLER, 1994).

$$C_{j-1,l} = \sum_{k=0}^{D-1} h_k \cdot C_{j,2l+k}, \quad l = 0, 1, 2, \dots, 2^{j-1} - 1 \quad (2.5)$$

$$D_{j-1,l} = \sum_{k=0}^{D-1} g_k \cdot C_{j,2l+k}, \quad l = 0, 1, 2, \dots, 2^{j-1} - 1 \quad (2.6)$$

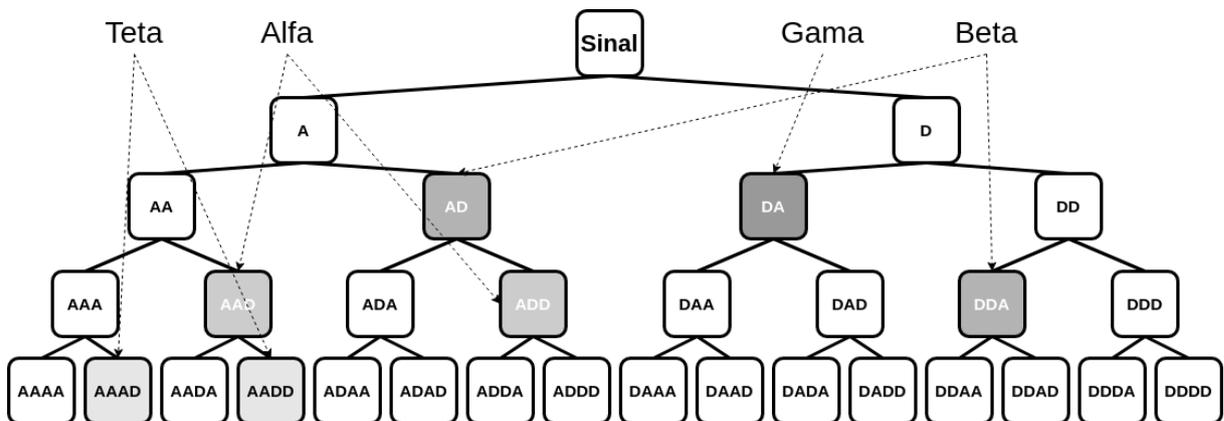
Neste trabalho, foi utilizada a DWT de Haar Packet. Esta transformada além de realizar a decomposição por níveis para os vetores de médias, são também decompostos os vetores de detalhes (EBRAHIMI et al., 2008). A Fig. 2.5 mostra a decomposição de um sinal em 4 níveis, sendo A o vetor de médias ou aproximações e D o vetor de detalhes, esta foi a configuração utilizada neste trabalho.

Tabela 2.1 – Filtros não-normalização e normalizados para a DWT de Haar.

k	Não-normalizados		Normalizados	
	h_k	g_k	h_k	g_k
0	$1/2$	$1/2$	$1/\sqrt{2}$	$1/\sqrt{2}$
1	$1/2$	$-1/2$	$1/\sqrt{2}$	$-1/\sqrt{2}$

Fonte: (VIDAKOVIC; MUELLER, 1994)

Figura 2.5 – DWT de Haar para um sinal em 4 níveis de decomposição. A são os vetores de médias ou aproximação e D os vetores de detalhes.



Fonte: Modificada de (EBRAHIMI et al., 2008)

2.6 EXTRAÇÃO DE ATRIBUTOS

A extração de características visa destacar informações relevantes para a identificação de padrões, por isso, é a tarefa mais difícil e mais importante no processamento de sinais (ZHU; LI; WEN, 2014). Atributos considerados eficientes podem destacar muito bem um padrão específico ou diferenciar padrões (CVETKOVIC; ÜBEYLI; COSIC, 2008), influenciando amplamente no desempenho do algoritmo de aprendizado de máquina (PECHENIZKIY et al., 2006). Uma pequena quantidade de informações relevantes pode obter melhor desempenho do que um conjunto de dados grande mas menos relevante (CVETKOVIC; ÜBEYLI; COSIC, 2008). Normalmente há redução de dimensionalidade após a extração de atributos, o que contribui para a redução do custo computacional para o algoritmo de aprendizado de máquina.

Existem quatro principais tipos de atributos que são extraídos do sinal de EEG para análise do sono: atributos temporais, espectrais, de tempo-frequência e atributos de me-

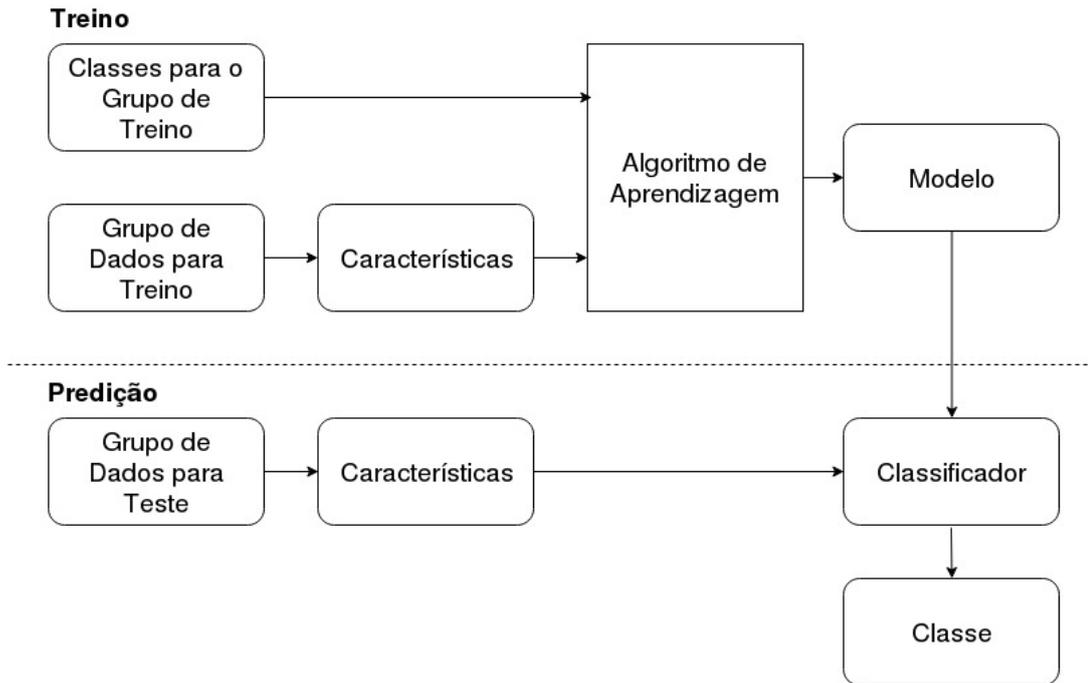
didadas não lineares / de complexidade. Apesar disso, a mais recorrente é a análise em frequência, devido a associação entre algumas faixas de frequências e os ritmos cerebrais. Os métodos mais comuns para extração de atributos em frequência são transformada de Fourier (do inglês Fast Fourier Transform - FFT), métodos de auto-regressão paramétricos e o método de Welch (KOLEY; DEY, 2012). Porém, como citado anteriormente as *Wavelets* são transformadas que, diferentemente desses métodos, permitem localização tanto no tempo quanto na frequência.

Assim, neste trabalho foram extraídas quatro faixas de frequência correspondentes aos ritmos teta, alfa, beta e gama através da transformada *packet* de Haar com 4 níveis (Fig 2.5). Para determinar quais dos pacotes representam cada ritmo cerebral foi realizado um experimento para medir a quantidade de energia para frequências entre 1 Hz e 30 Hz. Assim, para cada frequência foram determinados quais pacotes continham mais energia. A Fig. 2.5 mostra os pacotes selecionados para cada ritmo.

2.7 CLASSIFICAÇÃO

Classificação é o problema onde a partir de um conjunto de dados para treino e um conjunto de classes associadas, determina-se a qual destas classes um novo dado pertence. Muitas situações da vida real podem ser modeladas por problemas de classificação, como: enviar um e-mail para caixa de *spam* ou não, definir automaticamente se uma notícia é de esportes ou entretenimento e, diagnosticar uma doença em um paciente com base em características observadas nele (ex: gênero, pressão sanguínea, presença ou ausência de algum sintoma, etc). O processo de classificação pode ser dividido em duas etapas: treino e predição (Fig. 2.6). Classificação é um tipo de aprendizado de máquina supervisionado, ou seja, para a fase de treino o classificador recebe também a informação de qual classe cada dado pertence. O propósito é que a partir disso seja criado um modelo, o qual na fase de predição deve ser capaz de identificar a qual classe um novo dado pertence. Para isso, normalmente são separados dois grupos de dados um para treino e um para teste, além destes é comum também separar um grupo para validação, sendo que durante o processo de testes pode-se modificar parâmetros do classificador e portanto os dados não serão mais desconhecidos pelo modelo (AGGARWAL, 2014).

Figura 2.6 – Fluxo geral de um problema de classificação.



Fonte: Baseado em (AGGARWAL, 2014)

Diversos métodos de classificação já foram utilizados para o estudo do sono. Correa, Orosco e Laciari (2014), Boonnak, Kamonsantiroj e Pipanmaekaporn (2014) utilizaram redes neurais artificiais (do inglês Artificial Neural Networks - ANN), já He et al. (2014), Jalilifard e Pizzolato (2016) aplicaram o K-vizinhos mais próximos (do inglês K-Nearest Neighbors - KNN). As Máquinas de Vetores de Suporte (do inglês Support Vector Machines - SVM) também são muito recorrentes (MU; HU; MIN, 2017; OGINO; MITSUKURA, 2018; ABOALAYON; OCBAGABIR; FAEZIPOUR, 2014). Samiee et al. (2015), Sharma, Pachori e Upadhyay (2017) empregaram florestas aleatórias (do inglês Random Forest - RF) e Marcos et al. (2010) o LDA (do inglês Linear Discriminant Analysis). Assim, as próximas seções descrevem as principais características de cada um deles.

2.7.1 Redes Neurais Artificiais (ANN)

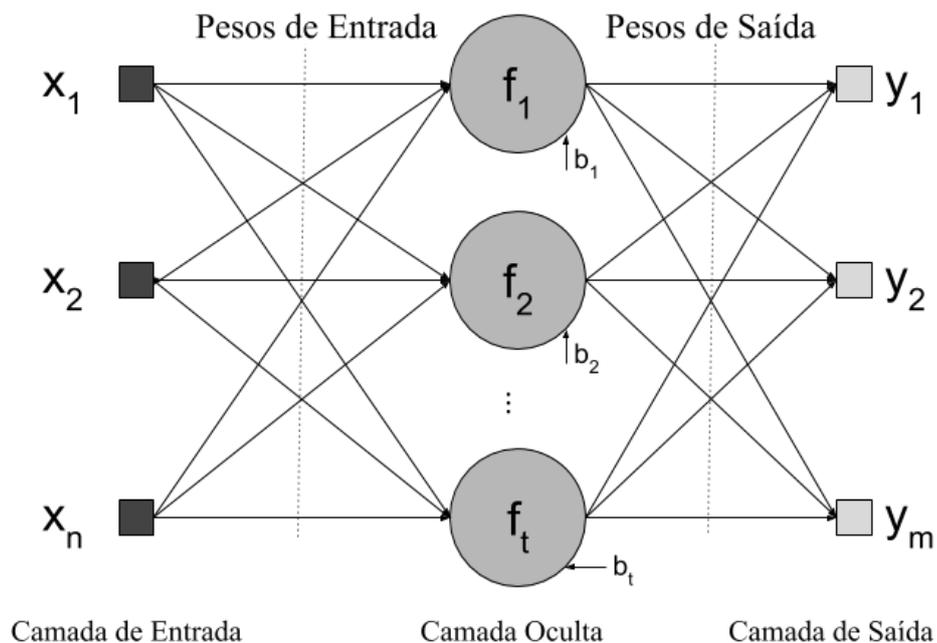
As redes neurais são métodos de aprendizagem baseados no funcionamento de células neurais, com a capacidade de reconhecimento de padrões em dados não lineares (HSU; GUPTA; SOROOSHIAN, 1995). Estas, são construídas a partir de três principais camadas de neurônios, sendo: camada de entrada, camadas ocultas e camada de saída. A camada de entrada possui um neurônio para cada variável de entrada. Já a quantidade de neurônios em cada camada oculta é um parâmetro a ser definido, pois estes repre-

sentam a quantidade de divisões necessárias para a separação das classes. Porém, um número grande pode gerar *overfitting*, quando o modelo fica muito ajustado ao conjunto de treino e se torna ineficiente para novos dados. A camada de saída contém o número de neurônios necessários para representar as classes, por exemplo se houver duas classes (0 ou 1), somente um neurônio de saída será necessário para a classificação. Existem vários tipos de redes neurais, a Figura 2.7 mostra um exemplo de uma *feed-forward multi-layer perceptron* (MLP). A rede neural perceptron é a mais simples das redes neurais e a MLP é uma variação da mesma com múltiplas camadas. Para cada neurônio oculto é realizada a soma entre cada valor de entrada (atributos) multiplicado pelo seu peso, além do limiar de ativação b_t . Na sequência, é aplicada uma função de ativação (f), como a *sigmoid*, por exemplo. Por fim, estes valores são multiplicados pelos pesos de saída, encontrando o valor de y , como mostra as Equações 2.7 e 2.8 (BOOSTANI; KARIMZADEH; NAMI, 2017; GARDNER; DORLING, 1998).

$$y_m = \sum_{k=1}^t W_{km}^{(2)} f_k \quad (2.7)$$

$$f_k = (W_{nk}^{(1)} x_n + b_k) \quad (2.8)$$

Figura 2.7 – Redes Neurais - *feed-forward multi-layer perceptron* (MLP).

