

Universidade de Brasília – UnB
Campus Gama – FGA
Engenharia Eletrônica

**Seleção e classificação automática de sinais de polissonografia
para ferramenta de auxílio a diagnóstico de distúrbios de sono**

ISABELA LACERDA DE RESENDE E MAURÍCIO BARROS WOLNEY

Orientador: Dr. CRISTIANO JACQUES MIOSSO



ISABELA LACERDA DE RESENDE E MAURÍCIO BARROS WOLNEY

**Seleção e classificação automática de sinais de polissonografia
para ferramenta de auxílio a diagnóstico de distúrbios de sono**

Monografia submetida ao curso de graduação
em Engenharia Eletrônica da Universidade de Bra-
sília, como requisito parcial para obtenção do Tí-
tulo de Bacharel em Engenharia Eletrônica.

Orientador: Dr. Cristiano Jacques Miosso

Brasília, DF

2016

Brasília/DF, Julho de 2016

FICHA CATALOGRÁFICA

ISABELA LACERDA DE RESENDE E MAURÍCIO BARROS WOLNEY

Seleção e classificação automática de sinais de polissonografia para ferramenta de auxílio a diagnóstico de distúrbios de sono

57p., 210 × 297 mm (FGA/UnB Gama, Engenharia Eletrônica, 2016)

Trabalho de graduação em engenharia eletrônica

Universidade de Brasília, Campus Gama – FGA/UnB

- | | |
|----------------------------|----------------------------|
| 1. Polissonografia | 2. Processamento de sinais |
| 3. Aprendizagem de máquina | 4. Engenharia Biomédica |
| I. FGA UnB/UnB. | II. Title (series) |

REFERÊNCIA

RESENDE, ISABELA LACERDA E WOLNEY, MAURÍCIO BARROS (2016). Seleção e classificação automática de sinais de polissonografia para ferramenta de auxílio a diagnóstico de distúrbios de sono. Dissertação de graduação em engenharia eletrônica, Universidade de Brasília, Campus Gama, DF, 57p.

*Dedicamos esse trabalho aos nossos familiares, amigos
e ao nosso Professor Orientador Dr. Cristiano Jacques Miosso.*

Agradecimentos

Agradeço primeiramente aos meus pais e minha irmã por todo suporte fornecido durante o processo de desenvolvimento deste trabalho e ao meu namorado, Tharcísio Castro, pela paciência e companheirismo em todos momentos. Agradeço também à todos meus amigos pela parceria e à minha dupla de trabalho, Maurício Barros, pelo apoio e empenho durante a nossa pesquisa. Por fim, agradeço especialmente ao meu Orientador, Dr. Cristiano Jacques Miosso, por toda sua sabedoria, auxílio e motivação para a realização deste trabalho.

Isabela Lacerda de Resende.

Agradecimentos

Gostaria de agradecer primeiramente ao meu orientador, Professor Dr. Cristiano Mi-
osso, por todo o auxílio direto que foi dado para este trabalho. Agradeço também à minha
parceira de pesquisa, Isabela Lacerda, junto à qual dediquei meu tempo e esforço à esse
trabalho. Finalmente, agradeço à minha família como um todo, pelo apoio incondicional
dado não somente durante a pesquisa, mas durante todo o curso de graduação.

Maurício Barros Wolney.

FGA/UnB – Universidade de Brasília, Campus Gama

**Seleção e classificação automática de sinais de polissonografia
para ferramenta de auxílio a diagnóstico de distúrbios de sono**

Isabela Lacerda de Resende e Maurício Barros Wolney

Monografia submetida ao curso de graduação em
Engenharia Eletrônica da Universidade de Brasília,
como requisito parcial para obtenção do título de
Bacharel em Engenharia Eletrônica.

APROVADA POR:

Prof. Cristiano Jacques Miosso, PhD
(Orientador)

Prof. Adson Ferreira da Rocha, PhD
(Examinador interno)

Prof^a Suélia Rodrigues Fleury Rosa, PhD
(Examinadora interna)

A menos que modifiquemos a nossa maneira de pensar, não seremos capazes de resolver os problemas causados pela forma como nos acostumamos a ver o mundo.

Albert Einstein

Resumo

A análise sistemática de características fisiológicas específicas constitui a base para estudos avançados do sono e para a determinação de quais hábitos, distúrbios e patologias afetam negativamente o ciclo do sono. Para um melhor entendimento da qualidade do sono, se faz necessária uma análise acerca do comportamento de sinais polissonográficos nos diferentes estágios de sono, coletados a partir de um exame médico. Os sinais polissonográficos mais comuns incluem o Eletroencefalograma (EEG), Eletrocardiograma (ECG), Eletromiograma (EMG), Eletrooculograma (EOG) e o sinal de respiração.

Estudos comprovam que o sinal de EEG apresenta características bem definidas em todos níveis de sono, sendo assim a principal variável polissonográfica. Em contrapartida, o processo de aquisição desse tipo de sinal requer uma mudança de contexto que pode afetar a qualidade de sono habitual do indivíduo em questão. Nesse sentido, esse trabalho propõe avaliar subconjuntos específicos de sinais, contendo ou não o EEG, na finalidade de alcançar resultados comparáveis ao padrão ouro de classificação automática de níveis de sono na restrição desse sinal.

Foram utilizados dois tipos de técnicas de classificação nos testes realizados, sendo uma delas a Máquina de Vetores de Suporte (SVM, do inglês - *Support Vector Machine*), um classificador binário do tipo supervisionado que apresenta um bom desempenho na literatura quando se trata de um baixo número de exemplos de treinamento comparados ao número de características. A outra técnica usada foi o classificador do tipo *Ensemble* em duas variantes, o *Adaboost* e o *Robustboost*, ambas conhecidas como classificadores multiclasse, que fazem o uso de vários algoritmos de aprendizagem combinados entre si.

Foram então definidos três subconjuntos de sinais que seriam utilizados nos três classificadores propostos, em dois cenários de classificação: discretização de 5 níveis de sono e 3 níveis de sono, totalizando 18 testes principais a serem realizados. Para isso, cada sinal passa por um algoritmo próprio de extração de características, onde são extraídos seus parâmetros mais relevantes para essa aplicação. Para validação, essa metodologia foi aplicada a 8 horas de sinais de polissonografia do participante SHHS1-200070 do banco de dados *Sleep Heart and Health Study*.

Resultados preliminares gerados a partir da classificação entre 2 níveis de sono somente com o EEG e a SVM apresentaram taxas de acerto de 91.16% a 96.83% na classificação entre vigília e estágio 3 para um indivíduo. Já os resultados obtidos a partir de classificações feitas com o *Ensemble Adaboost*, somente com o EEG, atingiram uma ordem de 86% no cenário de classificação de 5 níveis de sono e 93% para o cenário de 3 níveis de sono, enquanto que a SVM produziu uma taxa de acerto de 50% em média para os casos analisados.

Na utilização dos subconjuntos 2 e 3 de sinais, que excluem o EEG, o *Ensemble Adaboost* atingiu taxas de acerto da ordem de 83% na classificação de 5 níveis e 90%

para 3 níveis, estabelecendo um padrão de queda de aproximadamente 3% de acerto na restrição desse sinal. Esses resultados sugerem que o sinal de EEG pode de fato ser desconsiderado na classificação de estágios de sono, desde que utilizados o algoritmo *Adaboost* e os sinais do subconjunto 3. Além disso, a SVM não apresentou resultados comparáveis ao *Ensemble*, o que contrasta com alguns resultados encontrados na literatura na área de Engenharia Biomédica. Isso sugere que esse classificador apresenta melhor desempenho para essa aplicação, ao custo de um maior esforço computacional.

Na próxima etapa da pesquisa, os autores pretendem estender essa metodologia para o contexto de treinamento dos classificadores a partir de dados de múltiplos participantes para classificação de sinais de outros participantes. O objetivo é observar se o sistema de classificação pode ser pré-treinado para um novo participante ou se deve ser treinado individualmente para cada usuário.

Palavras-chave: Sinais Polissonográficos, Aprendizagem de Máquinas, Máquinas de Vetores de Suporte, *Ensemble*, Processamento de Sinais, Estágios do sono.

Abstract

The systematic analysis of specific physiological traits is the basis for advanced studies of sleep and for determining which habits, disorders and pathologies negatively affect the sleep cycle. To better understand quality of sleep, it becomes necessary to have analysis regarding the behaviour of polysomnographic signals, acquired from medical examinations, in all the different stages of sleep. The most commonly used polysomnographic signals include the Electroencephalogram (EEG), Electrocardiogram (ECG), Electromyogram (EMG), Electrooculogram (EOG) and the respiration monitoring signal.

Studies show that the EEG signal presents well defined characteristics in all stages of sleep, making it the main polysomnographic variable. However, the process of acquisition of this signal often requires a change in context that can affect the habitual quality of sleep of the analysed individual. In that regard, this study proposes to evaluate specific subsets of signals, some with and some without EEG, with the goal to achieve results that are comparable to the golden standard of automatic classification of sleep stages, even when restricting this signal.

Two major classification algorithms were used for the proposed tests, one of which is Support Vector Machine (SVM), a binary supervised classification algorithm that typically shows good performance when dealt with a small number of training examples compared to the number of characteristics. The other technique used was the Ensemble algorithm, both in the Robustboost and the Adaboost variants, which are known as multi-class classifiers and make use of various small classification algorithms combined.

Three subsets of signals were then defined and used with these three classification algorithms, for two scenarios of classification: discretization of 5 stages of sleep and 3 stages of sleep, making a total of 18 main tests to be performed. To do so, each signal had to go through a unique process of extraction of characteristics, in which their parameters most relevant to this application were extracted. For validation, this methodology was applied to 8 hours of polysomnographic signals from participant SHHS-200070 of the Sleep Heart and Health Study.

Preliminary results generated from the classification of 2 stages of sleep, using only the EEG signal and SVM, yielded a general accuracy of 91.16% to 96.83% in classifying between wakefulness and stage 3 for a given individual. The results obtained from classification performed by Ensemble Adaboost, using only EEG, reached an order of 86% when classifying 5 stages of sleep and 93% when classifying 3 stages of sleep. The SVM algorithm, however, only reached an accuracy of 50% on average, for both of these cases.

When using subsets 2 and 3, which exclude the EEG signal, Ensemble Adaboost achieved general accuracy rates in the order of 83% for the classification of 5 stages of sleep and 90% for 3 stages, establishing a pattern of degradation of approximately 3% of

accuracy when restricting this signal. These results suggest that the EEG signal can in fact be ignored in sleep stage classification when the Ensemble Adaboost and subset 3 are used. Furthermore, SMV did not yield results comparable to the Ensemble counterparts, which contrasts with some results found in other Biomedical Engineering studies. This suggests that, in exchange for higher computational cost, these classifiers yield better results for this application in particular.

For the next stage of the research, the authors intend to extend this methodology into training these classifiers with multiple participants in order to classify the signals from other participants. The goal is to observe whether or not the classification system can be pre-trained for a new participant, as opposed to training it for each individual user.

Keywords: Polysomnographic Signals, Machine Learning, Support Vector Machine, Ensemble, Signal Processing, Sleep Stages.

Sumário

1	Introdução	17
1.1	Contextualização	17
1.2	Definição do Problema e Proposta de Pesquisa	18
1.3	Objetivos	19
1.3.1	Objetivo Geral	19
1.3.2	Objetivos Específicos	19
1.4	Justificativa	19
2	Fundamentação Teórica	21
2.1	Registros Polissonográficos	21
2.1.1	Sinais Bioelétricos	21
2.1.2	Sinal de Respiração	24
2.2	Classificação dos Estágios de Sono	25
2.3	Técnicas de Classificação - Aprendizagem de Máquinas	26
2.3.1	Máquina de Vetores de Suporte - SVM	28
2.3.2	Classificadores do Tipo <i>Ensemble</i>	30
2.4	Análise de Eficiência dos Classificadores	32
2.4.1	Métricas de Desempenho	32
2.4.2	Análise de Histogramas e Matriz de Confusão	33
3	Metodologia	35
3.1	Banco de Dados	35
3.2	Escolha do Conjunto e Subconjuntos de Sinais a Serem Utilizados	36
3.3	Algoritmos Desenvolvidos	37
3.3.1	Algoritmos de extração de Características	37
3.3.2	Algoritmos de Classificação	39
3.4	Experimentos de Classificação dos Estágios de Sono	40
3.4.1	Experimentos Preliminares	40
3.4.2	Experimentos Conduzidos	41
3.5	Análise Estatística da Eficiência dos Classificadores	41
4	Resultados	43
4.1	Resultados para Experimentos Preliminares	43
4.2	Resultados para Experimentos Conduzidos	44
4.2.1	Experimentos Conduzidos para a Classificação dos 5 Níveis de Sono - Grupo A	44

4.2.2	Experimentos Conduzidos para a Classificação de 3 Níveis de Sono - Grupo B	45
4.2.3	Análise de Histogramas e Matrizes de Confusão	46
4.3	Experimentos Adicionais Realizados para Outros Participantes com o <i>Ensemble Adaboost</i>	51
5	Conclusão	53

