



UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO
UNIDADE ACADÊMICA DO CABO DE SANTO AGOSTINHO
BACHARELADO EM ENGENHARIA ELETRÔNICA

JOSÉ LUCAS DE VASCONCELOS COSTA SOBREIRA

Classificação dos estágios do sono por meio de sinais de polissonografia com auxílio
de algoritmos de aprendizagem de máquina e processamento de sinais

Cabo de Santo Agostinho - PE

2023

JOSÉ LUCAS DE VASCONCELOS COSTA SOBREIRA

Classificação dos estágios do sono por meio de sinais de polissonografia com auxílio de algoritmos de aprendizagem de máquina e processamento de sinais

Monografia apresentada ao Curso de Graduação em Engenharia Eletrônica da Unidade Acadêmica do Cabo de Santo Agostinho da Universidade Federal Rural de Pernambuco para obtenção do título de Bacharel em Engenharia Eletrônica.

Área de concentração: Engenharia Eletrônica

Orientador: Prof. Felipe Alberto B. S. Ferreira

Cabo de Santo Agostinho - PE

2023

FICHA CATALOGRÁFICA

Dados Internacionais de Catalogação na
Publicação Universidade Federal Rural
de Pernambuco Sistema Integrado de
Bibliotecas
Gerada automaticamente, mediante os dados fornecidos
pelo(a) autor(a)

S677c Sobreira, José Lucas de Vasconcelos Costa
Classificação dos estágios do sono por meio de sinais de polissonografia com auxílio de algoritmos de aprendizagem de máquina e processamento de sinais: / José Lucas de Vasconcelos Costa Sobreira. - 2023.
57 f. : il.

Orientador: Felipe Alberto Barbosa
Simao Ferreira. Inclui referências.

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal Rural de Pernambuco, Bacharelado em Engenharia Eletrônica, Cabo de Santo Agostinho, 2024.

1. polissonografia. 2. estágios do sono. 3. aprendizagem de máquina. 4. distúrbios do sono. I. Ferreira, Felipe Alberto Barbosa Simao, orient. II. Título

CDD 621.3

FOLHA DE APROVAÇÃO

JOSÉ LUCAS DE VASCONCELOS COSTA SOBREIRA

Classificação dos estágios do sono por meio de sinais de polissonografia com auxílio de algoritmos de aprendizagem de máquina e processamento de sinais

Monografia apresentada ao Curso de Graduação em Engenharia Eletrônica da Unidade Acadêmica do Cabo de Santo Agostinho da Universidade Federal Rural de Pernambuco para obtenção do título de Bacharel em Engenharia Eletrônica.

Aprovada em: 26 de abril de 2023

Banca Examinadora

Orientador

Prof. Felipe Alberto B. S. Ferreira

Universidade Federal Rural de Pernambuco, UFRPE

Examinador

Prof. Fernando Gonçalves de Almeida Neto, D.Sc.

Universidade Federal Rural de Pernambuco, UFRPE

Examinador

Prof. Denis Keuton Alves, D.Sc.

Universidade Federal Rural de Pernambuco, UFRPE

DEDICATÓRIA

Dedico este trabalho a todos que fizeram parte da minha vida, e a todos que virão.

AGRADECIMENTOS

Agradeço primeiramente a Deus, como força suprema e motora do Universo, sem O qual Nada existiria.

Agradeço ao meu pai Marcondes (*in memoriam*) e à minha mãe Tatiana, como pontes para que eu tivesse a oportunidade de vir ao mundo, e como propagadores de amor e vida, me ensinando a fazer a diferença.

Agradeço aos meus irmãos, Marcondes e Vitória, como os melhores amigos que eu pude e posso contar.

Agradeço aos Mestres de Luz, como fonte de luz, paz e amor, e que sempre me deram tudo que eu mereci.

Agradeço à minha esposa Letícia, como companheira amorosa que muitas vezes me indica o caminho de ser uma pessoa melhor.

Agradeço a todos os meus amigos, como instrumentos de alegria e propósito para minha vida.

Agradeço ao professor Fernando Gonçalves de Almeida Neto, como exemplo de profissional, acadêmico e humano, e também ao professor Felipe Alberto Simão Barbosa Ferreira, como orientador e possibilitador de conclusão deste trabalho.

A todos os envolvidos na minha formação como humano, profissional e todos os aspectos que viemos para desenvolver, agradeço.