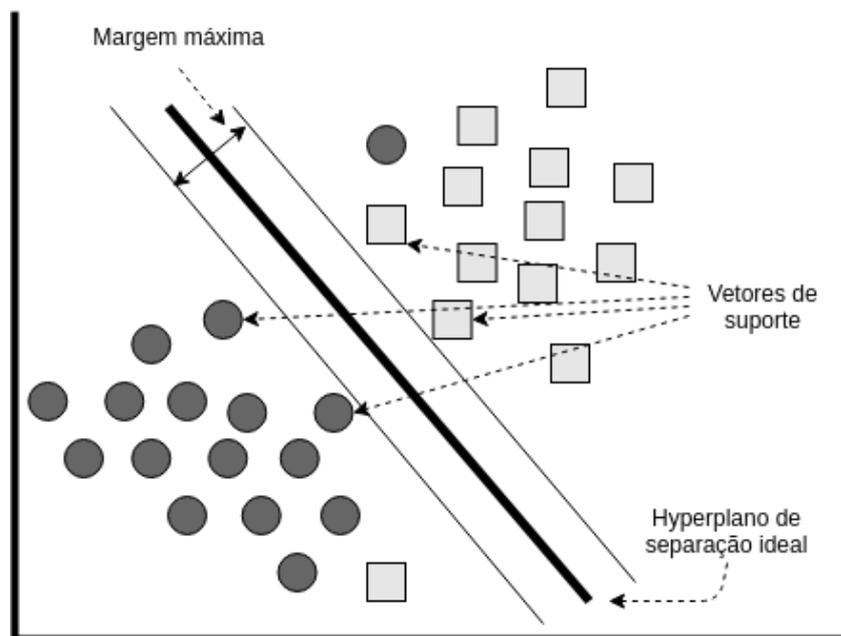


Fonte: Modificada de (BOOSTANI; KARIMZADEH; NAMI, 2017)

2.7.2 Máquinas de Vetores de Suporte (SVM)

A SVM é um método supervisionado para classificação, existem também a variante *Support Vector Regression (SVR)* para regressão. A SVM linear utiliza os pontos que formam as margens entre duas classes, chamados vetores de suporte, para determinar o melhor hiperplano que as separa. O melhor hiperplano é aquele que maximiza a distância de margem, ou seja, a distância entre os vetores de suporte e o hiperplano. A SVM também permite que hajam amostras classificadas erroneamente para evitar *overfitting* e *outliers* (Fig. 2.8). Ainda, para dados de difícil separação diretamente, a SVM realiza uma transformação dos atributos para um espaço de dimensionalidade superior através de *kernels*, assim dados que antes eram impossíveis de se separar com curvas simples agora podem ser separados por uma superfície linear. A Figura 2.9 mostra dados originalmente em duas dimensões sendo projetados em 3D, de uma forma que possibilite a criação de uma superfície para separação das classes. Os kernels mais comuns são o *radial basis function (RBF)*, polinomial e sigmoideal (WANG, 2005; JAIN, 2018).

Figura 2.8 – Maximização da margem com as Máquinas de Vetores de Suporte (SVM).

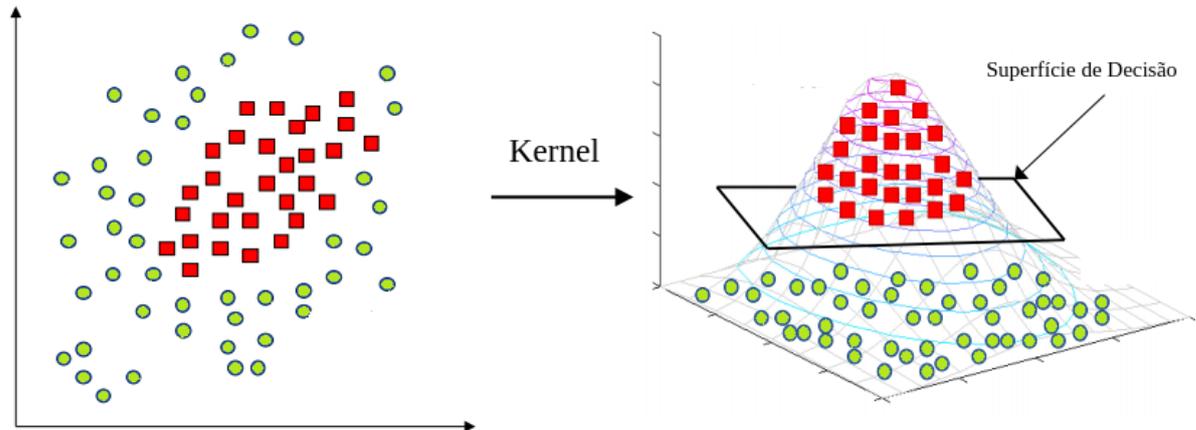


Fonte: Modificada de (JAIN, 2018)

2.7.3 k-Vizinhos mais Próximos (kNN)

O método de classificação kNN se baseia em similaridade entre atributos. A partir de um critério, normalmente através da distância euclidiana, são selecionados k vizinhos

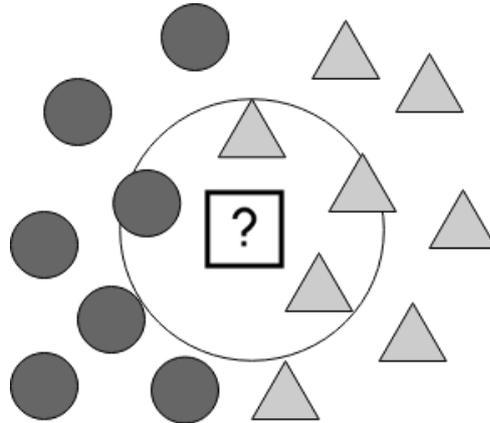
Figura 2.9 – Mudança de dimensão das Máquinas de Vetores de Suporte (SVM).



Fonte: Modificada de (JAIN, 2018)

mais próximos. No caso de regressão, é realizada a média dos valores dos vizinhos mais próximos (NAVOT et al., 2006). No caso de classificação, determina-se a qual classe aquele dado pertence através de uma votação, ou seja, a classe que mais aparece entre os vizinhos (YAO; RUZZO, 2006). A Fig. 2.10 mostra um exemplo de predição para $K=4$, considerando um novo dado, dentre os seus 4 vizinhos mais próximos a classe mais recorrente é a classe do formato triângulo, assim o novo dado será classificado como pertencente desta classe. A escolha de k pode ser feita utilizando a raiz quadrada do número de pontos, além de que, para casos de duas classes, por exemplo, o valor deve ser ímpar e, no geral, k não deve ser múltiplo do número de classes. O kNN é usado para aprendizado supervisionado, quando os dados não possuem ruído e com um conjunto de dados que não seja muito grande e complexo (THEODORIDIS; KOUTROUMBAS et al., 2008). Isso porque, diferente dos outros classificadores citados, o KNN não gera um modelo após o treinamento, aos invés disso, todas as amostras de treino são guardadas, o que pode gerar alto consumo de memória (RASCHKA; MIRJALILI, 2017).

Figura 2.10 – Classificador k-Vizinhos mais Próximos.



Fonte: Baseado em (RASCHKA; MIRJALILI, 2017).

2.7.4 LDA

O *Linear Discriminant Analysis* (LDA) é um método para redução de dimensionalidade, assim como o PCA busca por relações lineares. Este, é utilizado quando tem-se variáveis independentes contínuas e variáveis dependentes categóricas (classes). Baseado na discriminação linear de Fisher (do inglês Fisher's linear discriminant), o objetivo é maximizar a distância entre as classes e minimizar a distância entre os elementos de cada classe, de acordo com

$$\frac{(\mu_1 - \mu_2)^2}{S_1^2 + S_2^2}, \quad (2.9)$$

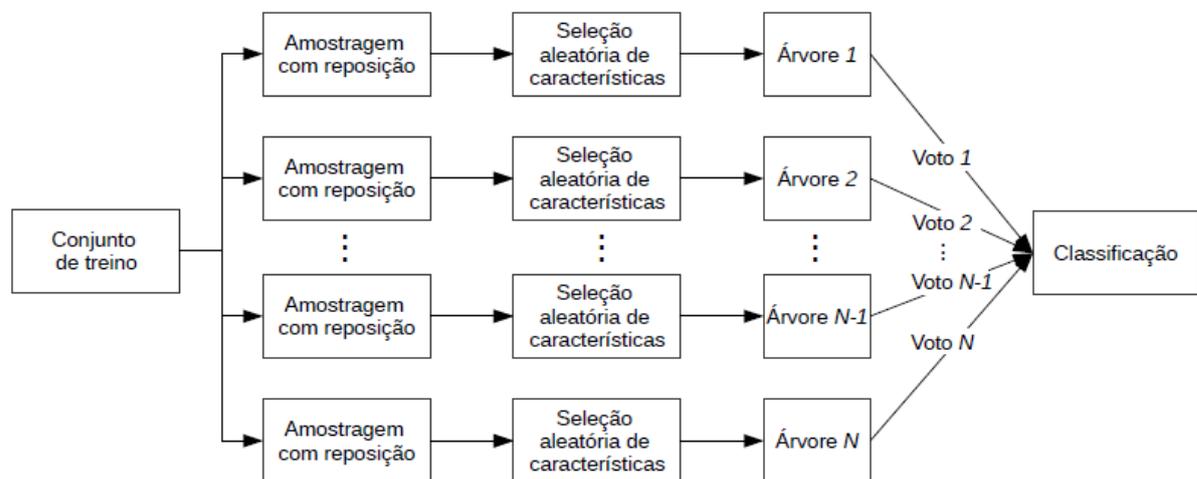
onde μ_1 é o valor médio dos elementos da classe 1, μ_2 média dos elementos da classe 2, S_1 é a variância dos elementos da classe 1 e S_2 é a variância dos elementos da classe 2. Para os casos com mais de duas classes, a média total é calculada e a diferença entre esta e a média de cada classe é medida (FRAIWAN et al., 2010).

2.7.5 Florestas Aleatórias (RF)

O classificador florestas aleatórias é um *ensemble* do tipo *bagging* onde, na etapa de treino, cada método de aprendizado (todos em paralelo) seleciona aleatoriamente e com reposição um conjunto de amostras e de *features* (DIETTERICH, 2000; OPITZ; MACLIN, 1999). Normalmente em torno de 63.2% dos dados selecionados por um método não é repetido. Assim, cada método gera o seu resultado, se for classificação o resultado final

será por votação, caso seja regressão será realizada uma média das respostas (GALAR et al., 2011). O RF é formado por um conjunto de árvores de decisão. As árvores de decisão guardam regras em seus nós e as classes são representadas pelos nós folhas, no caso de classificação. No treino a árvore vai sendo construída conforme os dados vão sendo subdivididos de forma mais homogênea possível, ou seja, espera-se que cada subdivisão contenha dados de apenas uma classe. Esta característica na construção pode levar a um modelo de grande variância, ou *overfitting*, o que pode ser evitado com *ensembles* como o RF. A construção de uma floresta aleatória é feita como mostra a figura 2.11. Segundo BREIMAN (2001) a combinação dos conjuntos com redundância e a seleção aleatória das características aumenta o desempenho do classificador tornando-o mais robusto a ruídos.

Figura 2.11 – Classificador florestas aleatórias.



Fonte: Modificado de (FRAIWAN et al., 2012)

2.7.6 Threshold

Os *Thresholds* já foram muito utilizados como classificadores por serem fáceis de interpretar e simples de implementar, inclusive em hardware, além de que, na maioria das vezes, possuem baixo custo computacional. A partir disso, alguns trabalhos criaram índices, os quais são uma relação entre medidas formando um *threshold* para determinar o começo e o fim de cada classe. Belakhdar et al. (2018) criou dois índices: $\frac{Teta}{Alfa}$ e $\frac{[3-4]}{Alfa}$, assim como, Arnin et al. (2013) que criou uma relação entre $\frac{0.6Teta+0.4Alfa}{0.5Beta}$.

Em geral, é comum utilizar relações de divisão para índices, porém para o desenvolvimento de um hardware, a divisão se torna custosa. A partir disso, Baldissera (2015)

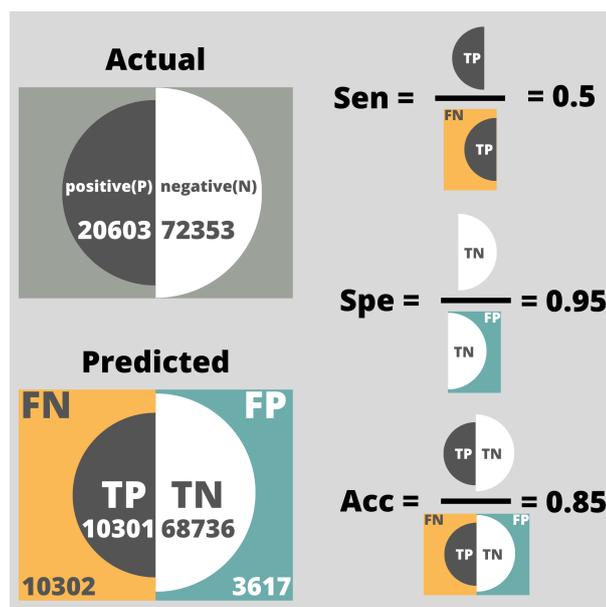
propôs um índice utilizando subtração, sendo este $Teta - 2Beta$. Em um trabalho seguinte, Retamal (2018) testou o índice com os mesmos sujeitos utilizados neste trabalho, alcançando 82.2% de sensibilidade. Assim, neste trabalho será estudada a capacidade de detecção de sonolência deste índice em ambientes mais realistas, contendo ruído, além de comparar sua performance com os classificadores do estado da arte para detecção de sonolência. Além das vantagens já citadas para se utilizar um *threshold*, o índice utiliza apenas duas características do sinal (Teta e Beta).

2.7.7 Métricas de Avaliação

Quadro 2.2 – Matriz de confusão para duas variáveis (positivo (P) e negativo (N)).

		Predito	
		P	N
Verdadeiro	P	VP	FN
	N	FP	VN

Figura 2.12 – Exemplo de um problema com duas classes, considerando um problema desbalanceado. Amostras oriundas do Physionet, sendo a classe P amostras anotadas como "S1" e "S2" e a classe N como "W". São calculadas a Sensibilidade (Sen), Especificidade (Esp) e Acurácia (Acc).



Métricas são a forma de avaliar a performance do algoritmo de aprendizado. A escolha da métrica errada pode levar a interpretações falsas da performance do sistema, tanto por encontrar um resultado superior a capacidade real do sistema, quanto inferior (DAVIS et al., 2007). A matriz de confusão organiza os acertos e erros para problemas de classificação. A Tabela 2.2 mostra o exemplo de uma matriz de confusão para duas variáveis ou classes, temos as classes positivo (P) e negativo (N). Por convenção a classe P é considerada a classe alvo, sendo para este trabalho a classe sonolência. Assim, os verdadeiros positivos (VP) são aquelas amostras preditas corretamente como sonolência. Assim como, os verdadeiros negativos são as amostras preditas corretamente como acordado. Já os falsos positivos (FP) são aquelas preditas como sonolência porém eram acordado, assim como, falsos negativos (FN) são aquelas que foram preditas como acordado, mas eram sonolência (VISA et al., 2011).