Lista de Tabelas

2.1	Tabela de contingência com parâmetros necessários para o cálculo de métricas de desempenho. Adaptado de: [7]	33
2.2	Exemplo de uma matriz de confusão para duas classes.	34
3.1	Testes preliminares realizados	40
3.2	Experimentos conduzidos	42
4.1	Taxas de erro e desvio padrão para classificações de sono do participante SHHS1-200070 do banco de dados utilizado no cenário de classificação para todos níveis de sono (Grupo A).	45
4.2	Taxas de erro e desvio padrão para classificações de sono do participante SHHS1-200070 do banco de dados utilizado no cenário de classificação para 3 níveis de sono (Grupo B).	46
4.3	Matriz de confusão gerada na classificação no cenário do Grupo B utilizando o subconjunto 1 de sinais e o classificador <i>Ensemble Adaboost</i>	47
4.4	Matriz de confusão gerada na classificação no cenário do Grupo B utilizando o subconjunto 1 de sinais e o classificador <i>Ensemble Robustboost</i> . .	47
4.5	Matriz de confusão gerada na classificação no cenário do Grupo B utilizando o subconjunto 2 de sinais e o classificador <i>Ensemble Adaboost</i>	47
4.6	Matriz de confusão gerada na classificação no cenário do Grupo B utilizando o subconjunto 2 de sinais e o classificador <i>Ensemble Robustboost</i> . .	47
4.7	Matriz de confusão gerada na classificação no cenário do Grupo B utilizando o subconjunto 3 de sinais e o classificador <i>Ensemble Adaboost</i>	47
4.8	Matriz de confusão gerada na classificação no cenário do Grupo B utilizando o subconjunto 3 de sinais e o classificador <i>Ensemble Robustboost</i> . .	47
4.9	Matriz de confusão gerada na classificação no cenário do Grupo B utilizando o subconjunto 1 de sinais e o classificador SVM.	48
4.10	Métricas de desempenho calculadas para os resultados obtidos com o Grupo B, onde S é a Sensibilidade, P é a precisão e A é a Acurácia.	50
4.11	Taxas de erro e desvio padrão para testes adicionais realizados nos dois cenários de classificação (Grupo A e Grupo B) com diferentes participantes.	52

Lista de Figuras

2.1	Forma de onda do Potencial de Ativação. Imagem de domínio público adaptada, licenciada por <i>Creative Commons Attribution</i>	22
2.2	Ondas características dos sinais de EEG. Em A, estão representadas as ondas alfa; em B, as ondas beta; em C, as ondas teta e em D, delta. Fonte: [21].	23
2.3	Forma de onda do sinal de ECG para um coração saudável, apresentado o complexo QRS e intervalos entre os picos. Imagem de domínio público, criada por Anthony Atkielski.	23
2.4	Sinais de EEG em épocas de 10 segundos, representando os estágios do sono descritos. Adaptado de: [6]	27
2.5	Representação das duas classes, os 'x' e os '*', separados pelos seus hiperplanos. Fonte: [17]	29
4.1	Histograma gerado na classificação no cenário do Grupo B utilizando o subconjunto 1 de sinais e o classificador <i>Ensemble Adaboost</i>	49
4.2	Histograma gerado na classificação no cenário do Grupo B utilizando o subconjunto 2 de sinais e o classificador <i>Ensemble Adaboost</i>	49
4.3	Histograma gerado na classificação no cenário do Grupo B utilizando o subconjunto 3 de sinais e o classificador <i>Ensemble Adaboost</i>	51

1 Introdução

Este trabalho tem como proposta avaliar a classificação automática de estágios de sono para três diferentes subconjuntos de sinais de polissonografia aplicados a três diferentes algoritmos de classificadores automáticos nos cenários de classificação de todos os estágios e na classificação entre vigília, sono leve e sono profundo. Dessa forma, busca-se avaliar a eficiência de sinais e classificadores para os diferentes casos estudados.

1.1 Contextualização

Como função primordial a restauração mental e corporal de um indivíduo, o sono é o estado de consciência reduzida, que processa diversas funções neurológicas [3]. Ao dormirmos, consolidamos memórias de curto prazo em memórias de longo prazo; refinamos nosso rendimento motor; temos nossas funções metabólicas reguladas, dentre tantas outras funções.

Fatores como privação do sono, distúrbios mentais, patologias, transtornos depressivos e até mesmo mudança de fuso horário afetam de forma negativa o ciclo do sono [3]. Há evidências de que, pela relação entre o sono e metabolismo, hábitos irregulares de sono podem acarretar riscos de diabetes, também relacionados a insônia e apneia [9].

Os sistemas biológicos sofrem mudanças fisiológicas durante o sono, principalmente o Sistema Nervoso Central, que através da análise dos sinais de Eletroencefalografia (EEG), foram realizados os primeiros estudos sobre o sono [1], indicando informações úteis sobre a atividade cerebral para o diagnóstico e tratamento de algumas doenças, sendo assim a variável polissonográfica principal. Com o passar dos anos, métodos de classificação dos estágios de sono foram desenvolvidos, a maioria dos quais se utiliza de Redes Neurais (RN) como ferramenta de classificação a partir de sinais processados com a Transformada de Fourier (TF). A taxa de acerto destes métodos encontra-se entre 60% e 90% [15].

Motivados pela propriedade de resolução em tempo-frequência da Transformada de Wavelet (TW), alguns cientistas propuseram as vantagens do uso dessa análise de acordo com o fato de que algumas estruturas de registro de sono tem padrões bem definidos em tempo-frequência [11], permitindo então melhor classificação dos estágios de sono com TW e RN, gerando assim a taxa de 97,5% de acerto [15].

O estudo da Polissonografia abrange o registro de determinadas variáveis fisiológicas [27]. Além do EEG, sinais de Eletrooculografia (EOG), Eletromiografia (EMG), Eletrocardiografia (ECG) e sinais respiratórios são comumente usados nesse estudo [4]. Em 1953, pesquisadores do sono associaram os padrões encefalográficos ao movimento ocular rápido, o REM (do inglês *Rapid Eye Movement*), que caracteriza o sono profundo.

Foi percebida a ocorrência desse estado durante vários momentos do sono, que se alternava com períodos em que a movimentação ocular cessava e o padrão encefalográfico passaria a ser o sono não-REM, associado a ocorrência de sonhos. Notou-se também que a atonia muscular, detectada por EMG, estava relacionada a essa movimentação ocular. Desenvolveu-se então a análise desses sinais em conjunto para a classificação de estágios do sono [1].

1.2 Definição do Problema e Proposta de Pesquisa

Apesar da ciência do sono ser um assunto estabelecido, o conhecimento sobre técnicas de análise de sinais fisiológicos tendem a aumentar a influência desse assunto na ciência médica. Por outro lado, ainda são poucos os estudos relacionados a classificação automática de estágios do sono, já que ainda é um tipo de análise recente e não há padronização dos manuais existentes na área [20].

Historicamente, técnicas de reconhecimento de padrões de sinais são realizadas a partir de uma interpretação visual dos sinais fisiológicos por profissionais especializados na área [20]. Paralelamente, a maior parte das pesquisas voltadas a classificação automática dos estágios de sono estão centradas na análise de sinais de EEG, sinais estes de aquisição mais trabalhosa quando comparado a outros como ECG, EOG e EMG.

Invariavelmente, os processos de aquisição de múltiplos sinais em clínicas de sono requerem uma mudança do contexto com o qual o paciente dorme, em termos de ambiente, posicionamento do corpo e presença de aparelhagem conectada ao corpo para a aquisição dos sinais. Essas mudanças se traduzem em uma sequência de estados de sono observada durante a noite de exame que não necessariamente reflete a qualidade de sono típica ou diária do indivíduo em questão.

Diante disso, a proposta é avaliar subconjuntos específicos de sinais fisiológicos, que resultem em métricas de desempenho semelhantes às obtidas em um conjunto total desses sinais, isto é, verificar se com esses subconjuntos mais restritos já é possível classificar os estágios de forma eficiente. De fato, observa-se que alguns sinais são de aquisição mais complexa e envolvem equipamentos que podem alterar a classificação e, portanto, prejudicar a análise. Neste contexto, deseja-se idealmente conter os sinais menos invasivos, mas de forma a não impactar na avaliação dos estágios.

Classificadores automáticos, como a SVM (do inglês, *Support Vector Machine*) e *Ensemble*, serão usados não somente para a automatização do processo de análise do sono, mas também para garantir que essa classificação esteja o mais condizente possível com os padrões diários de sono do indivíduo estudado.

Uma vez que o sinal de EEG possui a aquisição mais intrusiva e, ao mesmo tempo, a mais útil para a classificação automática [3], a seleção de sinais a serem analisados pelo projeto será feita com o objetivo de avaliar se é possível restringir o uso deste sinal sem

que haja perdas perceptíveis na qualidade de classificação. Dessa forma, serão usados três subconjuntos de sinais para classificação aplicados a dois cenários de classificação: a discretização de todos estágios e a discretização entre vigília, sono leve e sono profundo. Além disso, serão utilizados três algoritmos de classificadores para cada caso estudado.

1.3 Objetivos

1.3.1 Objetivo Geral

O objetivo geral deste trabalho é definido em avaliar e comparar, de forma sistemática, o desempenho de três algoritmos de classificação distintos, aplicados em duas configurações de estágios de sono e utilizando três subconjuntos de sinais polissonográficos.

1.3.2 Objetivos Específicos

Para o desenvolvimento do classificador de sono automático, se faz necessário o alcance de objetivos específicos.

- Proposta e avaliação do conjunto e dos subconjuntos dos sinais a serem utilizados na classificação dos estágios de sono, com base na descrição fisiológica da literatura sobre o assunto e diferentes aspectos do funcionamento do organismo;
- Desenvolvimento de algoritmos de extração de características para cada um dos sinais, de acordo com suas características individuais mais relevantes;
- Desenvolvimento de algoritmos de classificação automática para cada classificador utilizado: SVM, *Ensemble Adaboost* e *Ensemble Robustboost*;
- Realizar a classificação dos sinais nos dois cenários propostos: classificação de todos os estágios e classificação entre vigília, sono leve e sono profundo;
- Avaliar eficiência, em termos de taxas de erro, para cada caso estudado, além de avaliar histogramas e matrizes de confusão para determinar a consistência dos resultados para o caso dos classificadores de melhor desempenho.

1.4 Justificativa

A proposta de se trabalhar com subconjuntos de sinais para a classificação do sono parte da ideia de analisar a eficiência de alguns classificadores baseando-se em um estudo mais concreto a respeito das características fisiológicas dos sinais utilizados. Para garantir essa eficiência, serão feitos testes sobre os subconjuntos escolhidos, no intuito de validar possíveis bons desempenhos para subconjuntos menores de sinais, ou seja, sem o EEG.

Contribuições práticas para desenvolver equipamentos que colem sinais mais simples, podendo ser usados no dia-a-dia, o que possibilitará a determinação da qualidade do sono e poderá fornecer subsídios para a construção de dispositivos de uso pessoal, a partir de subconjuntos menores de sinais que já permitam a classificação.

Dessa forma, a principal contribuição desse trabalho é a implementação de bons classificadores na restrição do sinal de EEG, o que terá grande relevância para a ciência médica, tornando esse estudo mais abrangente, pelo uso dos diversos sinais polissonográficos.

2 Fundamentação Teórica

2.1 Registros Polissonográficos

O registro polissonográfico padrão é realizado em um período de 8 a 12 horas de sono, no qual são coletadas diversas variáveis fisiológicas do indivíduo. Dentre os sinais coletados, destacam-se o EEG, EMG, EOG, ECG e o sinal de respiração [20].

2.1.1 Sinais Bioelétricos

Sinais bioelétricos, como EEG, EMG, EOG e ECG, são aqueles que podem ser medidos em termos de potencial elétrico, seja de forma superficial com o uso de eletrodos de pele, seja de forma invasiva com a incisão de eletrodos no tecido analisado. Os sinais medidos por aparelhos de eletrografia como ECG e EEG refletem o chamado Potencial de Ativação das células do tecido analisado.

Todas as células do corpo humano respondem a estímulos e geram estímulos por meio de Potencial de Ativação. Neste processo, a célula encontra-se inicialmente em repouso e polarizada negativamente, uma vez que possui mais íons negativos em seu interior. Ao ser estimulada, por meio de neurotransmissores ou outro mecanismo, a célula tem alguns de seus canais iônicos abertos, permitindo a entrada de íons positivos e assim elevando o potencial elétrico da célula [10].

Quando o estímulo é forte o suficiente, essa elevação do potencial passa o limiar no qual mais canais iônicos são abertos e o potencial se eleva ao seu limite, chegando a valores positivos e levando a célula a exercer a atividade na qual ela é especializada. No caso de células musculares, elas se contraem; no caso neurônios, elas liberam mais neurotransmissores que por sua vez induzem mais potenciais de ativação em células vizinhas, categorizando-se assim transmissão de informação.

Mecanismos de controle iônico da célula tratam de repolarizá-la negativamente reestabelecer o estado de repouso. Este processo de despolarização e repolarização da célula é denominado Potencial de Ativação e possui sempre a mesma forma genérica vista na Figura 2.1, sendo que diferentes tipos de células possuem diferentes valores de potencial de repouso e limiar, além de trabalharem com diferentes tipos de íons [10].