Courage need not to be remembered, for it is never forgotten.
(Princess Zelda)

RESUMO

Uma das grandes razões para a incidência de graves problemas de saúde na atualidade são os distúrbios do sono. Alguns dos impactos destes na saúde vão desde a perda de produtividade nas atividades diárias até a incidência de obesidade. Hoje, a Polissonografia (PSG) é considerada um método padrão de alta qualidade para diagnosticar diversos distúrbios do sono. Contudo, o processo de diagnóstico destes distúrbios utilizando PSG é um trabalho exaustivo, uma vez que são necessárias anotações de especialistas durante a gravação dos sinais fisiológicos do paciente, que em muitos casos dura mais do que 6 horas. Além disso, a classificação dos estágios do sono por meio de anotações de especialistas requer que o mesmo defina um padrão de estágios cerebrais baseado em frequências de ondas mostradas no PSG para então realizar as anotações, tornando o processo de classificação de maneira manual trabalhoso. Como alternativa, há métodos sugeridos na literatura utilizando modelos de algoritmos de aprendizagem de máquina para classificação dos estágios do sono, facilitando assim o processo de diagnóstico de distúrbios relacionados a este estado fisiológico. Desenvolvimentos recentes presentes na literatura demonstram uma acurácia de 80% a 95% utilizando algoritmos de aprendizagem de máquina na classificação de estágios do sono, a depender do número de pacientes estudados e da técnica utilizada. Este trabalho propõe estudar e analisar algoritmos de aprendizagem de máquina para classificação de estágios de sono utilizando processamento de sinais de PSG de diferentes pacientes e seguindo os padrões da *American Academy of Sleep Medicine (AASM)* com valores pré-definidos para cada estágio de sono. A metodologia utilizada para desenvolver o algoritmo é descrita neste documento, tal como a avaliação de desempenho do modelo gerado pelo algoritmo de aprendizagem de máquina utilizando a técnica de árvore de decisão e *random forest*, mostrando que o modelo desenvolvido consegue alcançar um desempenho semelhante ao presente na literatura.

Palavras-chave: polissonografia; estágios do sono; aprendizagem de máquina; distúrbios do sono.

ABSTRACT

One of the major reasons for the incidence of serious health problems today is sleep disorders. Some of the health impacts of sleep disorder range from loss of productivity in daily activities to premature aging. Today, Polysomnography (PSG) is considered a high-quality standard method for diagnosing various sleep disorders. However, the process of diagnosing sleep disorders using PSG is an exhausting work, as expert notes are required while recording the patient's sleep signals, which in many cases lasts longer than 6 hours. In addition, the classification of sleep stages through expert notes requires the expert to define a pattern of sleep stages based on wave frequencies shown on the PSG to then perform the notes, making the classification process manually laborious. As an alternative, there are methods suggested in the literature using models of machine learning algorithms to classify sleep stages, thus facilitating the process of diagnosing sleep disorders. Recent developments in the literature demonstrate an accuracy of 80% to 95% using machine learning algorithms for classifying sleep stages, depending on the number of patients studied and the technique used. This work proposes to study and analyze machine learning algorithms to classify sleep stages using PSG signal processing from different patients and following the American Academy of Sleep Medicine (AASM) standards with pre-defined values for each sleep stage. The methodology used to develop the algorithm is described in this document, as well as the performance evaluation of the model generated by the machine learning algorithm using the decision tree and random forest technique, showing that the model developed can achieve a performance similar to the present in literature.

Key-words: polysomnography; sleep stages; machine learning; sleep disorders.

LISTA DE FIGURAS

Figura 1 — Histograma dos estágios do sono para um adulto saudável	20
Figura 2 — Trecho de 30 segundos dos sinais de PSG	21
Figura 3 — Representação gráfica dos sinais captados por actígrafo triaxial (esquerda) e por um actígrafo uniaxial (direita)	22
Figura 4 — Exemplo de SVM para dados linearmente separáveis	25
Figura 5 — Exemplo de árvore de decisão	27
Figura 6 — Exemplo de sinal PSD gerado a partir de sinal de EEG	29
Figura 7 — Exemplo de algoritmo DSVM	31
Figura 8 — Árvore de decisão utilizada para classificar os estágios do sono	33
Figura 9 — Diagrama de blocos das etapas propostas para a metodologia	35
Figura 10 — Exemplo de sinais temporais de PSG multicanal gerados após leitura utilizando <i>MNE-Python</i>	36
Figura 11 — Exemplo de cálculo da densidade espectral de potência por meio de método de Welch	39
Figura 12 — Matrizes de confusão do modelo SVM (esquerda) e do modelo <i>Random Forest</i> (direita)	47
Figura 13 — Curvas de aprendizagem do modelo SVM (esquerda) e do modelo <i>Random Forest</i> (direita)	48