A métrica mais simples é a taxa de acerto ou acurácia (Acc), Eq. 2.10, ela mede a razão entre o número de acertos e o número total de predições, a partir da matriz de confusão. Porém, a medida da Acc nem sempre expressa a performance real do sistema para todas as classes. Isso porque, para casos em que os dados são muito desbalanceados (TAN, 2005), ou seja, que não se tem a mesma quantidade de amostras para cada classe, é possível que o sistema tenha uma boa acurácia para detectar apenas uma das classes e não todas. Kayikcioglu, Maleki e Eroglu (2015), Li, Jiang e Su (2016) usaram apenas Acc para medir a performance (91% e 98.8% respectivamente), apesar destes disponibilizarem a quantidade de amostras por classe, a performance por classe não foi apresentada, o que nega ao leitor uma perspectiva geral do sistema. É possível perceber o impacto disto, em He et al. (2014), já que através da matriz de confusão fornecida pode-se calcular uma Acc de 84%, sendo que a capacidade de detectar sonolência (sensibilidade) foi de apenas 68.31%. A Fig. 2.12 mostra um exemplo de classes desbalanceadas e o impacto nas métricas de avaliação. Assim, outras duas medidas que ajudam a explicar com mais detalhes os resultados, e por isso são muito utilizadas em conjunto com a acurácia, são a sensibilidade e a especificidade. A primeira, representa a quantidade de acertos obtidos para a classe positivo em relação a todos os dados verdadeiramente da classe positivo (Eq. 2.11) e, a segunda, mostra a relação entre os dados preditos corretamente como negativo em relação a todos os dados verdadeiramente da classe negativo (Eq. 2.12). Neste trabalho, serão calculadas acurácia, especificidade e sensibilidade para todas as análises realizadas.

$$Acc = \frac{VP + VN}{VP + FN + VN + FP} \quad (2.10)$$

$$Sen = \frac{VP}{VP + FN} \quad (2.11)$$

$$Esp = \frac{VN}{VN + FP} \quad (2.12)$$

Tabela 2.2 – Principais características dos estudos revisados.

Ref.	Subj.	Electrode	Feature set	Predictor	Performance
(CORREA; OROSCO; LACIAR, 2014)	16	C3-O1	CF, IEEG α , Q1F, MaxF, IEEG θ , AC, STD	ANN	Alert=87.4%, Drowsy=83.6%
(HE et al., 2014)	6	Fp1	Attention, meditation	kNN	Spec=68.31%, Sen=90.43%
(LI; CHUNG, 2014)	20	O2	α power percentage	Regression	Acc=87.5%(M), 70%(F) MSE=0.013
(HAL et al., 2014)	3	Fp1	Mean and STD of α, β power	Threshold	Acc=81%
(KAYIKCIOGLU; MALEKI; EROGLU, 2015)	7	Pz-Cz	22 AR coef. from θ, α, β	PLS	Acc=91%
(KO et al., 2015)	15	Ch-1	$\theta, \alpha, \beta, \delta$ power	Regression	Acc=90%
(LI; LEE; CHUNG, 2015)	20	O1, O2	θ, α, β power	SVMPPM	Alert=91.25%, Early- warning=83.78%, Drowsy=91.92%
(SILVEIRA; KOZAKEVICIUS; RODRIGUES, 2015)	13	Fpz	α, β from Daubechies Wavelet	Threshold	Sen=84.9%, Pre=98.6%
(LI; JIANG; SU, 2016)	59	Fp1	21 features (PSD, DWT, Time)	DBN	Acc=98.86%
(PATRICK et al., 2016)	20	Cz-A1	δ, α power, center freq.	Threshold	Sen=94.9%, Sen=85%, Spe=93.3%
(QIAN et al., 2016)	25	C3-A2, C4-A1, O1-A2, O2-A1	Ratio, Amplitude, Symmetry, Ex- tention of θ, α and electrodes	BCDC	Acc=94.3%, Drowsy=98.1%
(KARTSCH et al., 2017)	7	Fpz-Oz	α and Blink duration	Threshold	Acc=85%
(MU; HU; MIN, 2017)	12	T5, TP7, TP8, Fp1	SpeEn, ApEn, SampEn, FuzzyEn	SVM(RBF)	Acc=98.75%, MCC=93.51%, Sen=96%, Spe=97.5%
(BELAKHDAR et al., 2018)	10	C3-O1	Mean power in 3,4, mean power ratio in IAF, $[3 - 4]/\alpha, \theta/\alpha$	ANN	Drowsy=89%, Embed- ded=84.29%
(HU; MIN, 2018)	22	TP7	SpeEn, ApEn, SampEn, FuzzyEn	GBDT	Acc=94%

Fonte: Autora.

3 REVISÃO DE LITERATURA

Esta seção apresenta a revisão de literatura realizada buscando trabalhos que foram selecionados com base na seguinte *string* de busca: "(\"EEG\" OR \"electroencephalogram\" OR \"electroencephalography\") AND (\"sleepiness\" OR \"drowsiness\" OR \"fatigue\" OR \"drowsy\" OR \"sleep\") AND (\"prediction\" OR \"detection\" OR \"classification\")". Os trabalhos foram buscados nas seguintes bases: Scopus, IEEExplorer, Science Direct, ACM, Google Scholar, de 2013 à 2018. Foram excluídos os trabalhos que:

- Utilizaram outros sinais fisiológicos;
- Utilizaram muitos eletrodos (mais do que 4);
- Não possuíam o objetivo de detecção e classificação para aplicações de tempo real;
- Não deixaram claras as etapas de processamento.

A Tab. 2.2 exibe as principais informações dos trabalhos revisados. A coluna "Ref." possui o trabalho citado, na coluna "Subj." são mostrados a quantidade de sujeitos utilizados, "Electrode" mostra quais foram os eletrodos usados, "Feature set" mostra os atributos extraídos do sinal de EEG, "Predictor" indica os algoritmos de aprendizagem usados e "Performance" mostra as métricas de avaliação e quais valores foram encontrados para elas.

Os estudos podem ser divididos em dois principais grupos: aqueles que utilizaram sinais oriundos de bancos de dados públicos e aqueles que realizaram um experimento para aquisição dos sinais. Assim nas próximas seções são apresentadas as principais características dos trabalhos revisados separando-os nestes dois grupos.

3.1 ESTUDOS UTILIZANDO BASES DE DADOS PÚBLICAS

As vantagens de se utilizar sinais de uma base pública é a possibilidade de se obter sinais, normalmente, confiáveis e adquiridos por um profissional, o qual realiza anotações nos dados. Além disso, a utilização de dados disponíveis publicamente permite a comparação entre trabalhos, contribuindo para a pesquisa.

Uma das principais fontes de dados públicos é o Physionet. Ele fornece bases de dados contendo aquisições de diversos sinais fisiológicos. Correa, Orosco e Laciari (2014) e Belakhdar et al. (2018) usaram sinais da base de dados MIT-BIH Polysomnographic. O primeiro segmentou os sinais em épocas de 5 s (10.074 épocas para sonolência e 10.074

épocas para acordado). Em seguida, foram extraídas características no tempo, na frequência e por decomposição *Wavelet*, sendo que após uma seleção das melhores restaram 7 atributos. Em alguns casos, o sistema foi capaz de detectar sonolência antes do sujeito estar sonolento, obtendo 87.4% de acurácia para detecção de sonolência. Já o segundo estudo, removeu artefatos dos sinais com um filtro passa-banda de 0.5-30 Hz e em seguida extraiu atributos em frequência a partir do cálculo da FFT. Dentre os atributos, o trabalho criou índices com algumas frequências correspondentes aos ritmos cerebrais, além de que, utilizou a frequência de alfa individual (do inglês Individual Alpha Frequency - IAF) para contornar o problema de invariabilidade entre indivíduos. O estudo também comparou a performance dos classificadores ANN e SVM constatando que a ANN possui melhor performance, a qual foi de 89% de acurácia. Além disso, os autores embarcaram a metodologia em uma *Raspberry Pi* para obter resultados mais próximos da aplicação real, a qual obteve 84.29% de acurácia e processou épocas de 30 s em 0.20 s.

Silveira, Kozakevicius e Rodrigues (2015) também utilizaram sinais do Physionet. Nesse trabalho, 6 h 50 min de dados de um único eletrodo (Fpz) foram usados para estimar os ritmos alfa e beta através da *Wavelet* de *Daubechies*. Os autores sugerem um algoritmo para aproximar os m melhores coeficientes da *Wavelet* para representar os ritmos citados. Com um *Threshold* este trabalho obteve 84,98% de sensibilidade e 98,65% de especificidade, concluindo que alcançaram maior desempenho com menor complexidade quando comparados aos trabalhos relacionados na época. Outro estudo (KAYIKCIOGLU; MALEKI; EROGLU, 2015) comparou dois canais e quatro classificadores, com um conjunto de 22 coeficientes de auto-regressão, decompostos pelo método Burg para alfa, teta e beta separadamente, gerando um *ensemble*. Os métodos *partial least squares regression* (PLS), o K-vizinhos mais próximos (do inglês K-Nearest Neighbors - KNN), *linear discriminant classifier* LDC e Bayes foram comparados e o PLS alcançou o melhor desempenho. Esse estudo é capaz de processar os sinais e prever sonolência com menos de 1 s.

DREAMS (MONS, 2015) também é uma base de dados pública, que contém sinais de 20 sujeitos. A partir disso, Patrick et al. (2016) extraiu características do espectro de frequência (do inglês Power Spectral Density - PSD) e medidas estatísticas para cada época de 1 s, após uma seleção de atributos a frequência central, a potência relativa de delta e de alfa foram os mais significativos. Para classificação, os autores realizaram um *ensemble* com *Thresholds* para cada atributo, destacando a importância de um preditor adaptativo para contornar o problema da invariabilidade interpessoal.

3.2 ESTUDOS QUE INCLUEM A AQUISIÇÃO DE DADOS

Muitas vezes, o protocolo de aquisição dos bancos de dados públicos pode não representar de forma tão próxima o ambiente da vida real onde o sistema deve operar.

Assim, muitos estudos decidiram organizar experimentos para adquirir os sinais.

Com um simulador de direção, Mu, Hu e Min (2017) adquiriram sinais de 12 sujeitos. Após 40 minutos, os sujeitos responderam aos questionários de *Li's* e *Borg's CR-10 scale*, que medem a sonolência do sujeito naquele momento. Em seguida, os autores realizaram uma seleção dos eletrodos através do cálculo da distância de Fisher. Hu e Min (2018) também adquiriram sinais de EEG utilizando um simulador de direção. Os autores extraíram atributos de entropia e compararam os classificadores no estado da arte, atingindo Acc de 94%. Em (KO et al., 2015), o carro eventualmente se afastava da pista original e os 15 sujeitos foram instruídos a retornar à posição inicial o mais rápido possível. O sistema registra o tempo de reação do sujeito junto com seus sinais de EEG. O tempo de reação é uma característica relevante, pois à medida que o indivíduo fica sonolento, seu reflexo se torna mais lento. Este trabalho também utilizou um EEG vestível com apenas 1 eletrodo para adquirir os sinais. Alguns estudos utilizaram este equipamento por ser compacto, com poucos eletrodos e permitirem mobilidade ao sujeito.

A maioria dos EEG vestíveis possuem alguns atributos já pré-processados. Assim, He et al. (2014) utilizaram os atributos de atenção e meditação provenientes do equipamento da Neurosky, os quais foram enviados via Bluetooth para um telefone Android, onde é calculado o coeficiente de correlação entre os atributos e a identificação do estado do sujeito acontece. Quando a sonolência é identificada, o telefone envia um alerta para o *bus monitor* ou *bus schedule center*. Este estudo obteve 345 amostras de 5 segundos para o estado acordado e 142 para estado de sonolência. Ainda, Hal et al. (2014) e Li, Jiang e Su (2016) também utilizaram esse tipo de sistema, ambos com um único eletrodo. O primeiro extraiu características estatísticas de densidade espectral (do inglês Power Spectral Density - PSD) e, por um *Threshold* adaptativo, obteve 81% de Acc. Este sistema foi implementado em uma plataforma Arduino, responsável pelo processamento do sinal. Quando a sonolência é detectada, um alarme é acionado. O segundo adquiriu sinais de 59 voluntários em diferentes períodos do dia. Os voluntários responderam ao questionário *Fatigue Scale-14* para determinar seus níveis de sonolência. No entanto, a fadiga pode ser uma característica abstrata para algumas pessoas, o que pode levar a uma classificação falsa. Este estudo obteve 98.86% de Acc com uma *Deep Belief Network (DBN)*. Apesar disso, os autores utilizaram apenas a acurácia como métrica de avaliação, sendo que esta não mede a performance para cada classe, além de que, não disponibilizaram a matriz de confusão com os acertos e erros por classe. Os sinais adquiridos e utilizados no estudo também não foram disponibilizados publicamente para comparação.

Ainda, Li, Lee e Chung (2015) desenvolveram um EEG vestível com 3 eletrodos secos. Os dados são enviados para um *smartwatch* onde o sinal é processado e, se necessário, um alerta é acionado. O classificador foi treinado no computador e o modelo foi transferido para o *smartwatch*. As classes foram criadas a partir de vídeos do comportamento do sujeito, gravados durante o experimento, alcançando 91.92% de Acc. Além

disso, Qian et al. (2016) adquiriram sinais de 25 indivíduos durante cochilos diurnos. O IAF foi utilizado para aproximar as bandas alfa e teta da seguinte forma: $IAF - \theta$ e $IAF - \alpha$, isto porque as faixas de frequência onde aparecem os ritmos podem variar de sujeito para sujeito. Os autores testaram a metodologia em tempo real e um sinal de 20 s pode ser processado em 2 s.

Alguns trabalhos investigaram a possibilidade de usar o sinal de EEG para substituir as metodologias baseadas em vídeo. Kartsch et al. (2017) desenvolveram um sistema embarcado para monitorar a duração da piscada dos olhos e o acúmulo de ondas alfa dos sujeitos, ou seja, a partir de um *threshold* é identificado um pico de onda alfa se houver mais de 5 segundos de ondas alfas acumuladas é considerado um indicador de sonolência. Os autores também relataram que o sistema pode operar por até 7.1 horas com uma bateria de 200mAh. Já Li e Chung (2014) encontraram uma relação linear entre EEG e o grau de fechamento palpebral (do inglês eyelid closure degree - ECD) mostrando a possibilidade de substituir sistemas baseados em vídeo para monitoramento palpebral. Os autores encontraram que a combinação de ritmo alfa e eletrodo de O2 foi a mais relevante para a regressão linear escolhida.

3.3 TRABALHOS RELACIONADOS E PROPOSTA DO TRABALHO

Para que um sistema seja capaz de detectar sonolência em situações como as citadas na seção anterior, onde o usuário está dirigindo ou realizando alguma tarefa que exige sua atenção, é necessário que este monitore o usuário constantemente, ou seja, realize processamento dos sinais em tempo real, conseqüentemente que haja baixo custo computacional, além de que, o sistema deve permitir mobilidade ao usuário.

A partir dos trabalhos revisados, percebeu-se que He et al. (2014), Hal et al. (2014), Li, Jiang e Su (2016), Kayikcioglu, Maleki e Eroglu (2015) e Belakhdar et al. (2018) são os trabalhos que mais buscaram desenvolver um sistema com estas características citadas, por isso será realizada uma comparação destes e da metodologia proposta. Diversos trabalhos utilizaram um EEG vestível para a aquisição dos sinais, porém não disponibilizaram os dados nem avaliaram os sinais capturados com este equipamento. A partir disso, este trabalho tem como objetivo propor uma metodologia para detecção de sonolência em tempo real, utilizando um EEG vestível.