Sinal de Eletroencefalografia (EEG)

O sinal de EEG é a representação gráfica da atividade elétrica espontânea dos neurônios, ou seja, dos vários potenciais de ativação dessas células ao longo do tempo. A aquisição deste sinal é normalmente obtida de forma não-invasiva por meio da aplicação de eletrodos ao longo da escalpe. Diagnósticos com sinais de EEG tipicamente envolvem análise

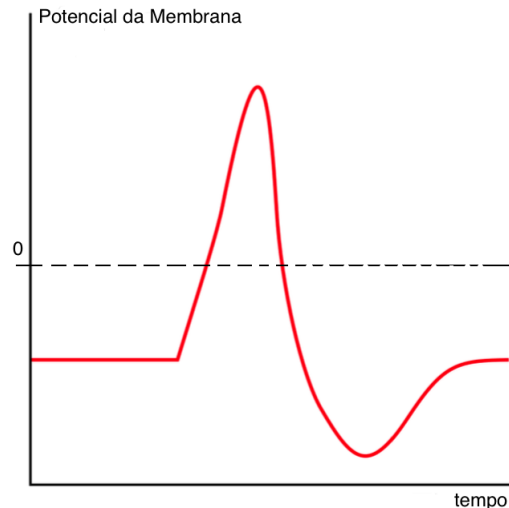


Figura 2.1. Forma de onda do Potencial de Ativação. Imagem de domínio público adaptada, licenciada por *Creative Commons Attribution*.

espectral das ondas, dando portanto maior ênfase às frequências do sinal e menor ênfase à demais características como amplitude, picos e vales, dentre outros [21].

Quando os registros sobre os lobos parietal e occipital estão em cerca de 8 a 13Hz, são caracterizadas as ondas alfa; aumentando de 13 até 30Hz, são as ondas beta. Também são analisadas as ondas delta, de 0.5 a 4Hz e as ondas teta, de 4 a 7Hz [20], como na Figura 2.2. Em análise de sono, a prevalência de um ou mais desses tipos de onda sobre os demais tipos caracteriza determinado estágio de sono. Por exemplo, ondas do tipo alfa e teta são comumente observadas em estágio de transição entre vigília e sono leve.

Sinal de Eletrocardiografia (ECG)

Sinais de ECG são a representação gráfica dos batimentos cardíacos de um indivíduo ao longo do tempo. A aquisição deste sinal é feita de forma não-invasiva, com a aplicação de eletrodos no peito e nos membros do paciente. Estes eletrodos por sua vez detectam as variações elétricas da pele, decorrentes dos vários potenciais de ativação das células dos músculos cardíacos que compõem o batimento cardíaco.

Diferentemente do EEG, o sinal de ECG possui uma forma de onda regular, com processos de despolarização e repolarização das células que geram um traçado previsível. Em um coração saudável, o sinal de EEG apresenta a forma de onda da Figura 2.3.

Diagnósticos realizados com o sinal de ECG levam em conta valores e alterações dos parâmetros apresentados na figura x, como valores dos picos Q,R e S; intervalo PR e intervalo QT [20]. A mesma análise destes parâmetros é usada na classificação de estágios de sono [21].




Figura 2.2. Ondas características dos sinais de EEG. Em A, estão representadas as ondas alfa; em B, as ondas beta; em C, as ondas teta e em D, delta. Fonte: [21].




Figura 2.3. Forma de onda do sinal de ECG para um coração saudável, apresentado o complexo QRS e intervalos entre os picos. Imagem de domínio público, criada por Anthony Atkielski.

Sinal de Eletromiografia (EMG)

Sinais de EMG são representações gráficas das atividades elétricas dos músculos esqueléticos ao longo do tempo. A aquisição desse tipo de sinal é feita com a aplicação de eletrodos ao longo da face, que medem o Potencial de Ativação de Unidades Motoras (em inglês, MUAP). Unidades Motoras são formadas por um grupo de células motoras controladas por um mesmo conjunto de moto-neurônios, células especializadas em realizar a interface entre células nervosas e motoras. A MUAP, portanto, é o somatório dos vários potenciais de ativação das células motoras que englobam a unidade motora.

Na análise de estágios de sono, as características mais relevantes desse sinal são variação de frequência e amplitude, sendo que a presença ou não de tônus (atividade muscular) é o fator necessário para a classificação de estágios de sono [20].

Sinal de Eletrooculografia (EOG)

Sinais de EOG são representações gráficas do movimento dos olhos ao longo do tempo. A aquisição destes sinais é feita de forma não-invasiva por meio da aplicação de eletrodos em cima ou embaixo de cada olho ou então nas laterais externas de cada olho. Os eletrodos medem o potencial córneo-retinal que existe entre as partes dianteiras e traseiras do olho humano. O globo ocular, portanto, age como um dipolo, sendo que a parte traseira é positiva e a parte dianteira é negativa. Quando há um movimento dos olhos para a esquerda, a córnea se aproxima do eletrodo esquerdo levando a um potencial negativo. Analogamente, quando há um movimento dos olhos para a direita, a córnea se aproxima do eletrodo direito, o que gera um potencial positivo em relação aos eletrodos. Em análise de estágios de sono, sinais de EOG são particularmente relevantes para a classificação do sono REM, estágio este em que há um aumento característico na movimentação ocular [20].

2.1.2 Sinal de Respiração

O sinal de respiração se difere dos demais sinais mencionados por não ser de caráter bioelétrico.

Sua aquisição pode ser feita por dois métodos distintos, sendo eles: análise do fluxo de ar e análise de movimento toraxoabdominal. Neste segundo caso, mais aplicado em estudos de sono por ser menos invasivo, o sinal é obtido com a medição da variação de pressão gerada pelo movimento torácico ou abdominal.

Uma cinta inflada com sensores internos de pressão é vestida no paciente e esses sensores resistivos, distribuídos em películas ao longo do comprimento da cinta, registram a variação de pressão decorrente da respiração. Para o estudo de estágios de sono, informações relevantes desse sinal se limitam à amplitude, à regularidade e à frequência dos

movimentos toraxoabdominais [20].

2.2 Classificação dos Estágios de Sono

Rechtschaffen e Kales (1968) descrevem um critério de classificação de estágios de sono a partir do reconhecimento de formas de ondas de sinais de polissonografia, tais como o EEG, EMG e EOG. Observa-se então os estágios de vigília, movimento rápido do olho (REM) e o estágio em que não há movimento rápido dos olhos (NREM), subdividido em mais quatro estágios [19].

- **Estágio W - vigília:** O estágio de vigília pode ser ativo (com alerta) ou passivo (relaxada). É caracterizado por ondas alfa e teta (EEG) relativamente rápidas de baixa amplitude e frequências variadas [20]. Usualmente acompanhado de um tônus muscular alto, verificado por registros de EMG, e movimento dos olhos e pálpebras (piscadas) no registro de EOG [21].
- **Estágio 1:** Transição entre a vigília e os estágios do sono. É caracterizado por uma atividade de EEG com frequências de 3 a 7Hz, ondas alfa e teta, que se aproxima de uma vigília mais branda [20]. Apresenta movimento lento dos olhos e EMG um pouco menos ativo, com duração em media de 1 a 5 minutos e representa 4 a 5% do total de sono ideal [6]. O sinal de ECG apresenta uma diminuição de potência em baixas frequências, com aumento acentuado em altas frequências [26].
- **Estágio 2:** A atividade muscular e o movimento dos olhos diminuem consideravelmente. Esse estágio é definido pela presença de complexos K, que representa uma forma de onda bem delineada, construído por ondas de 12 a 14Hz, representando derivações no registro de EEG [6]. O sinal de ECG não altera seu comportamento [26].
- **Estágio 3:** É caracterizado pela primeira etapa do sono profundo. Estágio onde no mínimo 20% e no máximo 50% do sono é composto por ondas delta, variando de 0,5 a 4Hz [21]. O EOG apresenta movimentos lentos e o EMG, um tônus mais importante [20]. O sinal de ECG não altera seu comportamento [26]. Representa 4 a 6% do total de sono ideal [6].
- **Estágio 4:** É onde 50% ou mais do sono é composto de ondas delta [21]. Representa 12 a 15% do total de sono ideal. Juntamente com o estágio 3, é o período mais restaurador do sono [6]. O sinal de ECG não altera seu comportamento [26]. O EOG ainda apresenta movimentos lentos e o EMG não apresenta alterações. A arritmia respiratória aumenta gradativamente da vigília passa esse estágio [28].
- **Estágio REM - Movimento Rápido dos Olhos:** Onde ocorrem os sonhos, caracterizado por sinais de EEG de baixa intensidade, com atividade cerebral similar

ao estágio 1, porém com níveis baixos de tônus muscular. O EOG apresenta movimentos bruscos rápidos e amplos [20]. O sinal de ECG apresenta um aumento de potência em altas frequências [26] e a arritmia respiratória diminui [28]. Representa 20 - 25% do total de sono ideal [6].

O sinal mais estudado para esse tipo de classificação é o EEG, que apresenta ondas bem definidas para cada estágio, como mostrado na Figura 2.4

Embora os sinais de EEG sejam os mais completos e úteis para a classificação de estágios de sono, outros tipos de sinais como EMG, EOG e ECG também são comumente utilizados como complemento para a classificação. Sinais de EMG e EOG são importantes discriminadores entre os estágios de vigília, estágio 1 e sono REM, por exemplo, dados os diferentes níveis de tônus muscular e movimento dos olhos entre esses estágios [24].

2.3 Técnicas de Classificação - Aprendizagem de Máquinas

Uma vez coletados e processados os sinais de polissonografia, é necessário uma análise sistemática desses sinais para, a partir deles, determinar o estágio de sono em que o indivíduo se encontra a cada instante. Esta análise, historicamente feita de forma manual por meio de observações dos sinais por um especialista, é feita cada vez mais de forma automática utilizando-se de ferramentas de aprendizagem de máquina e técnicas de classificação.

Em linhas gerais, classificação no contexto de aprendizagem de máquina consiste em definir a qual classe pertence determinada instância de um sistema, tendo como base instâncias prévias, cujas classes já estão determinadas, e um conjunto de características que definem essa instância. Técnicas de classificação (ou simplesmente classificadores) são portanto exemplos de aprendizagem supervisionada.

O modelo de um classificador pode ser preditivo ou construídos a partir de um conjunto de dados, como árvore de decisão, redes neurais, máquina de vetores de suporte, entre outros. A aprendizagem, ou treinamento, é então o modelo gerado a partir de dados. Dentre as diferentes configurações de aprendizagem, as mais comuns são as supervisionadas ou não supervisionadas [29].

A aprendizagem supervisionada tem como objetivo prever as características em instâncias invisíveis [29]. Um exemplo clássico dessa classificação é o chamado Iris Flower Data Set, problema este apresentado por Ronald Fisher em 1936 [8]. Neste problema, Fisher propunha uma análise de discriminação de três espécies da flor Íris (Iris setosa, Iris virginica e Iris versicolor) a partir de um conjunto de 50 amostras de cada espécie e quatro características medidas de cada amostra, sendo elas: o comprimento e a largura das

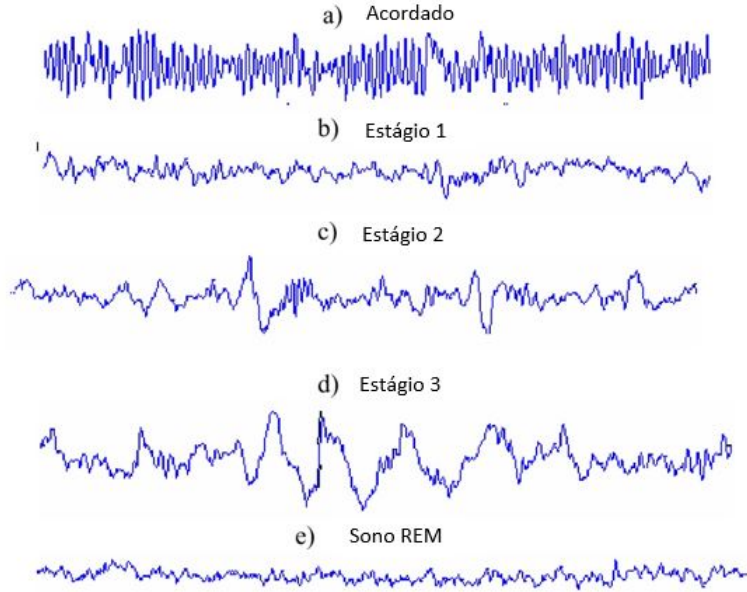


Figura 2.4. Sinais de EEG em épocas de 10 segundos, representando os estágio do sono descritos. Adaptado de: [6]

sépalas e o comprimento e largura das pétalas das flores, em centímetros. Este exemplo é comumente utilizado para demonstrar diversas técnicas de classificação.

Classificadores podem ser definidos como sendo binários ou multi-classe dependendo do número de classes envolvidas no processo. A classificação binária pode ser vista na separação de e-mails como sendo "*Spam*" ou "*Não-Spam*" pelos provedores, por exemplo. A maioria dos classificadores trabalha em princípio com classificação binária mesmo em casos onde há mais de uma classe envolvida. Nestes casos o classificador separa uma única classe das demais, realiza o processo de classificação com estes dois novos sub-grupos (classe selecionada vs. as demais) e então repete o procedimento para todas as outras classes [22].

Além de binários, boa parte dos classificadores é considerada linear, pois pode ser formulada em termos de uma função linear de estrutura, dada por

$$S(X_i, k) = k \times X_i, \quad (2.1)$$

onde $S(X_i, k)$ é saída do classificador que é atribuída a uma classe por limiarização, k é uma constante determinada por treinamento e X_i é cada sinal de entrada.

Para cada instância i do sistema, o vetor de características X_i tem seu valor associado a um vetor de pesos B_k correspondente às k classes possíveis, essencialmente atribuindo uma pontuação $S(X_i, k)$ à classe. A classe predita é, então, a que obtiver maior pontuação. Exemplos comuns de classificadores que seguem essa estrutura são: regressão logística, regressão probabilística, perceptron, perceptron multicamadas, máquina de vetores de

suporte (SVM), entre outros [13, 23].

Independente das técnicas de classificação a serem utilizadas, em se tratando de análise de sinais, é necessário que haja uma boa extração de características destes sinais. Níveis de energia em bandas de frequência, frequências máxima e mínima, variações de amplitude, entre outras, são características que descrevem um determinado sinal e reduzem a quantidade de informação a ser processada pelos classificadores. Uma boa extração de características garante a redução do sinal a ser analisado a um vetor de características mínimo que mantém uma representação fiel deste sinal. No caso dos sinais de EEG coletados, as energias em bandas de frequência dos sinais são as características mais significativas, pois permitem discernir quais tipos de onda (alfa, beta, delta) são mais proeminentes naquela determinada faixa do sinal.

2.3.1 Máquina de Vetores de Suporte - SVM

a SVM (do inglês - *Support Vector Machine*), é um modelo supervisionado associado a algoritmos de aprendizagem que, a partir da análise de dados, reconhecem padrões que são usados para classificação e regressão analítica. Dessa forma, a partir de um dado conjunto de exemplos para treinamento, que pertencem a duas classe, o algoritmo constrói o modelo que irá atribuir cada exemplo a uma classe, caracterizando um classificador linear binário [17].

Os exemplos mapeados de cada classe são separados, divididos por um intervalo claro. Esse intervalo é chamado de hiperplano, caracterizado por um conjunto de pontos x que satisfaz a equação:

$$\langle w, x \rangle + b = 0, \quad (2.2)$$

onde $\langle w, x \rangle$ é um produto interno, sendo w a direção do plano e b é uma constante que determina a posição [17].

Para o caso onde o sistema é de duas dimensões, o hiperplano será uma reta. Logo, o hiperplano sempre terá uma dimensão a menos em relação ao sistema. A tarefa da SVM então é calcular esse hiperplano.

O cálculo é feito partindo da idéia de não apenas definir o hiperplano em si, mas três hiperplanos em paralelo que possuem o mesmo w , mudando somente o b . Esses hiperplanos são definidos por:

$$\langle w, x \rangle + b = 1 \quad (2.3)$$

e

$$\langle w, x \rangle + b = -1. \quad (2.4)$$

Os hiperplanos paralelos estão representados na Figura 2.5. A proposta é maximizar a distância dos hiperplanos do extremo com a condição de se obter a menor quantidade possível de pontos (exemplos) entre eles, o que garante robustez para o sistema.




Figura 2.5. Representação das duas classes, os 'x' e os '*', separados pelos seus hiperplanos. Fonte: [17]

Realizada essa otimização, o que deve ser efetivamente calculado pelo algoritmo são os vetores que se encontram na borda, tangenciando os hiperplanos extremos, os chamados Vetores de Suporte. Conhecendo esses vetores, é possível detectar em qual lado dos vetores se encontra, ou seja, a qual classe pertencem. Os Vetores de Suporte representam um multiplicador de Lagrange, não sendo necessário o cálculo do hiperplano, isso para exemplos linearmente separáveis.

Mesmo para exemplos que não são linearmente separáveis, o algoritmo mapeia uma função de transformação que leva cada ponto de exemplo a um espaço de dimensão maior. Uma vez feita essa transformação, realiza-se a otimização. Escolhendo-se uma função apropriada, a chance de tornar o sistema linearmente separável se torna efetivamente grande.

Os multiplicados de Lagrange que devem ser calculados continuam na dimensão anterior e encontrá-los é a solução de um problema dual. O kernel representa então o resultado produto interno de duas funções de transformação, o que será calculado, ao invés dessa função [17]. A função do kernel mais utilizada está representada na forma:

$$K(x, y) = e^{-\sigma|x-y|^2}, \quad (2.5)$$

onde x e y representam dois vetores (funções de transformação) e σ é o parâmetro a ser alterado em testes para a melhor classificação possível [17].

Os vários tipos classificadores tem desempenhos diferentes em diferentes problemas. O que determina o melhor são testes, mas o fato é que várias variáveis contribuem para o que diferencia o desempenho dos classificadores, uma delas é a quantidade de exemplos disponíveis para treinamento e o nível de separação das classes envolvidas.

Em se tratando da quantidade de treinamento, a SVM é um dos classificadores que permite tradicionalmente o melhor treinamento quando há uma situação em que a quantidade de exemplos é comparativamente pequena com a quantidade de características que está usando. Quando se tem muitos exemplos comparado com a quantidade de característica que se tem, outros classificadores terão empenho tão bom ou até melhor que a

SVM. Apesar de ser uma escolha arbitrária, a SVM é interessante quando a quantidade é relativamente pequena, ou seja, melhor desempenho com poucos exemplos. Como serão testados diferentes subconjuntos de sinais, ter um classificador que não seja tão dependente da quantidade de exemplos é interessante para que não mascare o fato de que se está testando diferentes tipos de sinais, principalmente quando se está trabalhando com o nível de sono. É um classificador que tem tido um bom desempenho em classificação de sinais em diferentes cenários. Tem várias aplicações em classificação de imagem, em sinais de voz, em vários tipos de sinais biológicos e em muitas vertentes da Engenharia Biomédica, além de possuir uma teoria sólida por trás. Dessa forma, escolhendo-se um kernel apropriado em um domínio apropriado, se no domínio associado a esse kernel existe uma separação linear, ele vai separar. Isso é provado matematicamente.

2.3.2 Classificadores do Tipo *Ensemble*

Também conhecido como aprendizagem de vários sistemas classificadores, o *Ensemble* é a técnica que faz o treinamento de vários algoritmos de aprendizagem para resolver um mesmo problema, a partir de um conjunto de algoritmos que combinam entre si [29].

Contém um conjunto de classificadores base gerados a partir de algoritmos base de aprendizado, que pode ser uma árvore de decisão, uma rede neural ou outro tipo de algoritmo. Na maioria dos casos, essa técnica usa um classificador base único para produzir algoritmos homogêneos (do mesmo tipo), produzindo um conjunto homogêneo; ou utilizam múltiplos classificadores para produzir algoritmos heterogêneos (de tipos diferentes), produzindo conjuntos heterogêneos.

A técnica do *Ensemble* é um importante paradigma de aprendizagem desde a década de 1990, que com Hansen e Salamon, foi descoberto que as previsões feitas pelas combinações de um conjunto de classificadores são mais precisas que a de um classificador único.

O método é realizado em dois passos: obtenção do conjunto de algoritmos base de aprendizagem e depois combiná-los. Um bom conjunto base deve ser tão preciso quanto possível e o custo computacional para construí-lo não é tão maior quanto construir um único classificador, isso porque para um único classificador, se faz necessário um conjunto maior de características para classificação e as estratégias usadas na combinação dos conjuntos é simples [29].

Se tratando dos classificadores *Ensemble Adaboost* e *Ensemble Robustboost*, o termo *boosting* se refere a capacidade que os algoritmos de aprendizagem têm para converter *classificadores fracos*, que são apenas um pouco melhores que uma suposição aleatória, em *classificadores fortes*, que estão muito perto de um desempenho perfeito. O procedimento é simples, usando a classificação binária como um exemplo, as instâncias de treinamento são desenhadas num espaço X . A partir de uma distribuição D , temos uma função f .

Supondo que $X = \{X_1, X_2, X_3\}$, cada um tem 1/3 da quantidade de distribuição, sendo que um classificador aleatório teria 50% de erro de classificação nesse caso.

O objetivo é obter um bom classificador, com a menor taxa de erro possível, mas tem-se apenas um classificador base, que é o classificador fraco, com classificações corretas em X_1 e X_2 e classificações erradas em X_3 , com então 1/3 de erro. Denominando esse classificador fraco como h_1 , pode-se derivar a distribuição, obtendo D' , o que torna os erros de h_1 mais evidentes. Pode-se treinar então um classificador h_2 de D' . Supondo que h_2 também é um classificador fraco, com classificações corretas em X_1 e X_3 e classificações erradas em X_2 , combinando h_1 e h_2 de forma apropriada, o classificador terá classificações corretas em X_1 e alguns erros em X_2 e X_3 . Derivando a distribuição mais uma vez, temos D'' , para tornar os erros do classificador combinado mais evidente e treinar um classificador h_3 , com classificações corretas em X_2 e X_3 . Combinando então h_1 , h_2 e h_3 , tem-se o classificador quase perfeito, pois em cada espaço de X tem-se pelo menos duas classificações corretas [29].

Diante disso, o processo de *boosting* funciona de forma a treinar classificadores sequencialmente e combiná-los para previsão, onde os últimos classificadores gerados concentram-se sobre os erros dos classificadores base.

Ensemble Adaboost

O *Adaboost* (do inglês, *Adaptive Boosting*), que é o modelo mais usado nos algoritmos do tipo *boosting*, foi projetado especificamente para problemas de classificação de classes nominais.

Inicialmente, são atribuídos pesos iguais para todas instâncias, que são os dados de treinamento. A partir disso, é implementado um algoritmo de aprendizagem que irá gerar um classificador com esses dados iniciais e então atribuir pesos de acordo com a classificação feita.

Os exemplos corretamente classificados têm seus pesos diminuídos, enquanto os exemplos mal classificados têm seus pesos aumentados. Assim, para as próximas iterações, serão usados esses dados reponderados, agora na função de classificar as instâncias que anteriormente foram mal classificadas [12].

No processo de treinamento do classificador fraco, deve ser encontrado um limiar que melhor separe os exemplos positivos dos negativos. É então utilizada a paridade, que indica se o valor exemplo classificado como positivo deve estar abaixo ou acima desse limiar. Dessa forma, o classificador fraco é:

$$h_j(x) = \begin{cases} 1, & \text{se } p_j f_j(x) < p_j \theta_j \\ 0, & \text{caso contrário,} \end{cases} \quad (2.6)$$

onde p_j é a paridade, $f_j(x)$ é o valor do exemplo classificado e θ_j é o limiar. Para o caso

em que os exemplos positivos são classificados abaixo do limiar, a polaridade recebe 1, e, caso contrário, -1 [12].

Esse conjunto de classificadores fracos criados são então usados para fazer um classificador forte, que será associado a pesos com classificação mais precisa que a anterior.

$$H(x) = \sum \alpha_j h_j(x), \quad (2.7)$$

onde $H(x)$ é o classificador forte e α_j é o peso associado ao classificador fraco $h_j(x)$ [12].

Esse algoritmo foi originalmente projetado para dados limpos, mostrando-se então ser muito sensível a ruídos. Notou-se que, se um exemplo não fosse classificado corretamente, seu peso aumenta drasticamente e, conseqüentemente, como o *Adaboost* ainda tenta fazer a classificação correta, o seu desempenho diminui.

Diante disso, esse algoritmo possui algumas variações que minimizam esse problema com o ruído, como: *Madaboost*, *Filterboost* e BBM (do inglês, *Boosting By Majority*) [29].

Ensemble Robustboost

O *Robustboost* é uma melhoria do *Brownboost*, que é uma versão adaptável do BBM, com característica de tolerância ao ruído. Com isso, o *Robustboost* melhora essa capacidade de tolerância ao ruído, que, ao invés de minimizar o erro de classificação, aumenta a margem de classificação normalizada.

Agora é utilizado o processo de retorno de média de Ornstein-Uhlenbeck, que é semelhante à derivação usada no *Brownboost*. Dessa forma, o *Robustboost* faz com que a margem de classificação normalizada tenda a ser maior que a meta, enquanto o *Brownboost* apenas faz com que ela tenda a ser maior do que zero [29].

2.4 Análise de Eficiência dos Classificadores

2.4.1 Métricas de Desempenho

Para a classificação em duas categorias, como na SVM, são necessários alguns cálculos de métricas de desempenho para verificar a eficiência do classificador. Baseado em um modelo de classes positiva e negativa, um classificador é mapeado em instâncias para classe real e classe hipotética, que pode gerar quatro possíveis resultados [7]:

- Se a instância é positiva e é classificada como positiva, gera um Verdadeiro Positivo (VP);
- Se a instância é positiva e é classificada como negativa, gera um Falso Negativo (FN);

- Se a instância é negativa e é classificada como negativa, gera um Verdadeiro Negativo (VN);
- Se a instância é negativa e é classificada como positiva, gera um Falso Positivo (FP).

Considerando o classificador e seus instâncias, é possível gerar uma tabela de contingência construída a partir das combinações descritas na Tabela 2.2.

A partir da tabela, são calculadas as métricas de desempenho do classificador. A Sensibilidade é a representação da taxa de verdadeiros positivos que o sistema de classificação irá gerar.

$$S = \frac{VP}{T_p}, \quad (2.8)$$

onde S é a sensibilidade e T_p é o total de positivos.

Resultante da taxa de dispersão entre os valores, também será calculada a Precisão.

$$P = \frac{FP}{VP + FP}, \quad (2.9)$$

onde P é a precisão.

O cálculo da taxa de Acurácia definirá o quão próxima a classificação está de seu valor real.

$$A = \frac{VP + VN}{T_p + T_n}, \quad (2.10)$$

onde A é a acurácia e T_n é o total de negativos.

E por fim, a Medida F irá representar a relação entre a precisão e sensibilidade do classificador. Essa medida é alta apenas se os valores de precisão e sensibilidade forem elevados, sendo assim, caso um desses valores for maior que o outro, a medida F será baixa.

$$F = \frac{2}{\frac{1}{P} + \frac{1}{S}}, \quad (2.11)$$

onde F é a medida F.