4.1 EXPERIMENTO PARA AQUISIÇÃO

Para as análises realizadas, os sinais foram divididos aleatoriamente em 3 grupos: treino, teste e validação. O primeiro grupo possui sinais de 11 voluntários (51.767 épocas) e os outros possuem 4 voluntários cada (18.909 épocas para teste e 19.433 para validação), nenhum dos grupos compartilha sinais do mesmo sujeito. Com isso, para treino foram utilizadas em torno de 440 horas de sinal e para cada um dos outros grupos, 160 horas de sinal. O treino dos classificadores foi realizado offline, ou seja, no computador, utilizando os sinais do banco de dados.

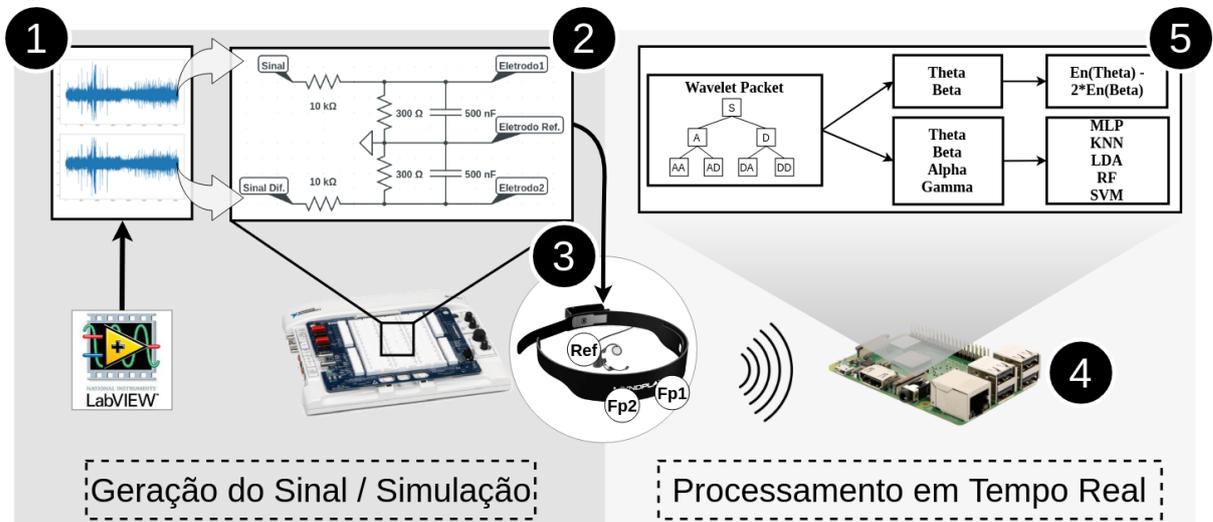
A partir disso, três experimentos foram realizados: leitura e processamento do sinal com o EEG vestível, comparação de performance do sinal lido pelo EEG e do mesmo sinal sendo processado diretamente do banco de dados e, avaliação da performance utilizando todas as amostras de teste e validação.

Para o primeiro experimento, já que se tem o objetivo de simular uma aquisição e processamento de sinais de EEG em tempo real, não seria viável fazer a leitura de todo o conjunto de dados. Assim, para cada sujeito de teste e validação, foram separadas 2 horas de sinal, o que corresponde a 240 épocas de 30 segundos. Cada sujeito possui dois arquivos de sinais gravados em duas noites de sono, dessa forma, para cada arquivo foram selecionadas 120 épocas de transição (60 do sujeito acordado seguidas de 60 do sujeito sonolento). Ao final cada grupo contém 960 épocas. Este experimento também tem o objetivo de avaliar a qualidade do sinal adquirido pelo EEG vestível considerando os ruídos do ambiente, ou seja, obter resultados para uma aplicação mais próxima da realidade. A utilização do banco de dados para este experimento permite que sinais de diversos sujeitos sejam utilizados para as análises. A Fig. 4.2 ilustra o experimento. A primeira etapa é a leitura do arquivo do sinal pelo Labview 2016 em formato diferencial para consequente aquisição em duas derivações (FP1 e FP2), em seguida estes vão sendo enviados (a 100 Hz) para duas saídas do Elvis II, onde é conectado um circuito para redução da amplitude do sinal e filtragem de altas frequências. É necessário realizar esta redução pois o EEG vestível adquire amplitudes de até 2 mV. Em seguida, as saídas do circuito são ligadas nos eletrodos do EEG vestível, e via bluetooth o sinal é enviado para a raspberry pi, onde é processado.

O segundo experimento, utiliza os mesmos sinais separados para o experimento anterior, com o objetivo de comparar a performance. Neste caso, os dados do banco de dados foram dados diretamente para a etapa de processamento, como ilustra a Fig. 4.3.

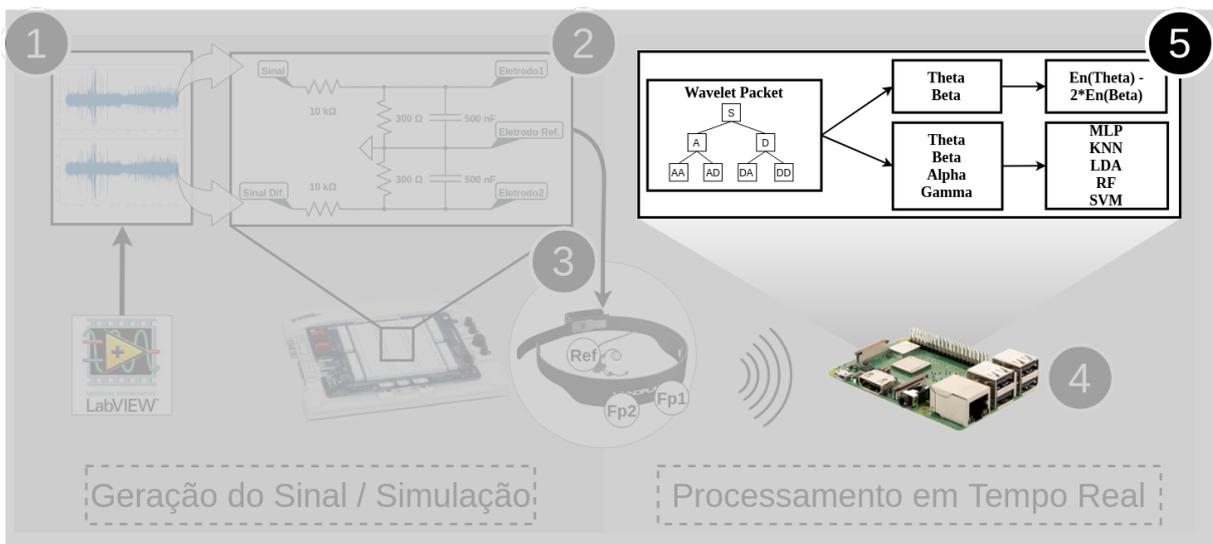
A última análise foi realizada para que se possa avaliar a performance da metodologia proposta através de um conjunto maior de amostras. Assim, utilizando todas as amostra dos grupos de teste e validação, foram medidas as performances para cada classificador.

Figura 4.2 – Fluxograma geral de processamento com EEG vestível.



Fonte: Autora.

Figura 4.3 – Fluxograma geral de processamento para comparação com sinais adquiridos pelo EEG vestível.



Fonte: Autora.

4.2 ESPECIFICAÇÕES DE HARDWARE E SOFTWARE

Neste trabalho, todas as análises foram realizados em um sistema linux Ubuntu versão 18.04, na linguagem de programação Python versão 2.7. A Tab. 4.1 mostra quais foram os parâmetros utilizados para cada classificador, sendo todos os classificadores oriundos da biblioteca Sklearn, na versão 0.20.4.

Para o experimento de aquisição construído, foram utilizados o NI Elvis II (especificações em: <http://www.ni.com/pdf/manuals/372590b.pdf>) e o Labview 2016 (especificações em:

<http://www.ni.com/pdf/manuals/371780m.pdf>).

Tabela 4.1 – Especificações de software usados em Python 2.7 e biblioteca sklearn 0.20.4.

Classificador	Parâmetros
MLPClassifier	activation='relu', alpha=1, batch_size='auto', beta_1=0.9, beta_2=0.999, early_stopping=False, epsilon=1e-08, hidden_layer_sizes=(100,), learning_rate='constant', learning_rate_init=0.001, max_iter=200, momentum=0.9, n_iter_no_change=10, nesterovs_momentum=True, power_t=0.5, random_state=None, shuffle=True, solver='adam', tol=0.0001, validation_fraction=0.1, verbose=False, warm_start=False
KNeighborsClassifier	algorithm='auto', leaf_size=30, metric='minkowski', metric_params=None, n_jobs=None, n_neighbors=15, p=2, weights='uniform'
LinearDiscriminantAnalysis	n_components=None, priors=None, shrinkage=None, solver='svd', store_covariance=False, tol=0.0001
RandomForestClassifier	bootstrap=True, class_weight='balanced', criterion='gini', max_depth=16, max_features='auto', max_leaf_nodes=None, min_impurity_decrease=0.0, min_impurity_split=None, min_samples_leaf=1, min_samples_split=2, min_weight_fraction_leaf=0.0, n_estimators=64, n_jobs=None, oob_score=False, random_state=None, verbose=0, warm_start=False
SVC	C=1.0, cache_size=200, class_weight='balanced', coef0=0.0, decision_function_shape='ovr', degree=3, gamma='auto', kernel='rbf', max_iter=-1, probability=False, random_state=None, shrinking=True, tol=0.001, verbose=False

Fonte: Autora.

5 RESULTADOS

Nesta seção serão apresentados os resultados obtidos a partir das análises realizadas comparando performances da aquisição e processamento em tempo real, além de, análise do sinal do EEG vestível, de tamanhos de épocas distintas e comparação entre classificadores.

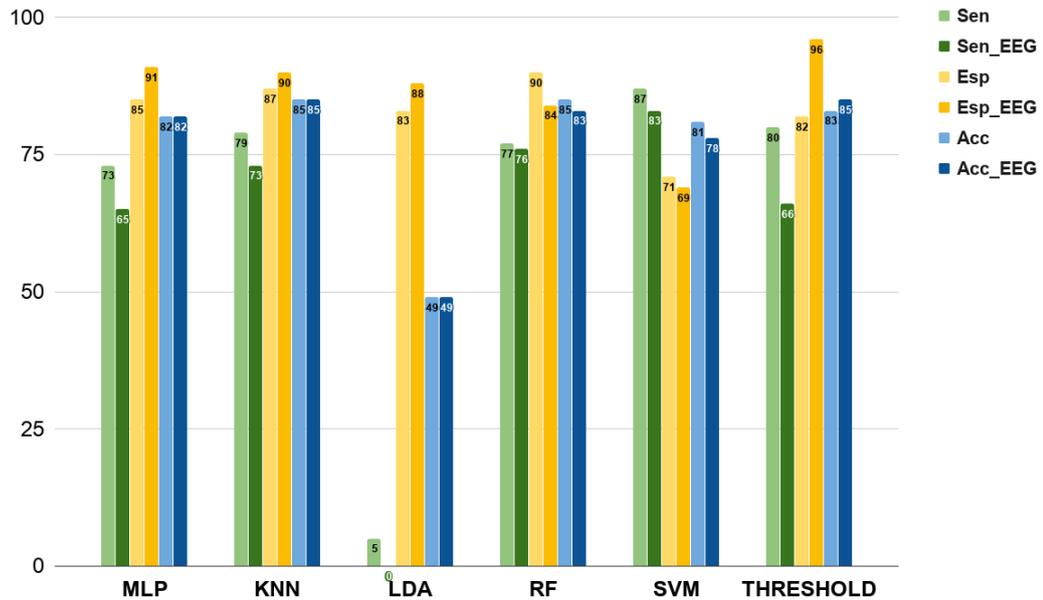
5.1 PERFORMANCE EM TEMPO REAL

Inicialmente, parte dos sinais dos grupos de teste e validação foram separados para aquisição com o EEG vestível (chamaremos TPEEG). Além disso, para uma avaliação de performance estes sinais foram processados também sem a aquisição pelo EEG (chamaremos TPBANCO). As figuras 4.2 e 4.3 citadas anteriormente ilustram estes experimentos, respectivamente.

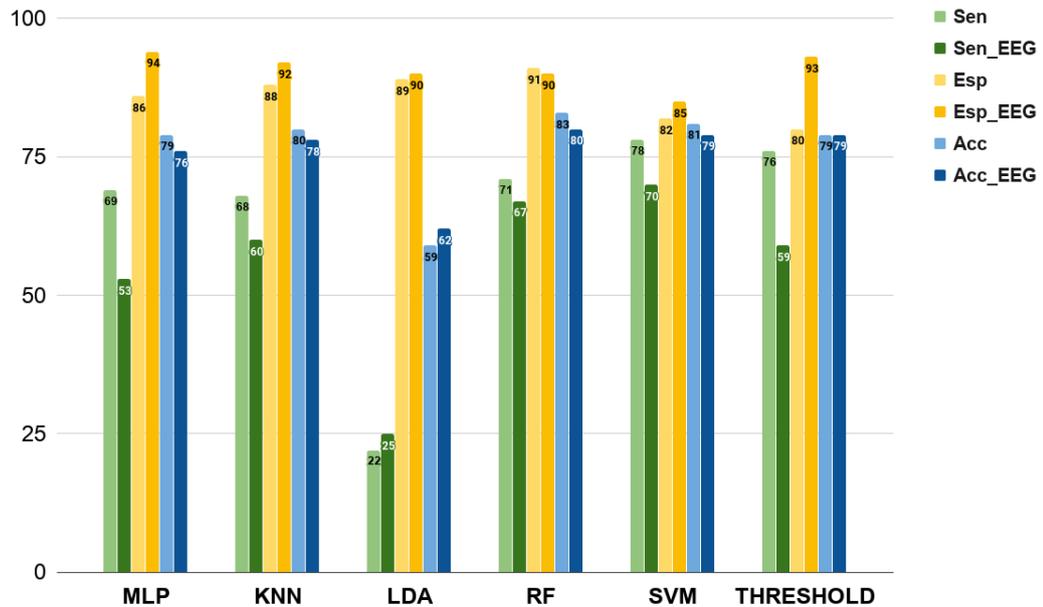
A partir disso, a Fig 5.1 (a) apresenta os resultados de sensibilidade (sen), especificidade (esp) e acurácia (acc) para as 120 amostras do grupo de teste. Os resultados que possuem legenda com o sufixo "_EEG" são para os sinais adquiridos em TPEEG. Com exceção do LDA todos os classificadores obtiveram boa performance. Para os sinais adquiridos em TPBANCO, o RF e o KNN obtiveram as maiores acurácias, sendo que o KNN atingiu maior sensibilidade. Ainda assim, dentre todos os classificadores, o SVM foi o que obteve melhor sensibilidade, ou seja, possui maior capacidade para detectar a classe de sonolência. Apesar da SVM ter gerado um grande número de falsos positivos, obtendo a menor acurácia, para uma aplicação onde o usuário possui risco de segurança, é aceitável que hajam falsos positivos ocasionalmente para que se tenha maior taxa de acerto quando este estiver sonolento. Já para os sinais de TPEEG, podemos perceber algumas diferenças na performance. Ainda assim, o RF apesar de ter perdido acurácia e especificidade se mostrou robusto em relação a sensibilidade, praticamente mantendo a taxa de acertos. Assim como, a SVM que se manteve com a maior sensibilidade, porém perdeu acurácia. Já o KNN manteve a acurácia, mas perdeu performance de sensibilidade. O *threshold*, assim como a MLP, obteve menor sensibilidade, porém aumentou a especificidade, o que sugere que o ruído possui características que influenciam o classificador a classificar como acordado, o desbalanceamento de classes também pode influenciar neste cenário. Ainda assim, o *threshold* possui melhor performance em relação a MLP.

Ainda, a Fig. 5.1 (b) exhibe as mesmas métricas, porém para os sinais do grupo de validação. Neste, a SVM segue com a maior sensibilidade e o RF com maior acurácia e praticamente a mesma especificidade para TPBANCO e TPEEG. Além disso, o *threshold* e a MLP mostraram novamente um comportamento similar, sendo que o *threshold* obteve

Figura 5.1 – A figura mostra os resultados de sensibilidade, especificidade e acurácia para os sinais do grupo de teste e validação para cada classificador. Os resultados com o sufixo "_EEG" correspondem ao experimento TPEEG.



(a) Grupo de Teste(%).



(b) Grupo de Validação(%).

Fonte: Autora.

melhor sensibilidade.

5.2 ANÁLISE DO SINAL DO EEG VESTÍVEL

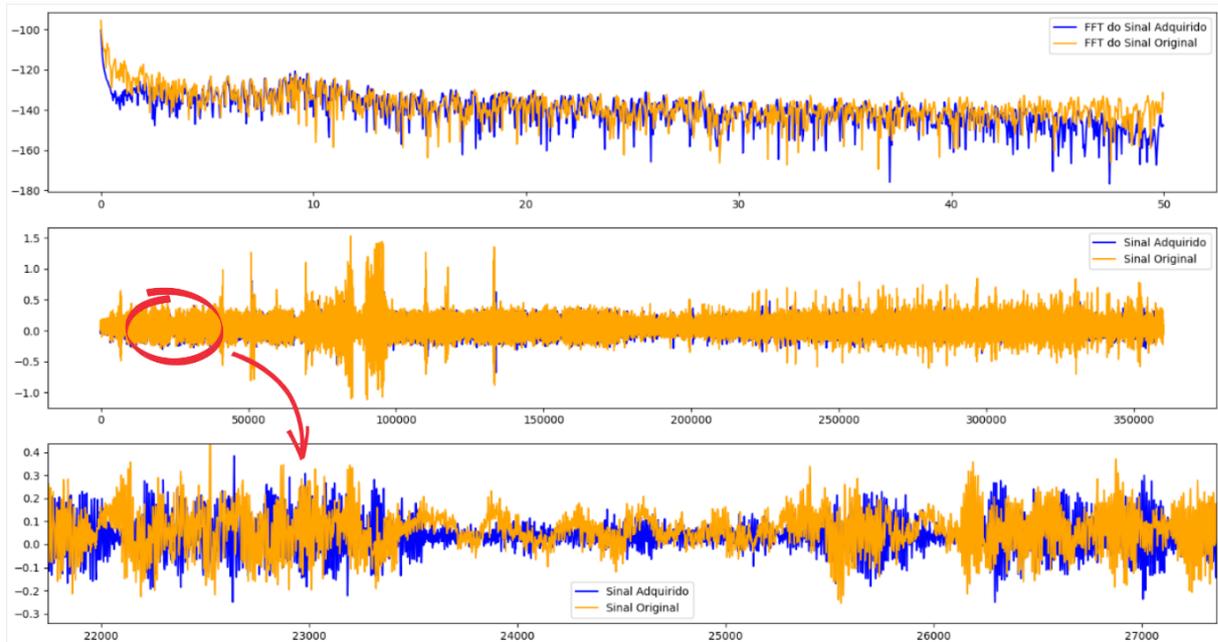
A diferença encontrada entre as performances dos sinais classificados em TP-BANCO e TPEEG, possui duas principais razões. Os testes simulam um cenário real, onde inevitavelmente, o sinal será afetado pelo ruído do ambiente, conseqüentemente, prejudicando a classificação. Além disso, a partir de parte do sinal do sujeito 5, na Fig. 5.2 percebemos algumas distorções no sinal após a leitura pelo EEG vestível. O primeiro gráfico mostra a FFT do sinal antes (TPBANCO) e depois (TPEEG) de ser lido pelo EEG vestível, o segundo mostra o sinal no tempo e o último uma aproximação de uma pequena parte do sinal no tempo. Como consequência da resposta em frequência do EEG vestível percebe-se que o sinal é atenuado em certas frequências. Presume-se que a atenuação tanto nas altas quanto nas baixas frequências seja um aspecto do EEG vestível, já que esta característica é comum a todos os sujeitos, o que faz com que parte da informação dos ritmos cerebrais seja perdida. É possível verificar este fato pela Fig. 5.3, onde é mostrado os ritmos Teta, Alfa, Beta e Gama para o mesmo sinal citado, antes e depois do sinal ser adquirido. Podemos perceber que o ritmo Teta, por aparecer nas baixas frequências, é o mais afetado.

5.3 PERFORMANCE PARA TODAS AS AMOSTRAS E TAMANHOS DE ÉPOCAS

Devido ao experimento realizado para processar os sinais em tempo real (TPEEG), não foi possível utilizar todo o conjunto de amostras disponível. O número total de épocas para os grupos de teste e validação, é apresentado no quadro 5.1. Já a tabela 5.1 mostra os tempos médios de processamento de uma época de 30 s para cada classificador. Além disso, as Figuras 5.4 (a) e 5.4 (b) mostram, respectivamente, os resultados dos classificadores para os grupos completos de teste e validação. Com isto, podemos avaliar a performance da metodologia de processamento do sinal e comparar os classificadores com um maior número de amostras. A partir disso, encontrou-se que a maior sensibilidade foi da SVM, sendo seguida bem próximo pelo *threshold*, e o RF obteve melhor especificidade e acurácia, para o grupo de teste. Para o grupo de validação, a RF seguiu com a maior especificidade e acurácia e o *threshold* obteve maior sensibilidade.

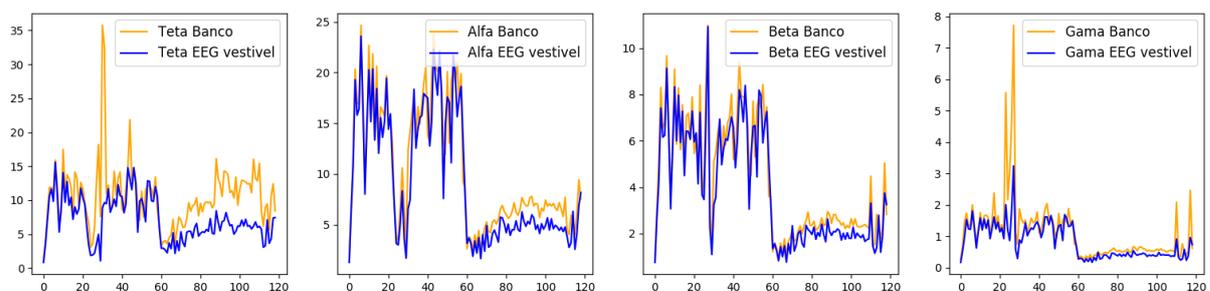
No grupo de validação foi identificado um sujeito, o qual todos os classificadores, com exceção do LDA, obtiveram as piores acurácias e especificidades, ambos os arquivos SC4171 e SC4172 correspondem ao sujeito 17. Além disso, o MLP, KNN e o RF obti-

Figura 5.2 – A figura mostra parte do sinal do primeiro dia de gravação do sujeito 5. O primeiro gráfico compara a FFT do sinal original e, este após ser lido pelo EEG vestível. O segundo gráfico mostra o sinal no domínio do tempo. E o último gráfico mostra uma aproximação do anterior.



Fonte: Autora.

Figura 5.3 – A figura mostra os ritmos cerebrais Teta, Alfa, Beta e Gama, para parte do sinal do primeiro dia de gravação do sujeito 5. A primeira linha de gráficos mostra cada ritmo para o sinal original do banco de dados e a segunda, o mesmo sinal após aquisição pelo EEG vestível



Fonte: Autora.

Tabela 5.1 – Tempo médio de processamento para cada época de 30 segundos.

Classificador	Épocas de treino	Épocas de teste e validação	Tempo total (s)	Tempo por amostra (s)
MLP	51767	38694	0.5747060776	0.00001485
KNN	51767	38694	0.6377301216	0.00001648
LDA	51767	38694	0.6480760574	0.00001675
RF	51767	38694	0.5844721794	0.00001510
SVM	51767	38694	0.6769809723	0.00001749

Fonte: Autora.

Tabela 5.2 – Tempo médio de processamento para cada época de 10 s com janela deslizante de 5s.

Classificador	Épocas de treino	Épocas de teste e validação	Tempo total (s)	Tempo por amostra (s)
RF	310589	232186	2.887809992	0.00001244
SVM	310589	232186	364.7498729	0.00157094

Fonte: Autora.

veram as piores sensibilidades com os sinais do paciente 3 (SC4031 e SC4032). Estes resultados sugerem que os pacientes, em especial o paciente 17, possuem características que diferem dos sujeitos utilizados para treino, gerando, assim, baixa performance pelos classificadores. Todos os resultados por sujeito podem ser encontrados no APÊNDICE A.

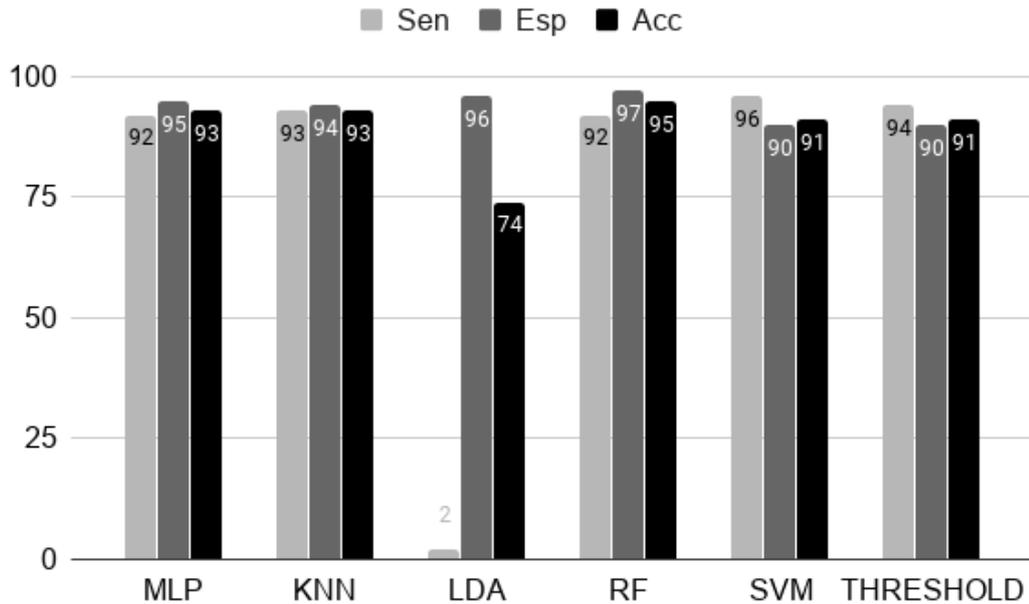
Ainda, para um aplicação de detecção de sonolência em tempo real, é necessário que o sujeito seja monitorado constantemente, assim uma época de 30 segundos pode representar um tempo muito grande para sua segurança. Por isso, novos resultados de performance foram gerados para os três classificadores com melhor performance geral (mais detalhes na seção 5.4), o RF, SVM e o *threshold* com os tamanhos de época de 10 segundos (s), 5 s e de 10 s com janelas deslizantes de 1 s e de 5 s. Os melhores resultados foram encontrados para uma época de 10 s com uma janela deslizante de 5 s (Tab.5.3), ou seja, a primeira época levará em torno de 10 s para ser predita, porém para as próximas o sujeito será monitorado a cada 5 segundos. A Tab. 5.2 mostra os tempos médios de processamento para esta configuração. Além disso, os resultados para outros tamanhos de épocas podem ser encontrados no APÊNDICE B.

Quadro 5.1 – Número de épocas de 30 s para os grupos de teste e validação.

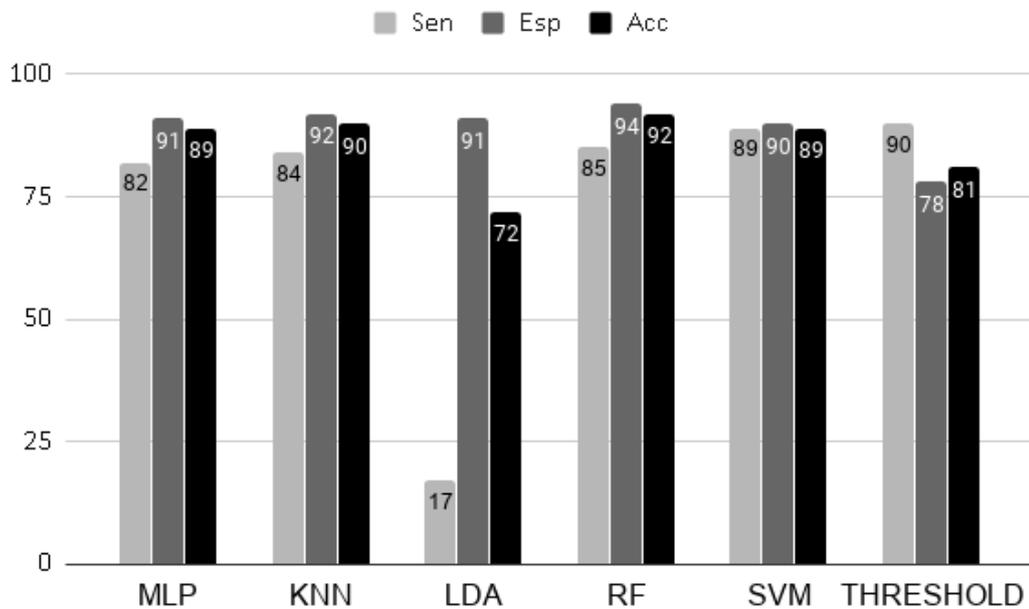
Grupo de Teste		Grupo de Treino	
Sonolência	Acordado	Sonolência	Acordado
5054	13855	4931	14502

Fonte: Autora.

Figura 5.4 – As figuras mostram os resultados de sensibilidade, especificidade e acurácia para cada um dos classificadores, com todas as amostras dos grupos de teste e validação.



(a) Grupo de Teste(%).



(b) Grupo de Validação(%).

Fonte: Autora.