2.4.2 Análise de Histogramas e Matriz de Confusão

Histogramas são representações gráficas da distribuição de valores numéricos para determinada variável contínua e são utilizados para estimar a distribuição de probabilidade dessa variável [16].

Tabela 2.1. Tabela de contingência com parâmetros necessários para o cálculo de métricas de desempenho. Adaptado de: [7]

Classe Hipotética	Classe Real	
	Verdadeiro Positivo	Falso Positivo
Total:	Falso Negativo	Verdadeiro Negativo
	Positivo	Negativo

Em um histograma, o intervalo total de valores possíveis para a variável em questão é dividido em intervalos menores, denominados bins, aos quais são então atribuídos a quantidade de instâncias de valores da variável que pertencem a cada intervalo. As quantidades de instâncias, também chamadas de frequências, são comumente representadas por barras de comprimento proporcional às frequências de cada bin.

A quantidade de bins necessária varia de acordo com a aplicação e não existe uma quantidade ideal de bins, de modo que diferentes tamanhos de bins permitem visualizar diferentes aspectos dos dados coletados. No geral, bins mais largos são utilizados quando deseja-se reduzir o efeito indesejado de ruído, enquanto bins mais curtos (e portanto mais numerosos) são usados para se obter maior precisão na estimativa da densidade de probabilidade da variável. De qualquer forma, comumente utilizam-se bins de tamanhos iguais e consecutivos, de forma a manter o caráter contínuo da variável em questão.

De um modo geral, quanto maior o número de instâncias da variável, melhor é a estimativa da distribuição de probabilidade que o histograma oferece [16].

Matrizes de confusão, também conhecidas como matrizes de erro, são tabelas usadas para descrever a performance de algoritmos de classificação, principalmente algoritmos de classificação supervisionada.

A matriz de confusão compara o vetor de classes resultante do processo de classificação com o vetor de classes de validação. As linhas da matriz representam os resultados obtidos para cada classe e as colunas da matriz representam os valores reais das classes. Cada instância de classificação é então posicionada na matriz de acordo com a relação entre "valor esperado" e "valor obtido". A Tabela 2.2 ilustra um exemplo simples com apenas duas classes, porém a matriz de confusão é também válida para algoritmos multiclasse [7].

Tabela 2.2. Exemplo de uma matriz de confusão para duas classes.

n = 165	CLASSES DE VALIDAÇÃO		
	CLASSES	A	B
RESULTADOS	A	50	10
	B	5	100

Em qualquer matriz de confusão, as instâncias corretamente classificadas pelo algoritmo encontram-se na diagonal principal.

A partir da matriz de confusão, é possível obter todas as métricas de desempenho já mencionadas para cada classe do sistema. Verdadeiros Positivos são obtidos a partir do elemento da diagonal principal referente à classe em questão; Falsos Positivos são obtidos com o somatório de todos os elementos da linha referente a essa classe, exceto o elemento da diagonal principal; Verdadeiros Negativos são obtidos com o somatório de todos os elementos da coluna referente a essa classe, exceto o elemento da diagonal principal; Falsos Negativos são obtidos com o somatório de todos os elementos restantes [7].

3 Metodologia

Essa pesquisa se fundamenta em experimentos com três subconjuntos de sinais de polissonografia provenientes do banco de dados do *Sleep Heart and Health Study* (2005) [14], disponibilizado para a pesquisa.

Esse capítulo descreve a metodologia utilizada, organizada em três partes. Para a primeira parte, serão descritos os algoritmos implementados para a extração de características dos sinais de polissonografia escolhidos, bem como os algoritmos de treinamento e validação para os três classificadores utilizados: SVM multi-classes, Ensemble Adaboost e Ensemble Robustboost.

Depois da implementação dos algoritmos, na segunda parte da metodologia serão detalhados os grupos de teste selecionados para a pesquisa, definindo, para cada grupo, as combinações de sinais envolvidos, os conjuntos de classes a serem avaliados e os classificadores adotados. Também serão explicados as rotinas de treinamento e validação adotadas, bem como a elaboração dos histogramas de desempenho a serem analisados.

Finalmente, para a terceira parte, serão descritos os cálculos das métricas de desempenho e a forma como os resultados de cada grupo de teste serão comparados e avaliados.

3.1 Banco de Dados

Em todos os experimentos foram utilizados sinais do banco de dados provindo do protocolo do SHHS (*Sleep Heart and Health Study*), promovidos pelos institutos americanos do coração, pulmão e sangue [14].

O estudo foi realizado com 6000 voluntários, sendo estes 3000 homens e 3000 mulheres, todos com idade acima de 40 anos. Para cada voluntário foram coletados 14 sinais distintos no período de uma noite, dentre os quais encontram-se: EEG primário, EEG secundário, EMG, EOG esquerdo, EOG direito e ECG.

As taxas de amostragem destes sinais são relativamente baixas, 125 Hz para EEG e ECG e 50 Hz para os demais sinais. Estes valores reduzidos de taxa de amostragem são possivelmente decorrentes do volume elevado de amostras.

No estudo original, para todos os sinais atribuíram-se faixas de 30 segundos a partir das quais foram feitas classificações manuais dos estágios de sono, incluindo vigília. A classificação automática por meio de algoritmos de aprendizado supervisionados, proposta nesta metodologia, terá como base essas classificações manuais já realizadas e, portanto, será aplicada nas mesmas faixas de 30 segundos definidas pelo estudo original.

Embora o banco de dados obtido do estudo original seja de grande porte, contendo em torno de 6000 participantes e analisando 14 sinais distintos para cada um destes, em se

tratando de um único participante, existem disponíveis apenas duas amostras, coletadas com dois anos de diferença.

Além disso, o banco de dados tem um viés para participantes com problemas de apnéia, uma vez que a pesquisa tem como objetivo primário definir correlação entre alta incidência de ronco e aumento do risco de problemas cardio-vasculares [14].

Conseqüentemente, há uma variação grande na qualidade dos sinais obtidos comparando participante a participante. Alguns participantes não apresentam amostras de nível de sono 4, por exemplo, enquanto outros sequer chegam ao sono REM, ou seja, há perda de sinais entre participantes distintos. Portanto, para que testes sejam feitos com múltiplos participantes, faz-se necessário haver um trabalho de pré-seleção dos sinais de participante, de modo a minimizar o efeito dessas discrepâncias. Esta pré-seleção deve ser feita a princípio de forma manual e com o auxílio de especialistas do sono, o que foge do escopo inicial do trabalho.

Diante destas limitações, propõe-se que a análise dos sinais, descrita a seguir, seja feita com o sinal de um único participante, SHHS1-200070, escolhido aleatoriamente e sob o qual serão testados todos os cenários de combinação a serem descritos. Em seguida, quatro outros participantes são testados e seus resultados combinados em um resultado final de análise de classificação.

3.2 Escolha do Conjunto e Subconjuntos de Sinais a Serem Utilizados

O conjunto de sinais a serem trabalhados para o desenvolvimento dos experimentos propostos serão os principais sinais da polissonografia, o EEG, EOG, EMG, ECG e respiração.

Como demonstrado na Seção 2.2, os sinais de polissonografia apresentam diferentes comportamentos para cada estágio, o que pode servir de parâmetro na escolha dos subconjuntos a serem utilizados. Nota-se então que o EEG é de fato o sinal mais completo para o estudo dos níveis de sono. O principal objetivo é então realizar experimentos com e sem o uso desse sinal, avaliando assim a eficiência dos classificadores em vários casos. Para isso, foram definidos 3 subconjuntos a serem trabalhados, são eles:

- 1º subconjunto: EEG, EMG, EOG e ECG
- 2º subconjunto: EMG, EOG e ECG
- 3º subconjunto: EMG, EOG, ECG e Respiração

A escolha do primeiro subconjunto foi adotado como um resultado base de comparação com os outros subconjuntos, por ser o subconjunto mais completo em termos de

características. Para o segundo subconjunto, será avaliada a eficiência dos classificadores sem o uso do EEG. Por fim, o terceiro subconjunto irá avaliar como o sinal de respiração poderá alterar ou não os resultados obtidos.

3.3 Algoritmos Desenvolvidos

Para realizar a classificação dos estágios do sono, os sinais de polissonografia passam pelo processo de extração de características, para depois serem treinados e classificados. Para isso, foi utilizado o software MATLAB® na implementação dos algoritmos desenvolvidos.

3.3.1 Algoritmos de extração de Características

A extração de características é diferente para cada sinal, isto é, cada sinal apresenta um conjunto próprio de parâmetros ou características que idealmente representem seus respectivos sinais originais em aplicação de determinado algoritmo, sem que se faça necessário utilizar os sinais como um todo. Dessa forma, foram criados algoritmos de extração de características para cada sinal, todos aplicados em janelas de 30 segundos, tal qual foi feita a classificação manual dos estágios de sono da pesquisa original.

EEG

A extração de características no EEG foi aplicado em janelas de 30 segundos, onde são geradas 10 características, referentes a quantidade de bandas em que o sinal é separado. Para isso, o sinal passa por um filtro digital do tipo IIR (do inglês - *Infinite Impulse Response*), caracterizado por apresentar uma resposta ao impulso de duração infinita. O filtro escolhido para isso foi o filtro *Butterworth*, pois apresenta resposta em frequência muito plana (com baixo nível de ripple) na banda passante e se aproxima de zero na banda de rejeição, com ordem máxima igual a 10, que diminuirá de acordo com a estabilidade do filtro, isto é, a ordem do filtro diminui até que ele esteja estável.

Também foi implementado um teste de estabilidade, onde são calculados os pólos da função de transferência do filtro, que devem permanecer dentro do círculo unitário. O filtro terá então a utilidade de separar o sinal nas bandas de frequência desejadas, passando por filtros passa-bandas até chegar na última divisão, que será um filtro passa-altas. Depois disso, é calculada a energia de cada banda do sinal, que é a característica de interesse do sinal, onde cujos valores serão armazenados em um vetor, posteriormente utilizado na classificação.

ECG

Diferentemente do sinal de EEG, cujas características principais estão associadas ao nível de energia em bandas de frequência, o sinal de ECG concentra suas informações mais relevantes na própria forma de onda, mais precisamente nos picos e vales que representam o batimento cardíaco.

O algoritmo proposto extrai as características do sinal de ECG primeiramente detectando os picos Q, R e S, em cada faixa de 30 segundos. A alta complexidade associada a detecção dos picos Q, R e S, contudo, fez com que fosse necessário adaptar um algoritmo pré-existente, proposto no TCC da aluna Edilaine G. C. de Faria [5], uma vez que o desenvolvimento de um algoritmo próprio de detecção de picos fugiria do escopo do trabalho.

O programa resultante realiza a detecção dos picos Q, R e S aplicando um janelamento com uma Wavelet a partir da segunda derivada da Gaussiana ao sinal. Este janelamento tem forma de onda similar ao sinal de ECG típico e é aplicado de modo a reduzir o efeito de ruído do sinal e destacar os picos principais. De posse do sinal janelado, o algoritmo define a localização de todos os picos do sinal por meio de cálculo diferencial, definindo *thresholds* ou limiares que são usados como referência.

Uma vez definida a posição de todos os picos, o programa aplica três SVM ao sinal, cada uma manualmente treinada para a detecção de picos Q, R e S em um sinal de ECG padrão. O algoritmo, portanto, retorna a posição de todos os picos da faixa do sinal em questão e a quais tipos de picos eles pertencem, Q, R, S ou indefinido. Diante disso, o vetor de características gerado possui 6 posições, referentes a média dos intervalos entre os picos R; a variância desses intervalos; a média e variância das relações entre todos os picos R e S subsequentes; e a média e a variância dos intervalos entre picos Q e S.

EMG, EOG e Respiração

Para esses sinais, serão obtidas características de amplitude e frequência para cada janela. A medida de amplitude a ser adquirida é o valor eficaz, ou RMS (do inglês - *Root Mean Square*), denominado Valor Quadrático Médio, que representa o valor obtido pela raiz quadrada da média das amplitudes da janela em questão. Essa é uma medida usual quando se trabalha com esses tipos de sinais, principalmente EMG e EOG, devido as evidências de que é o parâmetro que melhor reflete seu comportamento durante uma contração muscular [2].

Para se obter a frequência, o sinal passa pelo processo da Transformada de Fourier, também para cada janela. Diante disso, a frequência mediana divide o espectro do sinal em duas regiões de energia (altas frequências e baixas frequências). A literatura indica que essa é uma medida que fornece uma estimativa confiável, não tendenciosa do espectro de frequência [18].

Essas medidas serão obtidas com janelas de 3 segundos, para o EMG e o EOG, e janelas de 6 segundos para o sinal de Respiração. Além disso, para o sinal de Respiração, também será extraído o parâmetro HE (do inglês - *Hurst Exponent*), baseado em sons respiratórios.

O *Hurst Exponent* é uma medida estatística usada para a classificação de séries temporais a longo prazo [25]. Existem alguns métodos adequados para o cálculo desse parâmetro na classificação de séries temporais de curto prazo.

$$\left(\frac{R}{S}\right)_t = C \times t^{HE}, \quad (3.1)$$

onde R representa a diferença do valor máximo pelo valor mínimo da variância acumulada de cada valor de entrada (nesse caso, o sinal de Respiração); S é o desvio padrão desses valores; e C é uma constante considerada igual a 1.

O vetor de características para os sinais de EMG e EOG armazenará duas características para janelas de 3 segundos, o valor RMS e a frequência mediana. Para o sinal de respiração, além desses valores, terá o HE, para janelas de 6 segundos.