Tabela 5.3 – A tabela mostra os resultados de acurácia, sensibilidade e especificidade para uma época de 10 segundos com uma janela deslizante de 5 segundos.

Paciente	RF			SVM			Threshold		
	Acc	Sen	Esp	Acc	Sen	Esp	Acc	Sen	Esp
SC4191	0.880	0.783	0.945	0.859	0.859	0.859	0.852	0.815	0.877
SC4192	0.924	0.913	0.927	0.863	0.932	0.842	0.866	0.844	0.872
SC4121	0.930	0.957	0.923	0.848	0.997	0.806	0.905	0.995	0.880
SC4122	0.883	0.948	0.870	0.740	1.000	0.685	0.870	0.987	0.845
SC4051	0.977	0.955	0.980	0.939	0.981	0.934	0.908	0.943	0.903
SC4052	0.950	0.937	0.955	0.875	0.990	0.828	0.839	0.967	0.786
SC4021	0.975	0.911	0.996	0.980	0.955	0.988	0.955	0.889	0.977
SC4022	0.963	0.944	0.969	0.915	0.982	0.895	0.852	0.964	0.817
SC4171	0.813	0.995	0.780	0.648	0.997	0.584	0.419	0.999	0.313
SC4172	0.844	0.873	0.831	0.764	0.911	0.698	0.483	0.995	0.254
SC4041	0.951	0.895	0.980	0.953	0.941	0.959	0.907	0.800	0.962
SC4042	0.938	0.782	0.995	0.958	0.883	0.985	0.928	0.764	0.988
SC4031	0.962	0.831	0.998	0.972	0.889	0.995	0.955	0.863	0.980
SC4032	0.978	0.887	0.998	0.986	0.946	0.996	0.956	0.784	0.995
SC4011	0.956	0.929	0.966	0.921	0.949	0.911	0.907	0.894	0.911
SC4012	0.973	0.959	0.979	0.941	0.969	0.929	0.918	0.953	0.904
Média	0.931	0.906	0.943	0.885	0.949	0.868	0.845	0.904	0.829

Fonte: Autora.

5.4 DISCUSSÃO

De modo geral, pode-se observar o mesmo comportamento encontrado tanto para os testes das Figuras 5.1 (a) e 5.1 (b), quanto para um maior número de amostras (Fig. 5.4). A partir disso, percebemos que a MLP e o threshold proposto demonstraram um comportamento semelhante, sendo que o último obteve melhor performance utilizando menos atributos. Além disso, KNN obteve ótima performance, porém devido a este guardar todas as amostras de treino ao invés de gerar um modelo, o consumo de memória pode ser alto. A SVM obteve menor acurácia quando comparada ao RF, devido aos falsos positivos, ou seja, a geração de alertas ao usuário quando este não estava sonolento. Além disso, pelas Tab. 5.1 e 5.2 percebemos que a SVM se tornou mais complexa e, em consequência, mais lenta para classificação, quando o número de amostras para treino aumentou. Apesar disso, esta obteve maior sensibilidade, na maioria dos testes, o que demonstra uma robustez para identificar a sonolência. Embora o RF não tenha obtido a melhor sensibilidade, em ambos os testes da Fig. 5.1, este obteve menor perda de performance após a aquisição com o EEG vestível para identificar sonolência, o que demonstra que o ruído externo não prejudicou significativamente sua performance, além de que, atingiu a melhor acurácia e especificidade.

A Tab. 5.4 detalha os resultados encontrados para RF, SVM e o Threshold, utili-

zando uma época de 10 s com janela deslizante de 5 s e, compara com os resultados dos trabalhos relacionados. Nem todos os trabalhos disponibilizaram seus dados para haver uma comparação justa de performance. Ainda assim, a metodologia proposta utiliza menos atributos. Além disso, os trabalhos que utilizaram os sinais do banco de dados para suas análises (KAYIKCIOGLU; MALEKI; EROGLU, 2015; BELAKHDAR et al., 2018), não realizaram uma análise do comportamento do sistema em uma situação real, adicionando os ruídos do ambiente.

Por fim, as análises realizadas mostram que os resultados dos classificadores RF e SVM são complementares, enquanto a SVM se mostrou robusta para detectar a sonolência, o RF obteve ótimos resultados para a classe acordado. Este aspecto dos resultados sugere a possibilidade da criação de um *ensemble* para associação de ambos. Já o *threshold*, obteve resultados muito próximos utilizando apenas dois atributos. Este se mostrou suscetível ao ruído, em alguns momentos, uma das razões para isto, é que o treinamento dos classificadores e do *threshold* foram realizados previamente e utilizando os dados tratados do banco de dados, enquanto que o teste foi realizado com os sinais sendo capturados pelo EEG vestível. Este fato adiciona erro a predição, o ideal é que o treino seja feito com dados mais próximos da realidade daquela aplicação, o que pode ser alcançado com o ajuste periódico deste *threshold*, ou seja, realizar um aprendizado semi-supervisionado auxilia tanto no problema de ruído externo quanto na variabilidade inter e intrapessoal. Apesar disso, os resultados encontrados para a análise em tempo real se mostraram satisfatórios, já que obteve-se 95% de sensibilidade (capacidade de detectar sonolência) com a SVM e 94% de especificidade com o RF. Além disso, considerando os ruídos do próprio experimento (TPEEG), do ambiente externo, além do treinamento dos classificadores ter ocorrido com os sinais ideais do banco, e da possibilidade do EEG vestível ter atenuado algumas frequências, os resultados apresentados nas Fig. 5.1 (a) e 5.1 (b) mostram que, principalmente, o RF e a SVM obtiveram performances semelhantes para ambas as análises.

Tabela 5.4 – São apresentadas as principais características dos trabalhos relacionados e, os resultados encontrados para RF, SVM e o *Threshold*, utilizando uma época de 10 s com janela deslizando de 5 s.

Ref	Sujeitos	Eletrodos	Atributos	Classificador	Performance
¹	6, 18	Fp1	Atenção, Meditação	KNN	Sen= 68.31%, Esp= 90.43%
²	3	Fp1	Média, Desvio Padrão de α, β	Threshold	Acc=81%
³	59	Fp1	21 atributos do PSD, Wavelet Packet e Domínio do Tempo	DBN	Acc= 98.86%
⁴	7	Pz-Cz	22 AR coef. de θ, α, β	PLS	Acc= 91%
⁵	10	C3-O1	Potência Média em 3,4, IAF, $[3 - 4]/\alpha, \theta/\alpha$	ANN	Sono= 89%, Emb.= 84.29%
-	19	2	Theta, Beta, Alpha, Gamma	RF	Acc= 93%, Sen = 91%, Esp = 94%
-	19	2	Theta, Beta, Alpha, Gamma	SVM	Acc= 88%, Sen = 95%, Esp = 87%
-	19	2	Theta, Beta	Threshold	Acc= 84%, Sen = 90%, Esp = 83%

¹ (HE et al., 2014)

² (HAL et al., 2014)

³ (LI; JIANG; SU, 2016)

⁴ (KAYIKCIOGLU; MALEKI; EROGLU, 2015)

⁵ (BELAKHDAR et al., 2018)

Fonte: Autora.

6 CONCLUSÃO

Neste trabalho foi proposta uma metodologia para detecção de sonolência em tempo real, utilizando um EEG vestível. Para isto, sinais de EEG de 19 sujeitos de um banco de dados público foram utilizados para treino, teste e validação. A metodologia de processamento proposta extrai Alfa, Teta, Beta e Gama com uma transformada Wavelet de Haar e, em seguida, compara as performances dos classificadores: MLP, KNN, LDA, RF, SVM e um *Threshold*.

Para uma análise mais próxima da realidade, onde o ruído externo é inevitável, parte dos sinais do banco de dados foram separados e através de um experimento, adquiridos pelo EEG vestível. A partir disso, foram realizadas análises do sinal lido e avaliadas as performances dos classificadores para este sinal. Com isso, foi constatado que uma porção do espectro de frequência, correspondente a Teta, estava sendo atenuada na aquisição pelo EEG vestível. Considerando estas atenuações e que o treino do classificador foi realizado utilizando sinais ideais do banco, as performances antes e após a leitura do sinal com o EEG vestível foram semelhantes, e por isso os resultados foram considerados satisfatórios.

O RF e a SVM se mostraram complementares para detecção das classes. O primeiro obteve melhor performance para detectar quando o sujeito estava acordado e o segundo para detectar sonolência, o que sugere que uma combinação de ambos em um ensemble deve alcançar resultados ainda melhores. Além disso, o *Threshold* obteve resultados razoáveis em relação aos classificadores analisados, algumas vezes com a mesma performance. Todos os classificadores se mostraram, em algum grau, suscetíveis ao ruído externo, porém isto pode ser amenizado realizando o treino com sinais previamente adquiridos pelo EEG vestível e não, como citado anteriormente, utilizando os sinais ideais.

6.1 TRABALHOS FUTUROS

A partir das análises realizadas percebeu-se que para o progresso do trabalho os seguintes passos são recomendados:

- A criação de um banco de dados com os sinais do EEG vestível;
- Adaptar o algoritmo da transformada de Haar para decomposição de sinais adquiridos à 512 Hz;
- Avaliar a performance para os ritmos extraídos diretamente pelo EEG vestível;
- Avaliar métodos semi-supervisionados para detecção de sonolência.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABN. Dirigir com sono causa 20% dos acidentes de trânsito. 2017. [Http://www.saopaulo.sp.gov.br/spnoticias/dirigir-com-sono-causa-20-acidentes](http://www.saopaulo.sp.gov.br/spnoticias/dirigir-com-sono-causa-20-acidentes).
- ABOALAYON, K. A.; OCBAGABIR, H. T.; FAEZIPOUR, M. Efficient sleep stage classification based on eeg signals. In: IEEE. **IEEE Long Island Systems, Applications and Technology (LISAT) Conference 2014**. [S.l.], 2014. p. 1–6.
- ACHARYA, U. R. et al. Automated diagnosis of epileptic eeg using entropies. **Biomedical Signal Processing and Control**, Elsevier, v. 7, n. 4, p. 401–408, 2012.
- AGGARWAL, C. C. **DATA CLASSIFICATION: ALGORITHMS AND APPLICATIONS**. 1. ed. [S.l.]: CHAPMAN AND HALL/CRC, 2014. (CHAPMAN E HALL/CRC DATA MINING AND KNOWLEDGE DISCOVERY SERIES). ISBN 978-1-4665-8675-8,978-1-4665-8674-1.
- AHN, S. et al. Exploring neuro-physiological correlates of drivers' mental fatigue caused by sleep deprivation using simultaneous eeg, ecg, and fnirs data. **Frontiers in human neuroscience**, Frontiers, v. 10, p. 219, 2016.
- AL-GEELANI, N. A.; PIAH, M. A. M.; BASHIR, N. A review on hybrid wavelet regrouping particle swarm optimization neural networks for characterization of partial discharge acoustic signals. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 45, p. 20–35, 2015.
- ARNIN, J. et al. Wireless-based portable eeg-eog monitoring for real time drowsiness detection. In: IEEE. **2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)**. [S.l.], 2013. p. 4977–4980.
- ASSARI, M. A.; RAHMATI, M. Driver drowsiness detection using face expression recognition. In: IEEE. **2011 IEEE International Conference on Signal and Image Processing Applications (ICSIPA)**. [S.l.], 2011. p. 337–341.
- BAJAJ, V.; PACHORI, R. B. Automatic classification of sleep stages based on the time-frequency image of eeg signals. **Computer methods and programs in biomedicine**, Elsevier, v. 112, n. 3, p. 320–328, 2013.
- BALANDONG, R. P. et al. A review on eeg-based automatic sleepiness detection systems for driver. **IEEE Access**, IEEE, v. 6, p. 22908–22919, 2018.
- BALDISSERA, F. B. **DETECTOR DE SONOLÊNCIA EM TEMPO REAL UTILIZANDO A TRANSFORMADA HAAR EM UM CANAL DE EEG PARA IMPLEMENTAÇÃO EM FPGA**. 2015. Monografia (Trabalho de Conclusão de Curso) — Engenharia de Elétrica, a Universidade Federal de Santa Maria, SANTA MARIA, 2015.
- BELAKHDAR, I. et al. Single-channel-based automatic drowsiness detection architecture with a reduced number of eeg features. **Microprocessors and Microsystems**, Elsevier, v. 58, p. 13–23, 2018.
- BHARDWAJ, A.; ALI, R. Image compression using modified fast haar wavelet transform. **World Applied Sciences Journal**, v. 7, n. 5, p. 647–653, 2009.
- BODY, V. **Human anatomy atlas 7**. [S.l.]: Argosy Publishing Inc., Newton, MA. URL: www.visiblebody.com, 2015.

BOONNAK, N.; KAMONSANTIROJ, S.; PIPANMAEKAPORN, L. Classification of drowsiness in eeg records based on energy distribution and wavelet-neural network. In: **IEEE. 2014 IEEE 17th International Conference on Computational Science and Engineering**. [S.l.], 2014. p. 1664–1668.

BOOSTANI, R.; KARIMZADEH, F.; NAMI, M. A comparative review on sleep stage classification methods in patients and healthy individuals. **Computer methods and programs in biomedicine**, Elsevier, v. 140, p. 77–91, 2017.

BREIMAN, L. Random forests. **KLUWER ACADEMIC PUBLISHERS. MANUFACTURED IN THE NETHERLANDS.**, v. 45, p. 5–32, 2001.

CARSKADON, M. A.; DEMENT, W. C. et al. Normal human sleep: an overview. **Principles and practice of sleep medicine**, Saunders Philadelphia, v. 4, p. 13–23, 2005.

CORREA, A. G.; OROSCO, L.; LACIAR, E. Automatic detection of drowsiness in eeg records based on multimodal analysis. **Medical engineering & physics**, Elsevier, v. 36, n. 2, p. 244–249, 2014.

CVETKOVIC, D.; ÜBEYLI, E. D.; COSIC, I. Wavelet transform feature extraction from human ppg, ecg, and eeg signal responses to elf pemf exposures: A pilot study. **Digital signal processing**, Elsevier, v. 18, n. 5, p. 861–874, 2008.

DAVIS, J. V. et al. Information-theoretic metric learning. In: **ACM. Proceedings of the 24th international conference on Machine learning**. [S.l.], 2007. p. 209–216.

DIETTERICH, T. G. An experimental comparison of three methods for constructing ensembles of decision trees: Bagging, boosting, and randomization. **Machine learning**, Springer, v. 40, n. 2, p. 139–157, 2000.

DIYKH, M.; LI, Y. Complex networks approach for eeg signal sleep stages classification. **Expert Systems with Applications**, Elsevier, v. 63, p. 241–248, 2016.

EBRAHIMI, F. et al. Automatic sleep stage classification based on eeg signals by using neural networks and wavelet packet coefficients. In: **IEEE. 2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society**. [S.l.], 2008. p. 1151–1154.

FABIANI, G. E. et al. Conversion of eeg activity into cursor movement by a brain-computer interface (bci). **IEEE transactions on neural systems and rehabilitation engineering**, IEEE, v. 12, n. 3, p. 331–338, 2004.