3.3.2 Algoritmos de Classificação

Os algoritmos de classificação adotados para os três classificadores deste projeto, SVM, *RobustBoost* e *AdaBoost* seguem a mesma lógica descrita a seguir, sendo variadas apenas as funções do software MATLAB® que efetivamente implementam os classificadores.

O primeiro passo é definir as matrizes de características e de classes que serão utilizadas. A matriz de características é obtida diretamente a partir dos algoritmos de extração previamente descritos, sendo possível escolher quais sinais são usados em cada teste.

A matriz de classes, por sua vez, é obtida a partir do banco de dados para participante em questão, que contém as classificações manuais previamente realizadas. É necessário, contudo, definir com qual dos grupos de classe será trabalhado em cada teste. Para o Grupo A, o algoritmo reduz o número de classes de 6 (nível de sono de 0 até 5) para 5 (nível de sono de 0 até 5, mesclando níveis 3 e 4). A decisão de unificar os níveis 3 e 4 foi decorrente da observação de que o nível 4 não estava presente na maioria dos participantes analisados, o que impossibilitaria a aplicação dos classificadores. Para o Grupo B, o algoritmo reduz o número de classes de 6 para 3, de modo que os níveis 1,2 e 5 (REM) são unificados em uma única classe "sono leve" e os níveis 3 e 4 são mais uma vez unificados em uma única classe "sono profundo".

Obtidas as matrizes de características e de classes, ambas são particionadas em dois grupos: treinamento e validação. Este particionamento é feito de forma aleatória, sendo definida apenas a porcentagem de treinamento desejada para cada teste.

As duas matrizes de treinamento são então aplicadas aos algoritmos de treinamento multiclasse desenvolvidos para cada classificador. Nos três casos, o programa aplica

o conceito de classificação multiclass all-vs-one, na qual cada classe é separada das demais, atribuída um valor 1 enquanto às restantes é atribuído valor 0. As funções de classificação e *svmtrain()* e *fitEnsemble()*, disponíveis pela plataforma Matlab, são então aplicadas gerando a struct de classificação. Este processo de isolamento de uma classe das demais é então repetido para todas as classes, ao final sendo gerado um conjunto de *Structs*.

Este conjunto de *Structs* por sua vez é utilizado pelo algoritmo de validação multiclass, que aplica cada Struct à matriz de características de validação, utilizando-se das funções *svmclassify()* para a SVM e *predict()* para *RobustBoost* e *AdaBoost*. Ao final, são geradas o mesmo número de matrizes resultantes que o número de *Structs* e essas matrizes resultantes são então sobrepostas, de modo a obter uma única matriz de resultados como todas as classes trabalhadas.

Ao final do processo, há duas matrizes de classes a serem utilizadas para análise: a matriz de classes de validação, obtida com o particionamento aleatório da matriz de classes original; e a matriz de classes de resultados, obtida ao aplicar os classificadores à matriz de características de validação, como descrito a cima.

O número de vezes em que este algoritmo é aplicado para diferentes combinações de sinais de treinamento e de validação é ajustado de acordo com os teste em questão e, a partir das duas matrizes de análise, obtêm-se todos os parâmetros de análise explicados a seguir.

3.4 Experimentos de Classificação dos Estágios de Sono

3.4.1 Experimentos Preliminares

Para o TCC 1, os experimentos foram conduzidos com base em características apenas do sinal de EEG e utilizando apenas a SVM como classificador, onde foram realizados vários testes, representados na Tabela 3.1.

Em um primeiro momento, foi verificada a classificação para apenas um indivíduo,

Tabela 3.1. Testes preliminares realizados

Tipo de teste (estágio)	Número de participantes	Número de bandas de frequência	Porcentagem de treinamento	<i>rbf_ sigma</i>
0 vs 3	1	5, 10 e 15	25, 40 e 50%	0.4, 0.6 e 0.9
2 vs 5	11	10	60%	0.4
1 vs 5				
2 vs 3				
0 vs 3				
0 vs 1				
0 vs 5				
3 vs 5				

com diferentes bandas de frequência, porcentagem de treinamento e *rbf_sigma*, entre vigília e nível 3 do sono, que foram escolhidos devido ao maior número de amostras no ciclo de sono deste indivíduo em específico. O algoritmo foi executado para 5, 10 e 15 bandas, valores de *rbf_sigma* iguais a 0.4, 0.6 e 0.9 e porcentagem de treinamento de 25%, 40% e 60%. A performance resultante da SVM é obtida com a análise dos valores de taxa de erro, acurácia e precisão resultantes e a média desses valores foi obtida com 1000 realizações do programa.

Para um segundo experimento, um total de dez sinais foram utilizados para o treinamento da SVM e um décimo-primeiro sinal usado para o teste do classificador. Esta segunda abordagem é uma alternativa mais generalizada para a classificação dos sinais de determinado indivíduo, visto que não é necessário partir de uma classificação manual dos níveis de sono deste mesmo indivíduo para que se tenha um acompanhamento diário de seus níveis de sono.

Neste caso, a classificação foi realizada para 10 bandas de frequências do EEG, com 60% de treinamento e um *rbf_sigma* igual a 0.4. Entretanto, foi avaliada a performance do classificador em diferentes estágios: estado de sono basal vs sono REM (2 vs 3); basal vs sono profundo (2 vs 3); profundo vs REM (3 vs 5); estágio de transição vs sono REM (1 vs 5); vigília vs transição (0 vs 1); vigília vs sono profundo (0 vs 3); vigília vs sono REM (0 vs 5).

3.4.2 Experimentos Conduzidos

Depois de avaliar os classificadores nos diferentes estágios apenas usando o sinal de EEG e a SVM, foi escolhido um conjunto e os subconjuntos dos sinais a serem utilizados nos experimentos, que estão especificados na Seção 3.2. Com a Tabela 3.2, nota-se que os experimentos agora envolvem dois grupos de classificação, onde o Grupo A classifica todos os estágios de sono e o Grupo B classifica em vigília, sono leve e sono profundo. Além de acrescentar sinais para a classificação, agora serão usados 3 classificadores diferentes para cada experimento proposto, totalizando então 18 testes.

3.5 Análise Estatística da Eficiência dos Classificadores

Uma vez realizados os testes de classificação propostos, o interesse é definir o quão eficiente é o sistema em classificar os níveis de sono nas diferentes situações consideradas, ou seja, quais são as vantagens e desvantagens de cada subconjunto de sinais para qual tipo de classificador utilizado em questão de taxas de erro.

Para os experimentos preliminares, por se tratar de classificações para apenas 2 níveis de sono, foram calculadas as métricas de desempenho descritas na Seção 2.4.1. Foi criado então um algoritmo para calcular a média desses valores em cada um dos casos de

Tabela 3.2. Experimentos conduzidos

Tipo de classificação	Subconjunto de sinais	Classificador
Grupo A: Todos os estágios	EEG + EMG + EOG + ECG	SVM
		<i>Ensemble Adaboost</i>
		<i>Ensemble Robustboost</i>
	EMG + EOG + ECG	SVM
		<i>Ensemble Adaboost</i>
		<i>Ensemble Robustboost</i>
	EMG + EOG + ECG + Respiração	SVM
		<i>Ensemble Adaboost</i>
		<i>Ensemble Robustboost</i>
Grupo B: Vigília, sono leve e sono profundo	EEG + EMG + EOG + ECG	SVM
		<i>Ensemble Adaboost</i>
		<i>Ensemble Robustboost</i>
	EMG + EOG + ECG	SVM
		<i>Ensemble Adaboost</i>
		<i>Ensemble Robustboost</i>
	EMG + EOG + ECG + Respiração	SVM
		<i>Ensemble Adaboost</i>
		<i>Ensemble Robustboost</i>

classificação testados.

Os experimentos realizados na segunda parte do projeto, contudo, envolvem classificação multiclasse. Logo, a realização de análises de falso-positivo, falso-negativo e as demais métricas de desempenho utilizadas na parte 1 devem ser feitas para cada classe dos testes. Dessa forma, além da média de taxa de erro, decidiu-se pela implementação de gráficos com os histogramas dos resultados para observar a distribuição destes. Decidiu-se também pela análise com matriz de confusão de determinados grupos de teste, a fim de determinar a distribuição dos erros de classificação cometidos pelos classificadores e gerar as métricas de desempenho para cada classe.

4 Resultados

Diante dos experimentos propostos, este capítulo apresenta e discute os resultados obtidos em cada teste.

4.1 Resultados para Experimentos Preliminares

Os testes realizados na primeira fase limitaram-se à análise de extração de características apenas dos sinais de EEG, disponíveis pelo banco de dados, e à classificação de dois níveis de sono de um participante a partir destas características.

O objetivo desta primeira etapa foi definir quais os parâmetros de aquisição de características do EEG resultam nas melhores taxas de acerto ao utilizar o classificador SVM, parâmetros estes que são: número de bandas de frequência com que o sinal é dividido, valor de *rbf_sigma* (parâmetro associado a função núcleo da SVM) e porcentagem de treinamento e teste usados para a classificação.

Para a classificação entre a vigília e o estágio 3 do sono, considerando que foi apenas utilizado um sinal de EEG e o classificador SVM, foram obtidas taxas de erro entre 3.17% e 8.84%, o que sugere que as características utilizadas contêm as informações necessárias para determinar esses estágios. Cabe ressaltar que esses resultados ainda são restritos a apenas dois estágios de sono, correspondentes à vigília e ao nível 3 (sono profundo). Os demais estágios incluem condições intermediárias, o que significa que a classificação nestes casos pode levar a resultados de menor acurácia e precisão se forem usadas apenas as mesmas características e o mesmo classificador.

Para valores fixos de porcentagem de treinamento e *rbf_sigma*, 10 bandas produz uma taxa de erro necessariamente menor que 5 bandas, porém não há uma mudança significativa ao aumentarmos seu valor para 15 bandas. Fixados os valores de número de banda (10) e porcentagem de treinamento (40%), valores mais baixos de *rbf_sigma* resultam em taxas de erro menores. Entretanto, a literatura mostra que valores excessivamente baixos do sigma tendem a piorar o desempenho de SVM para aplicações mais genéricas, efetivamente tornando enviesado o classificador. Dessa forma, *rbf_sigma* igual a 0.4 mostra-se ideal para a pesquisa.

Depois de fixados os parâmetros de classificação, em uma análise para 11 sinais, foram obtidas taxas de erro entre 1.86%, para classificação dos estágios de sono basal vs sono profundo (2 vs 3) e 10.48%, para sono basal vs sono REM (2 vs 5).

Estes resultados preliminares, portanto, mostram que utilizando 10 bandas de frequência, *rbf_sigma* entre 0.6 e 0.9 e porcentagem de teste entre 20% e 40% geram as melhores características a serem usadas pelo classificador.

4.2 Resultados para Experimentos Conduzidos

Os experimentos preliminares realizados apontam que em aplicações para classificação de 2 níveis de sono, utilizando a SVM, o sinal de EEG sozinho proporciona taxas de acerto da ordem de 90%. Embora estas taxas de acerto obtidas tenham sido altas, estavam limitadas apenas a comparação de dois estágios de sono e ao sinal de EEG. Uma vez que o objetivo do projeto envolve classificar no mínimo 3 níveis distintos de estágio de sono (vigília, sono leve e profundo), sabia-se que estes resultados da ordem de 90% de acerto não seriam mantidos. Tendo isso em vista, decidiu-se incluir outros dois métodos de classificação: *Ensemble Robustboost* e *Ensemble Adaboost*, apontados pela literatura como ideais para cenários em que o número de características usadas é maior.

Os testes propostos pela Tabela 3.2, na Seção 3.4.2, foram realizados para o participante SHHS1-200070 do banco de dados utilizados neste trabalho. Os valores de taxa de erro obtidos para cada teste encontram-se nas Tabelas 4.1 e 4.2.

4.2.1 Experimentos Conduzidos para a Classificação dos 5 Níveis de Sono - Grupo A

Para o cenário de classificação dos 5 níveis de sono (vigília, estágios 1, 2, 3 e 4 e REM - Grupo A), a Tabela 4.1 apresenta as taxas de erro obtidas. Além dos três subconjuntos propostos, foram realizados testes de classificação utilizando exclusivamente o sinal de EEG e exclusivamente com o sinal de ECG para servirem de comparação.

Para as classificações realizadas apenas com o sinal de EEG, observa-se que a SVM gerou o pior resultado, com taxa de erro na ordem de 21%. Os classificadores *Ensemble*, por sua vez, obtiveram resultados na ordem de 14% de taxa de erro, sendo que o *Robustboost* obteve o melhor resultado, com 13.5% de erro. Em aplicações clínicas de classificação de estágios de sono, esses valores obtidos pelos classificadores *Ensemble* já seriam úteis, principalmente considerando que todos os níveis de sono são discretizados neste grupo de teste. Esses resultados corroboram a importância do sinal de EEG em tarefas de classificação de estágios de sono, sejam elas de forma manual ou automatizada.

Observa-se que o classificador de SVM obteve os piores resultados comparado aos outros classificadores, em todos os subconjuntos de sinais trabalhados. Percebe-se então que a SVM apresenta taxas de erro na ordem de 50% para os estes subconjuntos. Isso significa que a cada 2 classificações, a SVM acerta 1, resultado este que é melhor que o de um sorteio aleatório (que seria da ordem de 80% de erro para 5 níveis de sono), mas ainda assim de duas a quatro vezes pior que os resultados dos classificadores *Ensemble*. Em contrapartida, quando usado somente o sinal de EEG, a taxa de acerto da SVM é de 78.8%, o que sugere que a adição de mais características a este classificador reduziu seu desempenho. A mesma resposta negativa ao acréscimo de características não foi

observado pelos demais classificadores.