FAUST, O. et al. Wavelet-based eeg processing for computer-aided seizure detection and epilepsy diagnosis. **Seizure**, Elsevier, v. 26, p. 56–64, 2015.

FRAIWAN, L. et al. Classification of sleep stages using multi-wavelet time frequency entropy and lda. **Methods of information in Medicine**, Schattauer GmbH, v. 49, n. 03, p. 230–237, 2010.

_____. Automated sleep stage identification system based on time–frequency analysis of a single eeg channel and random forest classifier. **Computer methods and programs in biomedicine**, Elsevier, v. 108, n. 1, p. 10–19, 2012.

GALAR, M. et al. A review on ensembles for the class imbalance problem: bagging-, boosting-, and hybrid-based approaches. **IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)**, IEEE, v. 42, n. 4, p. 463–484, 2011.

GARDNER, M. W.; DORLING, S. Artificial neural networks (the multilayer perceptron) a review of applications in the atmospheric sciences. **Atmospheric environment**, Elsevier, v. 32, n. 14-15, p. 2627–2636, 1998.

GOLDBERGER, A. L. et al. Physiobank, physiotoolkit, and physionet: components of a new research resource for complex physiologic signals. **Circulation**, Am Heart Assoc, v. 101, n. 23, p. e215–e220, 2000.

GUGER, C. et al. How many people are able to operate an eeg-based brain-computer interface (bci)? **IEEE transactions on neural systems and rehabilitation engineering**, IEEE, v. 11, n. 2, p. 145–147, 2003.

_____. Rapid prototyping of an eeg-based brain-computer interface (bci). **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, IEEE, v. 9, n. 1, p. 49–58, 2001.

HAL, B. V. et al. Low-cost eeg-based sleep detection. In: IEEE. **2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society**. [S.l.], 2014. p. 4571–4574.

HASSAN, A. R.; BASHAR, S. K.; BHUIYAN, M. I. H. Automatic classification of sleep stages from single-channel electroencephalogram. In: IEEE. **2015 annual IEEE India conference (INDICON)**. [S.l.], 2015. p. 1–6.

HE, J. et al. A noninvasive real-time driving fatigue detection technology based on left prefrontal attention and meditation eeg. In: IEEE. **2014 International Conference on Multi-sensor Fusion and Information Integration for Intelligent Systems (MFI)**. [S.l.], 2014. p. 1–6.

HSU, K.-I.; GUPTA, H. V.; SOROOSHIAN, S. Artificial neural network modeling of the rainfall-runoff process. **Water resources research**, Wiley Online Library, v. 31, n. 10, p. 2517–2530, 1995.

HU, J.; MIN, J. Automated detection of driver fatigue based on eeg signals using gradient boosting decision tree model. **Cognitive neurodynamics**, Springer, v. 12, n. 4, p. 431–440, 2018.

JAIN, R. Simple tutorial on svm and parameter tuning in python and r. 2017. URL <https://www.hackerearth.com/blog/machine-learning/simple-tutorial-svm-parameter-tuning-python-r/>. Visited, v. 20, 2018.

JALILIFARD, A.; PIZZOLATO, E. B. An efficient k-nn approach for automatic drowsiness detection using single-channel eeg recording. In: IEEE. **2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)**. [S.l.], 2016. p. 820–824.

KARTSCH, V. et al. A wearable eeg-based drowsiness detection system with blink duration and alpha waves analysis. In: IEEE. **2017 8th International IEEE/EMBS Conference on Neural Engineering (NER)**. [S.l.], 2017. p. 251–254.

KAYIKCIOGLU, T.; MALEKI, M.; EROGLU, K. Fast and accurate pls-based classification of eeg sleep using single channel data. **Expert Systems with Applications**, Elsevier, v. 42, n. 21, p. 7825–7830, 2015.

KERMIT, M. et al. Treatment of obstructive sleep apnea syndrome by monitoring patients airflow signals. **Pattern Recognition Letters**, Elsevier, v. 21, n. 3, p. 277–281, 2000.

KIM, S. M. et al. Characteristics of vertex wave during light sleep according to age. **Journal of Korean Sleep Research Society**, Korean Sleep Research Society, v. 9, n. 1, p. 5–9, 2012.

KO, L.-W. et al. Single channel wireless eeg device for real-time fatigue level detection. In: IEEE. **2015 International Joint Conference on Neural Networks (IJCNN)**. [S.l.], 2015. p. 1–5.

KOLEY, B.; DEY, D. An ensemble system for automatic sleep stage classification using single channel eeg signal. **Computers in biology and medicine**, Elsevier, v. 42, n. 12, p. 1186–1195, 2012.

LAL, S. K.; CRAIG, A. A critical review of the psychophysiology of driver fatigue. **Biological psychology**, Elsevier, v. 55, n. 3, p. 173–194, 2001.

LEE, B.-G.; LEE, B.-L.; CHUNG, W.-Y. Mobile healthcare for automatic driving sleep-onset detection using wavelet-based eeg and respiration signals. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 14, n. 10, p. 17915–17936, 2014.

LI, G.; CHUNG, W.-Y. Estimation of eye closure degree using eeg sensors and its application in driver drowsiness detection. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 14, n. 9, p. 17491–17515, 2014.

LI, G.; LEE, B.-L.; CHUNG, W.-Y. Smartwatch-based wearable eeg system for driver drowsiness detection. **IEEE Sensors Journal**, IEEE, v. 15, n. 12, p. 7169–7180, 2015.

LI, P.; JIANG, W.; SU, F. Single-channel eeg-based mental fatigue detection based on deep belief network. In: IEEE. **2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)**. [S.l.], 2016. p. 367–370.

LU, J. et al. A putative flip–flop switch for control of rem sleep. **Nature**, Nature Publishing Group, v. 441, n. 7093, p. 589, 2006.

MARCOS, J. V. et al. Automated detection of obstructive sleep apnoea syndrome from oxygen saturation recordings using linear discriminant analysis. **Medical & biological engineering & computing**, Springer, v. 48, n. 9, p. 895–902, 2010.

MONS, T. L. U. of. The dreams sleep spindles database. In: . [S.l.: s.n.], 2015.

MOSER, D. et al. Sleep classification according to aasm and rechtschaffen & kales: effects on sleep scoring parameters. **Sleep**, Oxford University Press, v. 32, n. 2, p. 139–149, 2009.

MU, Z.; HU, J.; MIN, J. Driver fatigue detection system using electroencephalography signals based on combined entropy features. **Applied Sciences**, Multidisciplinary Digital Publishing Institute, v. 7, n. 2, p. 150, 2017.

MULCAHY, C. Image compression using the haar wavelet transform. **Spelman Science and Mathematics Journal**, Citeseer, v. 1, n. 1, p. 22–31, 1997.

MYNDPLAY. **MyndBand BLE EEG Brainwave Headset**. 2011. Acesso em 13 jan. 2020. Disponível em: <<https://store.myndplay.com/products.php?prod=48>>.

NAVOT, A. et al. Nearest neighbor based feature selection for regression and its application to neural activity. In: **Advances in Neural Information Processing Systems**. [S.l.: s.n.], 2006. p. 996–1002.

NHTSA. Traffic safety facts: crash and stats. In: . [S.I.]: NHTSAs National Center for Statistics and Analysis, 2017.

OGINO, M.; MITSUKURA, Y. Portable drowsiness detection through use of a prefrontal single-channel electroencephalogram. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 18, n. 12, p. 4477, 2018.

OMS. **Global status report on road safety 2018**. [S.I.]: World Health Organization, 2018.

OPITZ, D.; MACLIN, R. Popular ensemble methods: An empirical study. **Journal of artificial intelligence research**, v. 11, p. 169–198, 1999.

PATRICK, K. C. et al. An algorithm for automatic detection of drowsiness for use in wearable eeg systems. In: IEEE. **2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)**. [S.I.], 2016. p. 3523–3526.

PECHENIZKIY, M. et al. Class noise and supervised learning in medical domains: The effect of feature extraction. In: IEEE. **19th IEEE Symposium on Computer-Based Medical Systems (CBMS'06)**. [S.I.], 2006. p. 708–713.

PURVES, D. et al. **Neuroscience, 6th Ed.** [S.I.]: Addison-Wesley, 2017. v. 1.

QIAN, D. et al. Drowsiness detection by bayesian-copula discriminant classifier based on eeg signals during daytime short nap. **IEEE Transactions on Biomedical Engineering**, IEEE, v. 64, n. 4, p. 743–754, 2016.

RASCHKA, S.; MIRJALILI, V. **Python machine learning**. [S.I.]: Packt Publishing Ltd, 2017.

RAVIRAJ, P.; SANAVULLAH, M. The modified 2d-haar wavelet transformation in image compression. **Middle-East Journal of Scientific Research**, Citeseer, v. 2, n. 2, p. 73–78, 2007.

RETAMAL, G. R. **IMPLEMENTAÇÃO FPGA DE UM PROCESSADOR WAVELET HAAR APLICADO A DETECÇÃO DE SONOLÊNCIA A PARTIR DE UM ÚNICO CANAL DE EEG**. 2018. Monografia (Trabalho de Conclusão de Curso) — Engenharia de Computação, a Universidade Federal de Santa Maria, SANTA MARIA, 2018.

RODRÍGUEZ-SOTELO, J. et al. Automatic sleep stages classification using eeg entropy features and unsupervised pattern analysis techniques. **Entropy**, Multidisciplinary Digital Publishing Institute, v. 16, n. 12, p. 6573–6589, 2014.

SAHAYADHAS, A.; SUNDARAJ, K.; MURUGAPPAN, M. Hypothalamic regulation of sleep and circadian rhythms. **Nature**, Nature, v. 437, n. 7063, p. 1257–1263, 2005.

_____. Detecting driver drowsiness based on sensors: a review. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 12, n. 12, p. 16937–16953, 2012.

SAMIEE, K. et al. Sleep stage classification using sparse rational decomposition of single channel eeg records. In: IEEE. **2015 23rd European Signal Processing Conference (EUSIPCO)**. [S.I.], 2015. p. 1860–1864.

SANEI, S.; CHAMBERS, J. A. Eeg signal processing. Wiley Online Library, 2007.

SCHOMER, D.; SILVA, F. H. **Niedermeyer's Encephalography, 6th Ed.** [S.I.]: Lippincott Williams & Wilkins, 2011. v. 1.

SCHOMER, D. L.; SILVA, F. L. D. **Niedermeyer's electroencephalography: basic principles, clinical applications, and related fields**. [S.l.]: Lippincott Williams & Wilkins, 2012.

SHARMA, R.; PACHORI, R. B.; UPADHYAY, A. Automatic sleep stages classification based on iterative filtering of electroencephalogram signals. **Neural Computing and Applications**, Springer, v. 28, n. 10, p. 2959–2978, 2017.

SILVEIRA, T. d.; KOZAKEVICIUS, A. d. J.; RODRIGUES, C. R. Drowsiness detection for single channel eeg by dwt best m-term approximation. **Research on Biomedical Engineering**, SciELO Brasil, v. 31, n. 2, p. 107–115, 2015.

ŠUŠMÁKOVÁ, K. Human sleep and sleep eeg. **Measurement science review**, Citeseer, v. 4, n. 2, p. 59–74, 2004.

TAN, S. Neighbor-weighted k-nearest neighbor for unbalanced text corpus. **Expert Systems with Applications**, Elsevier, v. 28, n. 4, p. 667–671, 2005.

THEODORIDIS, S.; KOUTROUMBAS, K. et al. Pattern recognition. **IEEE Transactions on Neural Networks**, IEEE INSTITUTE OF ELECTRICAL AND ELECTRONICS, v. 19, n. 2, p. 376, 2008.

VIDAKOVIC, B.; MUELLER, P. Wavelets for kids. **Instituto de Estadística, Universidad de Duke**, 1994.

VISA, S. et al. Confusion matrix-based feature selection. **MAICS**, v. 710, p. 120–127, 2011.

WALBER. Sensitivity and specificity. 2014. Disponível em: <https://en.wikipedia.org/wiki/Sensitivity_and_specificity>.

WANG, L. **Support vector machines: theory and applications**. [S.l.]: Springer Science & Business Media, 2005. v. 177.

YAO, Z.; RUZZO, W. L. A regression-based k nearest neighbor algorithm for gene function prediction from heterogeneous data. In: BIOMED CENTRAL. **BMC bioinformatics**. [S.l.], 2006. v. 7, n. 1, p. S11.

YAZICIOGLU, R. F. et al. A 200 μ W eight-channel eeg acquisition asic for ambulatory eeg systems. **IEEE Journal of Solid-State Circuits**, IEEE, v. 43, n. 12, p. 3025–3038, 2008.

ZHU, G.; LI, Y.; WEN, P. P. Analysis and classification of sleep stages based on difference visibility graphs from a single-channel eeg signal. **IEEE journal of biomedical and health informatics**, IEEE, v. 18, n. 6, p. 1813–1821, 2014.

APÊNDICE A – RESULTADOS PARA TODAS AS AMOSTRAS

Tabela A.1 – Resultados de acurácia, sensibilidade e especificidade para todos os classificadores e todos dados.