O *Ensemble Adaboost* obteve os melhores resultados, comparado aa SVM e *Ensemble Robustboost*, conseguindo taxas de acerto de 83.5% e 83.6% para os subconjuntos 2 e 3 de sinais, ambos os quais não incluem o sinal de EEG. Estes resultados começam a se aproximar da taxa de acerto adquirida somente com o sinal de EEG, que foi de 85.6%. Isso indica que esse classificador já consegue um desempenho comparável ao EEG quando se restringe o uso desse sinal. Nota-se também que quando usado em conjunto com outros sinais, como o subconjunto 1, que inclui todos os sinais exceto o de respiração, os resultados são comparavelmente ainda melhores, da ordem de 87.8%.

4.2.2 Experimentos Conduzidos para a Classificação de 3 Níveis de Sono - Grupo B

Na classificação dos 3 níveis de sono desse mesmo participante (vigília, sono leve e sono profundo - Grupo B), todos os resultados obtidos foram melhores que os respectivos resultados para o Grupo A, algo esperado tendo em vista que a quantidade de classes a serem discretizadas pelos classificadores foi menor.

A Tabela 4.2 mostra que a SVM mais uma vez teve um desempenho pior quando comparado ao *Ensemble Adaboost* em todos subconjuntos testado, que apresentou um caso de 93.7% de acerto para o subconjunto 1 e 90.2% e 91% para os subconjuntos 2 e 3, isso significa que houve uma queda de aproximadamente 2.7% de acerto quando restringido o uso do EEG. Com isso, os subconjuntos 2 e 3, que não incluem o sinal de EEG, garantem uma qualidade de classificação comparável ao subconjunto 1, considerando que o compromisso entre o desempenho final e a restrição de sinais de EEG pode ser apropriado para a aplicação em questão.

Essa proximidade dos resultados do subconjunto 3 aos resultados do subconjunto 1 que o Adaboost proporciona é observada nos dois grupos de classe testados e valida a hipótese de que, embora de grande valor para a classificação de estágios de sono, o sinal de EEG não é essencial e, portanto, pode ser desconsiderado.

O sinal de ECG também foi testado isoladamente, porém foi apenas capaz de ge-

Tabela 4.1. Taxas de erro e desvio padrão para classificações de sono do participante SHHS1-200070 do banco de dados utilizado no cenário de classificação para todos níveis de sono (Grupo A).

Sinais	SVM	<i>Ensemble Robustboost</i>	<i>Ensemble Adaboost</i>
EEG	21.2 ± 2.5	13.5 ± 2.1	14.4 ± 2.6
ECG	57.0 ± 2.5	27.1 ± 2.2	22.9 ± 2.4
subconjunto 1	56.8 ± 0.2	13.1 ± 2.0	12.2 ± 2.5
subconjunto 2	56.8 ± 0.2	26.9 ± 2.5	16.5 ± 2.5
subconjunto 3	56.8 ± 0.2	26.4 ± 2.0	16.4 ± 2.0

rar taxas de erro abaixo de 20% com testes do grupo B, utilizando os classificadores *Ensemble RobustBoost* e *Adaboost*. Isso sugere que, diferente do sinal de EEG, o sinal de ECG sozinho não é capaz de gerar resultados aplicáveis em um contexto clínico de forma consistente. Para verificar essa hipótese e validar os demais resultados obtidos pelo classificador *Ensemble Adaboost*, repetiu-se parte dos testes para quatro outros participantes, como está descrito na Seção 4.3.

4.2.3 Análise de Histogramas e Matrizes de Confusão

O bom desempenho de um classificador multiclases pode ser analisado a partir de sua matriz de confusão, que deve se aproximar o máximo possível de uma matriz diagonal. Em outras palavras, os termos que não estão na diagonal principal da matriz devem se aproximar de zero, o que significa que não foram gerados falsos positivos ou falsos negativos no processo de classificação. Além disso, os histogramas gerados por essas classificações devem estar o mais próximo possível da curva de distribuição Gaussiana.

Para a classificação no cenário do Grupo B com o subconjunto 1 de sinais, os classificadores *Ensemble Adaboost* e *Ensemble Robustboost* apresentaram resultados de classificação similares e bons quando comparados, o que era esperado dada a presença do sinal de EEG. Isso pode ser confirmado pelas matrizes de confusão apresentadas nas Tabelas 4.3 e 4.4.

De acordo com as Tabelas 4.5 e 4.7, com a matriz de confusão gerada na classificação do Grupo B para os subconjuntos 2 e 3 sinais, comprova-se que o *Ensemble Adaboost* obteve melhor desempenho ao ser comparado ao *Ensemble Robustboost*, que de acordo com as Tabela 4.6 e 4.8, apresentou dificuldades de classificação na parte de sono profundo. Esta dificuldade em classificar o sono profundo não foi observada em nenhum dos casos testados de *Adaboost*, fator este que se reflete nos valores de taxa de erro, sendo melhores que os do *Robustboost* para todos os testes realizados com os subconjuntos 1, 2 e 3.

Em virtude do bom desempenho do *Ensemble Adaboost* na aplicação proposta em comparação com outros classificadores, os histogramas apresentados nas Figuras 4.1, 4.2 e 4.3, de fato possuem a forma desejada para um bom classificador, se aproximando então

Tabela 4.2. Taxas de erro e desvio padrão para classificações de sono do participante SHHS1-200070 do banco de dados utilizado no cenário de classificação para 3 níveis de sono (Grupo B).

Sinais	SVM	<i>Ensemble Robustboost</i>	<i>Ensemble Adaboost</i>
EEG	7.9 ± 1.7	6.7 ± 1.3	7.4 ± 2.3
ECG	33.4 ± 3.2	14.9 ± 1.9	11.3 ± 2.0
subconjunto 1	47.0 ± 0.5	6.5 ± 1.2	6.3 ± 2.3
subconjunto 2	45.9 ± 0.8	16.3 ± 2.1	9.8 ± 1.8
subconjunto 3	47.7 ± 0.1	16.3 ± 2.4	9.0 ± 1.7

Tabela 4.3. Matriz de confusão gerada na classificação no cenário do Grupo B utilizando o subconjunto 1 de sinais e o classificador *Ensemble Adaboost*.

Resultados	Classes de validação			
	Classe	Vigília	Sono leve	Sono Profundo
	Vigília	86.75	4.78	1.22
	Sono leve	6.25	108.01	0.24
	Sono profundo	0.00	0.21	8.54

Tabela 4.4. Matriz de confusão gerada na classificação no cenário do Grupo B utilizando o subconjunto 1 de sinais e o classificador *Ensemble Robustboost*.

Resultados	Classes de validação			
	Classe	Vigília	Sono leve	Sono Profundo
	Vigília	84.56	5.58	0.10
	Sono leve	8.44	107.26	0.22
	Sono profundo	0.00	0.16	9.68

Tabela 4.5. Matriz de confusão gerada na classificação no cenário do Grupo B utilizando o subconjunto 2 de sinais e o classificador *Ensemble Adaboost*.

Resultados	Classes de validação			
	Classe	Vigília	Sono leve	Sono Profundo
	Vigília	82.50	8.62	0.81
	Sono leve	10.50	103.47	0.27
	Sono profundo	0.00	0.91	8.92

Tabela 4.6. Matriz de confusão gerada na classificação no cenário do Grupo B utilizando o subconjunto 2 de sinais e o classificador *Ensemble Robustboost*.

Resultados	Classes de validação			
	Classe	Vigília	Sono leve	Sono Profundo
	Vigília	81.12	12.15	8.62
	Sono leve	11.88	100.85	1.38
	Sono profundo	0.00	0.00	0.00

Tabela 4.7. Matriz de confusão gerada na classificação no cenário do Grupo B utilizando o subconjunto 3 de sinais e o classificador *Ensemble Adaboost*.

Resultados	Classes de validação			
	Classe	Vigília	Sono leve	Sono Profundo
	Vigília	82.48	7.96	0.76
	Sono leve	10.52	103.83	0.12
	Sono profundo	0.00	1.21	9.12

Tabela 4.8. Matriz de confusão gerada na classificação no cenário do Grupo B utilizando o subconjunto 3 de sinais e o classificador *Ensemble Robustboost*.

Resultados	Classes de validação			
	Classe	Vigília	Sono leve	Sono Profundo
	Vigília	79.66	11.97	8.68
	Sono leve	13.34	101.02	1.24
	Sono profundo	0.00	0.01	0.08

da curva de distribuição Gaussiana.

Observando a Tabela 4.9, o desempenho do classificador SVM também pode ser explicado, tendo em vista que a matriz apresenta que esse classificador, mesmo usando o subconjunto 1, que possui o sinal de EEG, não conseguiu classificar a maioria dos estágios de vigília e sono profundo.

Em todas as matrizes de confusão geradas observa-se que há dificuldade dos classificadores em diferenciar estado de vigília de sono leve, ao passo que essa mesma dificuldade não é observada ao diferenciar sono leve de sono profundo, independente do classificador utilizado. Esse resultado sugere que, em termos de sinais fisiológicos, o sono leve se aproxima mais ao estado de vigília que ao de sono profundo.

Diante dos resultados de desempenho obtidos com o Grupo B, foram calculadas as métricas de sensibilidade, precisão, acurácia e medida F de cada um dos três estágios definidos para esse grupo, como mostra a Tabela 4.10.

Observa-se que os valores de sensibilidade medidos para sono profundo ficaram abaixo de 90% em 4 dos 6 cenários testados, em particular os casos do *Robustboost* com subconjunto 2 e 3, que obtiveram sensibilidade nula e próxima de zero, respectivamente. Isso mostra mais uma vez a dificuldade que esse classificador apresentou ao classificar sono profundo sem a presença do sinal de EEG.

Observa-se também que tanto no caso do *Robustboost* quanto no caso do *Adaboost*, os valores das medidas de precisão e sensibilidade dos estados de vigília e sono leve caem com a retirada do sinal de EEG, no subconjunto 2, e se mantém com a adição do sinal de respiração, no subconjunto 3. Esse resultado mostra que a adição do sinal de respiração melhora apenas a medida de acurácia desses estados, o que se reflete no aumento da taxa de acerto do teste como um todo, mas não influencia as demais métricas de desempenho.

As métricas calculadas obtiveram na maioria dos casos valores acima de 85%, o que mostra que houve uma classificação compatível a resultados encontrados no estado da arte para esses três níveis de sono. As principais exceções foram a medida de precisão do estado de vigília para o subconjunto 3 com *Ensemble Robustboost*, que obteve 79% de precisão, e a medida de precisão do sono profundo para o subconjunto 2 com *Robustboost*, que não obteve valor de precisão dada a ausência de valores de Verdadeiros Positivos e Falso Positivos.

As matrizes de confusão apresentadas foram geradas a partir de uma média de 100

Tabela 4.9. Matriz de confusão gerada na classificação no cenário do Grupo B utilizando o subconjunto 1 de sinais e o classificador SVM.

	Classes de validação			
	Classe	Vigília	Sono leve	Sono Profundo
Resultados	Vigília	1.86	0.03	0.00
	Sono leve	91.14	112.97	10.00
	Sono profundo	0.00	0.00	0.00




Figura 4.1. Histograma gerado na classificação no cenário do Grupo B utilizando o subconjunto 1 de sinais e o classificador *Ensemble Adaboost*.




Figura 4.2. Histograma gerado na classificação no cenário do Grupo B utilizando o subconjunto 2 de sinais e o classificador *Ensemble Adaboost*.

Tabela 4.10. Métricas de desempenho calculadas para os resultados obtidos com o Grupo B, onde **S** é a Sensibilidade, **P** é a precisão e **A** é a Acurácia.

		TP	TN	FP	FN	S	P	A	<i>F measure</i>
<i>Adaboost SC1</i>	vigília	86.75	117.09	6	6.25	0.93	0.94	0.94	0.93
	sono leve	108.1	96.51	6.49	4.99	0.96	0.94	0.95	0.95
	sono profundo	8.54	205.79	0.21	1.46	0.85	0.98	0.99	0.91
<i>Adaboost SC2</i>	vigília	82.5	113.57	9.43	10.5	0.89	0.90	0.91	0.89
	sono leve	103.47	92.23	10.77	9.53	0.92	0.91	0.91	0.91
	sono profundo	8.92	205.09	0.91	1.08	0.89	0.91	0.99	0.90
<i>Adaboost SC3</i>	vigília	82.48	114.28	8.72	10.52	0.89	0.90	0.91	0.90
	sono leve	103.83	92.36	10.64	9.17	0.92	0.91	0.91	0.91
	sono profundo	9.12	204.79	1.21	0.88	0.91	0.88	0.99	0.90
<i>Robustboost SC1</i>	vigília	84.56	117.32	5.68	8.44	0.91	0.94	0.93	0.92
	sono leve	107.26	94.34	8.66	5.74	0.95	0.93	0.93	0.94
	sono profundo	9.68	205.84	0.16	0.32	0.97	0.98	1.00	0.98
<i>Robustboost SC2</i>	vigília	81.12	102.23	20.77	11.88	0.87	0.80	0.85	0.83
	sono leve	100.85	89.74	13.26	12.15	0.89	0.88	0.88	0.89
	sono profundo	0	206	0	10	0.00	-	0.95	-
<i>Robustboost SC3</i>	vigília	79.66	102.35	20.65	13.34	0.86	0.79	0.84	0.82
	sono leve	101.02	88.42	14.58	11.98	0.89	0.87	0.88	0.88
	sono profundo	0.08	205.99	0.01	9.92	0.01	0.89	0.95	0.02




Figura 4.3. Histograma gerado na classificação no cenário do Grupo B utilizando o subconjunto 3 de sinais e o classificador *Ensemble Adaboost*.

iterações do código implementado, enquanto os histogramas foram gerados para 1500 iterações. Cada iteração corresponde a um experimento com um conjunto de sinais de validação e teste, ou seja, os sinais de validação e testes são alterados aleatoriamente de uma iteração para outra.