GRUPO DE TESTE								GRUPO DE VALIDAÇÃO								
PACIENTE	VP	VN	FP	FN	ACC	SEN	ESP		VP	VN	FP	FN	ACC	SEN	ESP	PACIENTE
SC4191	697	1330	97	254	0.852	0.733	0.932		346	1214	701	3	0.689	0.991	0.634	SC4171
SC4192	447	1605	102	59	0.927	0.883	0.940		644	1050	432	87	0.781	0.881	0.736	SC4172
SC4121	511	1714	95	0	0.959	1.000	0.947		666	1501	33	120	0.934	0.847	0.978	SC4041
SC4122	404	1670	249	4	0.891	0.990	0.870	MLP	511	1766	7	140	0.939	0.785	0.996	SC4042
SC4051	253	2186	72	8	0.968	0.969	0.968		297	2006	1	249	0.902	0.544	1.000	SC4031
SC4052	726	1645	135	4	0.945	0.995	0.924		296	1955	2	149	0.937	0.665	0.999	SC4032
SC4021	575	1899	8	64	0.972	0.900	0.996		600	1766	90	71	0.936	0.894	0.952	SC4011
SC4022	524	524	524	524	0.965	0.894	0.987		725	1759	65	27	0.964	0.964	0.964	SC4012
Média					0.935	0.921	0.946						0.885	0.822	0.907	Média
SC4191	757	1303	124	194	0.866	0.796	0.913		348	1328	587	1	0.740	0.997	0.693	SC4171
SC4192	449	1637	70	57	0.943	0.887	0.959		659	1245	391	72	0.804	0.902	0.761	SC4172
SC4121	505	1689	120	6	0.946	0.988	0.934		682	1508	26	104	0.944	0.868	0.983	SC4041
SC4122	405	1709	210	3	0.908	0.993	0.891	KNN	512	1768	5	139	0.941	0.786	0.997	SC4042
SC4051	246	2192	66	15	0.968	0.943	0.971		336	2001	6	210	0.915	0.615	0.997	SC4031
SC4052	714	1564	216	16	0.908	0.978	0.879		306	1956	1	139	0.942	0.688	0.999	SC4032
SC4021	565	1902	5	74	0.969	0.884	0.997		604	1788	68	67	0.947	0.900	0.963	SC4011
SC4022	549	1803	59	37	0.961	0.937	0.968		723	1771	53	29	0.968	0.961	0.971	SC4012
Média					0.934	0.926	0.939						0.900	0.840	0.921	Média

GRUPO DE TESTE								GRUPO DE VALIDAÇÃO								
PACIENTE	VP	VN	FP	FN	ACC	SEN	ESP		VP	VN	FP	FN	ACC	SEN	ESP	PACIENTE
SC4191	1	1421	6	950	0.598	0.001	0.996		0	1592	323	349	0.703	0.000	0.831	SC4171
SC4192	0	1700	7	506	0.768	0.000	0.996		87	899	737	644	0.417	0.119	0.550	SC4172
SC4121	0	1807	2	511	0.779	0.000	0.999		4	1531	3	782	0.662	0.005	0.998	SC4041
SC4122	0	1918	1	408	0.824	0.000	0.999	LDA	0	1766	7	651	0.729	0.000	0.996	SC4042
SC4051	1	2020	238	260	0.802	0.004	0.895		430	1920	87	116	0.920	0.788	0.957	SC4031
SC4052	50	1472	308	680	0.606	0.068	0.827		138	1932	25	307	0.862	0.310	0.987	SC4032
SC4021	80	1905	2	559	0.780	0.125	0.999		0	1855	1	671	0.734	0.000	0.999	SC4011
SC4022	0	1861	1	586	0.760	0.000	0.999		77	1805	19	675	0.731	0.102	0.990	SC4012
Média					0.740	0.025	0.964						0.720	0.166	0.913	Média
SC4191	770	1374	53	181	0.902	0.810	0.963		346	1515	400	3	0.822	0.991	0.791	SC4171
SC4192	456	1640	67	50	0.947	0.901	0.961		629	1348	288	102	0.835	0.860	0.824	SC4172
SC4121	498	1697	112	13	0.946	0.975	0.938		694	1516	18	92	0.953	0.883	0.988	SC4041
SC4122	393	1754	165	15	0.923	0.963	0.914	RF	503	1768	5	148	0.937	0.773	0.997	SC4042
SC4051	246	2239	19	15	0.987	0.943	0.992		346	2006	1	200	0.921	0.634	1.000	SC4031
SC4052	676	1724	56	54	0.956	0.926	0.969		344	1956	1	101	0.958	0.773	0.999	SC4032
SC4021	571	1902	5	68	0.971	0.894	0.997		619	1806	50	52	0.960	0.923	0.973	SC4011
SC4022	536	1846	16	50	0.973	0.915	0.991		718	1795	29	34	0.976	0.955	0.984	SC4012
Média					0.951	0.916	0.966						0.920	0.849	0.945	Média
PACIENTE	VP	VN	FP	FN	ACC	SEN	ESP		VP	VN	FP	FN	ACC	SEN	ESP	PACIENTE
SC4191	847	1291	136	104	0.899	0.891	0.905		348	1177	738	1	0.674	0.997	0.615	SC4171
SC4192	475	1530	177	31	0.906	0.939	0.896		651	1188	448	80	0.777	0.891	0.726	SC4172
SC4121	511	1526	283	0	0.878	1.000	0.844		731	1483	51	55	0.954	0.930	0.967	SC4041
SC4122	408	1436	483	0	0.792	1.000	0.748	SVM	566	1764	9	85	0.961	0.869	0.995	SC4042

GRUPO DE TESTE								GRUPO DE VALIDAÇÃO								
SC4051	254	2166	92	7	0.961	0.973	0.959		355	2003	4	191	0.924	0.650	0.998	SC4031
SC4052	723	1525	255	7	0.896	0.990	0.857		368	1955	2	77	0.967	0.827	0.999	SC4032
SC4021	593	1897	10	46	0.978	0.928	0.995		645	1724	132	26	0.937	0.961	0.929	SC4011
SC4022	576	1783	79	10	0.964	0.983	0.958		732	1730	94	20	0.956	0.973	0.948	SC4012
Média					0.909	0.963	0.895						0.894	0.887	0.897	Média
SC4191	818	1299	128	133	0.890	0.860	0.910		349	527	1388	0	0.387	1.000	0.275	SC4171
SC4192	444	1526	181	62	0.890	0.877	0.894		730	291	1345	1	0.431	0.999	0.178	SC4172
SC4121	510	1658	151	1	0.934	0.998	0.917		656	1488	46	130	0.924	0.835	0.970	SC4041
SC4122	405	1738	181	3	0.921	0.993	0.906	THRESHOLD	513	1755	18	138	0.936	0.788	0.990	SC4042
SC4051	252	2085	173	9	0.928	0.966	0.923		487	1987	20	59	0.969	0.892	0.990	SC4031
SC4052	726	1434	346	4	0.861	0.995	0.806		372	1954	3	73	0.968	0.836	0.998	SC4032
SC4021	578	1887	20	61	0.968	0.905	0.990		606	1730	126	65	0.924	0.903	0.932	SC4011
SC4022	563	1613	249	23	0.889	0.961	0.866		727	1678	146	25	0.934	0.967	0.920	SC4012
Média					0.910	0.944	0.901						0.809	0.902	0.782	Média

APÊNDICE B – RESULTADOS PARA DIFERENTES TAMANHOS DE ÉPOCAS

Tabela B.1 – A tabela mostra os resultados de acurácia, sensibilidade e especificidade para cinco tamanhos de épocas diferentes, utilizando o RF.

	30 s			5 s			10 s			10 s com janela de 1 s			10 s com janela de 5 s		
Paciente	Acc	Sen	Esp	Acc	Sen	Esp	Acc	Sen	Esp	Acc	Sen	Esp	Acc	Sen	Esp
SC4191	0.905	0.823	0.959	0.843	0.713	0.929	0.702	0.516	0.800	0.849	0.755	0.913	0.880	0.783	0.945
SC4192	0.947	0.901	0.960	0.889	0.920	0.880	0.704	0.570	0.729	0.873	0.932	0.855	0.924	0.913	0.927
SC4121	0.945	0.977	0.936	0.907	0.895	0.911	0.710	0.342	0.855	0.898	0.930	0.889	0.930	0.957	0.923
SC4122	0.919	0.963	0.909	0.848	0.926	0.831	0.683	0.420	0.764	0.831	0.954	0.805	0.883	0.948	0.870
SC4051	0.988	0.950	0.992	0.967	0.951	0.968	0.696	0.224	0.772	0.958	0.960	0.958	0.977	0.955	0.980
SC4052	0.957	0.930	0.967	0.929	0.888	0.946	0.676	0.515	0.772	0.930	0.922	0.933	0.950	0.937	0.955
SC4021	0.973	0.897	0.998	0.974	0.923	0.991	0.766	0.431	0.935	0.975	0.933	0.989	0.975	0.911	0.996
SC4022	0.975	0.923	0.991	0.940	0.954	0.936	0.719	0.470	0.835	0.935	0.957	0.928	0.963	0.944	0.969
SC4171	0.823	0.991	0.793	0.809	0.993	0.776	0.709	0.560	0.747	0.780	0.995	0.741	0.813	0.995	0.780
SC4172	0.844	0.870	0.832	0.847	0.868	0.837	0.535	0.333	0.677	0.831	0.874	0.812	0.844	0.873	0.831
SC4041	0.953	0.888	0.986	0.944	0.891	0.971	0.710	0.574	0.822	0.949	0.910	0.969	0.951	0.895	0.980
SC4042	0.936	0.768	0.997	0.933	0.770	0.993	0.677	0.406	0.828	0.941	0.804	0.991	0.938	0.782	0.995
SC4031	0.928	0.667	1.000	0.959	0.839	0.992	0.769	0.420	0.908	0.974	0.895	0.996	0.962	0.831	0.998
SC4032	0.953	0.751	0.999	0.976	0.881	0.997	0.744	0.368	0.867	0.982	0.915	0.997	0.978	0.887	0.998
SC4011	0.961	0.925	0.974	0.954	0.940	0.959	0.729	0.499	0.855	0.951	0.951	0.951	0.956	0.929	0.966
SC4012	0.977	0.953	0.987	0.967	0.957	0.971	0.725	0.475	0.885	0.965	0.963	0.965	0.973	0.959	0.979
Média	0.936	0.886	0.955	0.918	0.894	0.931	0.704	0.445	0.816	0.914	0.916	0.918	0.931	0.906	0.943

Fonte: Autora.

Tabela B.2 – A tabela mostra os resultados de acurácia, sensibilidade e especificidade para cinco tamanhos de épocas diferentes, utilizando a SVM.

Paciente	30 s			5 s			10 s			10 s com janela de 1 s			10 s com janela de 5 s		
	Acc	Sen	Esp	Acc	Sen	Esp	Acc	Sen	Esp	Acc	Sen	Esp	Acc	Sen	Esp
SC4191	0.899	0.891	0.905	0.785	0.875	0.725	0.645	0.872	0.527	0.802	0.846	0.773	0.859	0.859	0.859
SC4192	0.906	0.939	0.896	0.804	0.930	0.766	0.615	0.654	0.608	0.815	0.934	0.780	0.863	0.932	0.842
SC4121	0.878	1.000	0.844	0.792	0.997	0.735	0.627	0.696	0.600	0.810	0.997	0.757	0.848	0.997	0.806
SC4122	0.792	1.000	0.748	0.654	0.998	0.580	0.511	0.638	0.472	0.680	0.999	0.612	0.740	1.000	0.685
SC4051	0.961	0.973	0.959	0.902	0.984	0.893	0.596	0.301	0.643	0.911	0.983	0.903	0.939	0.981	0.934
SC4052	0.896	0.990	0.857	0.849	0.992	0.791	0.605	0.692	0.554	0.853	0.991	0.797	0.875	0.990	0.828
SC4021	0.978	0.928	0.995	0.969	0.952	0.975	0.768	0.516	0.894	0.970	0.956	0.975	0.980	0.955	0.988
SC4022	0.964	0.983	0.958	0.840	0.991	0.793	0.655	0.615	0.673	0.856	0.985	0.816	0.915	0.982	0.895
SC4171	0.674	0.997	0.615	0.586	0.997	0.511	0.467	0.814	0.377	0.606	0.997	0.535	0.648	0.997	0.584
SC4172	0.777	0.891	0.726	0.730	0.928	0.641	0.455	0.572	0.373	0.741	0.919	0.661	0.764	0.911	0.698
SC4041	0.954	0.930	0.967	0.939	0.938	0.939	0.723	0.656	0.778	0.943	0.941	0.945	0.953	0.941	0.959
SC4042	0.961	0.869	0.995	0.955	0.885	0.980	0.696	0.536	0.785	0.956	0.886	0.981	0.958	0.883	0.985
SC4031	0.924	0.650	0.998	0.971	0.915	0.986	0.727	0.505	0.815	0.978	0.927	0.992	0.972	0.889	0.995
SC4032	0.967	0.827	0.999	0.983	0.946	0.991	0.722	0.418	0.822	0.983	0.945	0.992	0.986	0.946	0.996
SC4011	0.937	0.961	0.929	0.904	0.943	0.890	0.704	0.593	0.765	0.908	0.943	0.895	0.921	0.949	0.911
SC4012	0.956	0.973	0.948	0.910	0.963	0.888	0.708	0.589	0.783	0.920	0.965	0.901	0.941	0.969	0.929
Média	0.901	0.925	0.896	0.848	0.952	0.818	0.639	0.604	0.654	0.858	0.951	0.832	0.885	0.949	0.868

Fonte: Autora.

Tabela B.3 – A tabela mostra os resultados de acurácia, sensibilidade e especificidade para cinco tamanhos de épocas diferentes, utilizando o Threshold.

Paciente	30 s			5 s			10 s			10 s com janela de 1 s			10 s com janela de 5 s		
	Acc	Sen	Esp	Acc	Sen	Esp	Acc	Sen	Esp	Acc	Sen	Esp	Acc	Sen	Esp
SC4191	0.890	0.860	0.910	0.824	0.780	0.854	0.676	0.675	0.676	0.823	0.780	0.851	0.852	0.815	0.877
SC4192	0.890	0.877	0.894	0.848	0.809	0.860	0.694	0.602	0.711	0.847	0.808	0.858	0.866	0.844	0.872
SC4121	0.934	0.998	0.917	0.881	0.988	0.850	0.691	0.688	0.692	0.882	0.989	0.852	0.905	0.995	0.880
SC4122	0.921	0.993	0.906	0.834	0.982	0.802	0.635	0.513	0.672	0.838	0.982	0.808	0.870	0.987	0.845
SC4051	0.928	0.966	0.923	0.893	0.918	0.890	0.692	0.263	0.761	0.890	0.919	0.887	0.908	0.943	0.903
SC4052	0.861	0.995	0.806	0.821	0.942	0.771	0.636	0.627	0.641	0.821	0.939	0.773	0.839	0.967	0.786
SC4021	0.968	0.905	0.990	0.944	0.871	0.969	0.754	0.555	0.854	0.944	0.871	0.969	0.955	0.889	0.977
SC4022	0.889	0.961	0.866	0.831	0.961	0.790	0.679	0.612	0.711	0.826	0.954	0.786	0.852	0.964	0.817
SC4171	0.387	1.000	0.275	0.445	0.999	0.344	0.400	0.910	0.269	0.445	0.999	0.345	0.419	0.999	0.313
SC4172	0.431	0.999	0.178	0.520	0.988	0.311	0.492	0.894	0.211	0.519	0.987	0.309	0.483	0.995	0.254
SC4041	0.924	0.835	0.970	0.893	0.772	0.954	0.701	0.557	0.819	0.893	0.777	0.953	0.907	0.800	0.962
SC4042	0.936	0.788	0.990	0.920	0.740	0.986	0.696	0.487	0.813	0.919	0.739	0.985	0.928	0.764	0.988
SC4031	0.969	0.892	0.990	0.944	0.845	0.971	0.742	0.498	0.839	0.944	0.844	0.971	0.955	0.863	0.980
SC4032	0.968	0.836	0.998	0.949	0.767	0.990	0.731	0.359	0.853	0.948	0.767	0.989	0.956	0.784	0.995
SC4011	0.924	0.903	0.932	0.894	0.868	0.904	0.707	0.569	0.782	0.893	0.871	0.901	0.907	0.894	0.911
SC4012	0.934	0.967	0.920	0.901	0.936	0.887	0.708	0.601	0.777	0.903	0.936	0.890	0.918	0.953	0.904
Média	0.860	0.923	0.842	0.834	0.885	0.821	0.665	0.588	0.693	0.834	0.885	0.820	0.845	0.904	0.829

Fonte: Autora.