4.3 Experimentos Adicionais Realizados para Outros Participantes com o *Ensemble Adaboost*

A partir dos resultados obtidos, notou-se que o *Ensemble Adaboost* obteve os melhores resultados dentre os classificadores utilizados. Diante disso, a Tabela 4.11 apresenta as taxas de erro obtidas em alguns testes extra feitos para outros participantes, na tarefa de aprofundar a análise acerca desse classificador.

De acordo com a tabela, observa-se que o padrão de resultados encontrados no participante SHHS1-200070 não sofreram grandes alterações para os participantes utilizados nos testes adicionais. Os participantes SHHS1-200080, SHHS1-200085 e SHHS1-200090 obtiveram resultados próximos ao participante SHHS1-200070 e entre si, com os testes de classificação do grupo B e subconjunto 3. O participante SHHS1-200075, contudo, apresentou o pior desempenho dentre os testados, com uma perda de aproximadamente

10% de acerto entre as classificações com o uso do EEG e do subconjunto 3, sendo que para este subconjunto a taxa de erro ficou acima de 20%.

O participante SHHS1-200080 obteve o melhor desempenho dentre os demais, com uma taxa de acerto de 87% para o subconjunto 3 no cenário de classificação de 3 estágios (Grupo B), isso pode estar relacionado a qualidade dos sinais fisiológicos de cada participante. Esses números confirmam a relação encontrada com participante SHHS1-200070, que tem uma queda de aproximadamente 3% de acerto na classificação com o sinal de EEG comparado ao subconjunto 3. Ainda assim, os valores obtidos com o participante SHHS1-200070 foram os melhores entre os participantes testados, não tendo sido obtidos valores equiparáveis para os demais participantes.

Testes realizados apenas com o sinal de ECG para esses participantes confirmaram que o sinal sozinho não é suficiente para gerar resultados aceitáveis de forma consistente, tendo em vista que três dos quatro participantes selecionados obtiveram taxa de erro acima de 20% para os testes com o sinal de ECG isolado.

Tendo isso em vista, se faz necessária uma pesquisa aprofundada acerca da variabilidade de desempenho para diferentes participantes. Para pesquisas futuras, poderá ser feita a comparação desses desempenhos para um grupo maior de participantes na tentativa de visualizar o nível de incerteza baseado nessas taxas de participante para participante, de forma a obter uma análise mais concreta acerca dessas quedas de taxas de acerto na restrição do uso do sinal de EEG.

Tabela 4.11. Taxas de erro e desvio padrão para testes adicionais realizados nos dois cenários de classificação (Grupo A e Grupo B) com diferentes participantes.

	Sinais	GRUPO A	GRUPO B
SHHS1-200075	EEG	17.4 ± 2.2	10.1 ± 2.0
	ECG	36.1 ± 3.0	28.0 ± 3.1
	subconjunto 3	26.5 ± 3.1	20.2 ± 3.0
SHHS1-200080	Sinais	GRUPO A	GRUPO B
	EEG	20.6 ± 2.2	11.8 ± 2.1
	ECG	29.4 ± 3.1	12.1 ± 2.1
	subconjunto 3	24.0 ± 3.1	13.0 ± 2.0
SHHS1-200085	Sinais	GRUPO A	GRUPO B
	EEG	15.2 ± 2.4	9.3 ± 2.2
	ECG	31.0 ± 2.5	20.2 ± 2.6
	subconjunto 3	20.6 ± 2.4	16.2 ± 2.8
SHHS1-200090	Sinais	GRUPO A	GRUPO B
	EEG	15.0 ± 2.5	9.9 ± 2.1
	ECG	35.2 ± 3.4	20.2 ± 2.4
	subconjunto 3	24.5 ± 2.6	14.1 ± 2.4

5 Conclusão

Estudos primordiais sobre classificação níveis de sono têm a maioria de suas pesquisas baseadas na análise do sinal EEG, que apresenta características bem definidas para cada nível, tornando-se o principal sinal quando se trata de aplicações desse tipo. Considerando que, para a aplicação deste trabalho, a aquisição complexa do sinal de EEG, onde o participante em questão se encontra em um contexto diferente de seu habitual, faz com que a qualidade da classificação possa ser possivelmente afetada.

Em virtude disso, foi proposto avaliar classificações de níveis de sono em diferentes cenários usando subconjuntos de sinais, com e sem o EEG, na expectativa de gerar resultados satisfatórios na restrição desse sinal.

Os resultados mostram que os classificadores do tipo SVM não obtiveram resultados comparáveis ao *Ensemble*, o que contrasta com os resultados aplicados a algumas áreas da Engenharia Biomédica. Cabe ressaltar que o *Ensemble* tem um custo computacional muito alto e, em muitas aplicações acaba por não ser optado, diferente desse caso.

Quanto a classificação, considerando 5 níveis de sono, foram obtidas taxas de acerto na ordem de 87.8% com o classificador *Ensemble Adaboost* para o subconjunto 2, que não tem o sinal de EEG, enquanto a SVM gerou uma taxa de erro em torno de 50%.

Já para 3 níveis de sono, o desempenho do *Ensemble Adaboost* foi da ordem de 90%, isso sugere que, ao longo de uma noite, esse caso testado permite classificar corretamente 90% do sono, que é um resultado comparavelmente tão bom quanto quando se usa o EEG.

Para os dois cenários de classificação testados, nota-se que há uma perda na taxa de acerto na classificação da ordem de 3% quando se restringe o uso do EEG. Esse resultado é importante, considerando que mesmo sem o uso do sinal de EEG (subconjuntos 2 e 3), a taxa de acerto é comparavelmente alta. Isso indica que, apesar do alto custo computacional, o *Ensemble Adaboost* se torna a melhor escolha para esse tipo de classificação.

Para trabalhos futuros, a sugestão é, inicialmente, fazer uma análise mais detalhada sobre a SVM, já que ele apresentou resultados inesperadamente piores comparados ao *Ensemble*. Para isso, reajustar os parâmetros que ainda não foram testados para esse classificador, por exemplo, utilizar outras funções de kernel, sendo que para esse trabalho foi usada a função de kernel mais comum, que é o *rbf_sigma*, que apresentam resultados similares ao *Ensemble* na literatura.

Apesar do banco de dados utilizado contar com os sinais de 6000 participantes, por questão de tempo de implementação e experimentação, foram feitos poucos testes. Isso indica que pesquisas futuras podem trabalhar em experimentos partir de um número maior de participantes, a fim de se fazer uma análise de confiabilidade do sistema proposto. Em outras palavras, avaliar o padrão de taxas de erros encontrados para mais

participantes.

Finalmente, uma próxima etapa é a análise desses sinais utilizando técnicas de aprendizagem profunda, área que tem atingido resultados bem mais expressivos comparados a técnicas anteriores nos últimos anos na área de aprendizagem de máquinas. Entretanto, esse tipo de técnica exige um esforço computacional muito maior, o que normalmente requer a utilização de *clusters* de processadores ou supercomputadores, além de um tempo muito maior de treinamento, e resultados melhores só acontecem realmente se houver um grande número de dados de treinamento. Assim, é importante realizar a pesquisa e comparar os resultados, com base em uma etapa mais longa de desenvolvimento.

Referências Bibliográficas

- [1] G. O. Bustamante. Monitorização polissonográfica–aspectos gerais. *Medicina (Ribeirao Preto. Online)*, 39(2):169–184, 2006.
- [2] C. S. C. Carpenter, J. Novaes, e L. A. Batista. La Comparação entre a puxada por trás e a puxada pela frente de acordo com a ativação eletromiográfica. *Revista Educação Física*, 136:20–27, 2007.
- [3] A. T. Coelho, L. M. Lorenzini, et al. Qualidade de sono, depressão e ansiedade em universitários dos últimos semestres de cursos da area da saúde. *Neurobiologia*, 73(1):35–39, 2010.
- [4] M. de Albuquerque, J. O. Cardeal, e C. J. R de Campos. Distúrbios do Sono, Epilepsia e Indicações para o Registro Polissonográfico–Revisão. *NEUROCIÊNCIAS*, 6(2):69–74, 1998.
- [5] E. G. C. de Faria. *Sistema de Análise de Características de Sinais de Eletrocardiografia para Associação com a Síndrome Metabólica*. Trabalho de conclusão de curso, Universidade de Brasília, Campus Gama, Brasília, DF, Brasil, 2016.
- [6] F. Ebrahimi, M. Mikaeili, et al. Automatic sleep stage classification based on EEG signals by using neural networks and wavelet packet coefficients. In *2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, páginas 1151–1154. IEEE, 2008.
- [7] T. Fawcett. An introduction to ROC analysis. *Pattern recognition letters*, 27(8):861–874, 2006.
- [8] R. A. Fisher. The use of multiple measurements in taxonomic problems. *Annals of eugenics*, 7(2):179–188, 1936.
- [9] M. A. Grandner, A. Seixas, et al. Sleep Duration and Diabetes Risk: Population Trends and Potential Mechanisms. *Current Diabetes Reports*, 16(11):106, 2016.
- [10] A. L. Hodgkin e A. F. Huxley. A quantitative description of membrane current and its application to conduction and excitation in nerve. *The Journal of physiology*, 117(4):500–544, 1952.
- [11] M. Jobert, C. Tismer, et al. Wavelets: a new tool in sleep biosignal analysis. *Journal of sleep research*, 3(4):223–232, 1994.

- [12] C. C. Mendes. *Classificação de imagens de retina para auxílio a diagnóstico de retinopatia diabética via detecção de exsudatos duros, com base em classificadores robustos, máquinas de vetores de suporte e algoritmos com treinamento de dicionários*. Dissertação de mestrado, Programa de Pós-Graduação em Engenharia Biomédica. Universidade de Brasília, Campus Gama, Brasília, DF, Brasil, 2017.
- [13] J. Nocedal e S. Wright. *Numerical optimization*. Springer Science & Business Media, 2006.
- [14] University of Arizona. The Sleep Heart Health Study (SHHS) PROTOCOL, 2005. Description of the SHHS database of polysomnography signals.
- [15] E. Oropesa, H. L. Cycon, e M. Jobert. Sleep stage classification using wavelet transform and neural network. *International computer science institute*, 1999.
- [16] K. Pearson. Contributions to the mathematical theory of evolution. *Philosophical Transactions of the Royal Society of London. A*, 185:71–110, 1894.
- [17] V. C. Pinheiro. Desenvolvimento e Avaliação de um Sistema de Análise de Equilíbrio Postural Humano com Base em Sinais de Inclinômetros e Máquinas de Suporte Vetorial, 2014. Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Biomédica, Universidade de Brasília, Campus Gama.
- [18] K. F. Pires. Análise dos efeitos de diferentes protocolos de eletroestimulação neuromuscular através da frequência mediana. *Revista Brasileira de Ciência e Movimento*, 12(2):25–28, 2008.
- [19] A. Rechtschaffen e A. Kales. *A manual of standardized terminology, techniques and scoring system for sleep stages of human subjects*. US Government Printing Office, US Public Health Service, 1968.
- [20] C. S. C. Rocha. Técnicas de Reconhecimento de Padrões para a Classificação de Sinais Fisiológicos, 2013. Tese de Doutorado, Laboratório de Modelagem, Análise e Controle de Sistemas Não-Lineares, Universidade Federal de Minas Gerais.
- [21] M. A. B. Rodrigues. Sistema para detecção e classificação automática de apnéias do sono a partir de registros polissonográficos, 2002. Tese de Doutorado, Departamento de Engenharia Elétrica, Universidade Federal de Santa Catarina.
- [22] B. Rosner. *Fundamentals of Biostatistics*. Duxbury Press: Boston, 2015.
- [23] S. Russel e P. Norvig. *Artificial intelligence: a modern approach*. Pearson Education, 2010.
- [24] J. W. Shephard. *Atlas of sleep medicine*. Futura Publisher, 1991.

- [25] R. Soltanzadeh e Z. Moussavi. Sleep stage detection using tracheal breathing sounds: a pilot study. *Annals of biomedical engineering*, 43(10):2530–2537, 2015.
- [26] E. Vanoli, P. B. Adamson, G. D. Pinna, et al. Heart rate variability during specific sleep stages. *Circulation*, 91(7):1918–1922, 1995.
- [27] D. S. P. Vieira, T. M. Silva, et al. CARACTERIZAÇÃO DO SONO DE PACIENTES COM SÍNDROME PÓS-POLIOMIELITE PELA POLISSONOGRÁFIA. *Revista de Neurociências*, 19(1):18–25, 2011.
- [28] D. Žemaitytė, G. Varoneckas, e E. Sokolov. Heart rhythm control during sleep. *Psychophysiology*, 21(3):279–289, 1984.
- [29] Zhi-Hua Zhou. *Ensemble methods: foundations and algorithms*. CRC press, 2012.