LISTA DE TABELAS

Tabela 1 — Escolha de <i>features</i> utilizadas para treinamento do modelo de <i>Decision Tree</i>	32
Tabela 2 — Escolha de <i>features</i> utilizadas para treinamento do modelo de CNN	34
Tabela 3 — Escolha de <i>features</i> utilizadas para treinamento do modelo <i>Multi-Class-SVM</i>	42
Tabela 4 — Escolhas de <i>features</i> utilizadas para treinamento do modelo RF	43
Tabela 5 — Dados dos pacientes escolhidos	46
Tabela 6 — Métricas de desempenho calculadas para os modelos de <i>Multi-Class-SVM</i> e RF	48
Tabela 7 — Métricas de desempenho calculadas para os modelos de <i>Multi-Class-SVM</i> e RF	50

LISTA DE ABREVIATURAS E SIGLAS

AASM	<i>American Academy Sleep Medicine</i>
PSG	Polissonografia
EEG	Eletroencefalograma
EOG	Eletrooculograma
EMG	Eletromiograma
ECG	Eletrocardiograma
PSD	<i>Power Spectral Density</i>
DT	<i>Decision Tree</i>
RF	<i>Random Forest</i>
CNN	<i>Convolutional Neural Network</i>
SVM	<i>Support Vector Machine</i>
REM	<i>Rapid Eye Movement</i>
NREM	<i>Non-Rapid Eye Movement</i>
FFT	<i>Fast Fourier Transform</i>
RBF	<i>Radial Basis Function</i>
OVR	<i>One-vs-Rest</i>
OVO	<i>One-vs-One</i>
DSVM	<i>Dendro-Support Vector Machine</i>
EDF	<i>European Data Format</i>
W	<i>Wake</i>

SUMÁRIO

1 INTRODUÇÃO	15
1.1 Contextualização	15
1.2 Justificativa	16
1.3 Objetivos	16
1.3.1 Geral	17
1.3.2 Específicos	17
1.4 Organização do trabalho	17
2 FUNDAMENTAÇÃO TEÓRICA	19
2.1 Sono	19
2.2 Métodos de monitoramento do sono	20
2.2.1 Polissonografia	21
2.2.2 Actigrafia	22
2.3 Processamento de sinais	23
2.3.1 Transformada de Fourier	23
2.3.2 Densidade Espectral de Potência	23
2.4 Aprendizagem de máquina	24
3 REVISÃO BIBLIOGRÁFICA	28
3.1 Método utilizando-se de múltiplos canais, com modelo híbrido de aprendizagem de máquina	28
3.2 Método utilizando-se de múltiplos canais e classificação pelo modelo <i>Decision Tree</i>	31
3.3 Método utilizando-se de múltiplos canais e classificação pelo modelo CNN	33
4 METODOLOGIA	35
4.1 Seleção da base de dados	35
4.2 Leitura dos dados brutos	36
4.3 Pré-processamento do sinal e transformação PSD	37
4.4 Extração de <i>features</i> e <i>labels</i>	38
4.4.1 Extração de <i>features</i>	38
4.4.2 Extração de <i>labels</i>	40
4.5 Treinamento e avaliação dos modelos de aprendizagem	40

5 RESULTADOS E DISCUSSÕES	45
5.1 Estrutura dos algoritmos de referência	45
5.2 Experimentos	47
6 CONCLUSÃO	52
6.1 Trabalhos futuros	53
6.1.1 Utilização de mais dados de entrada	53
6.1.2 Estudar a seleção de <i>features</i> para o modelo de <i>Random Forest</i>	53
REFERÊNCIAS	54

1 INTRODUÇÃO

1.1 Contextualização

A falta de sono é considerada um dos problemas proeminentes nos dias de hoje. A insuficiência de sono está relacionada com diversos problemas de saúde, incluindo, mas não se limitando a deficiência no sistema cognitivo, aumento no risco de suicídio em adolescentes, alterações no humor, incidência de doenças cardiovasculares, aumento no risco de câncer e envelhecimento precoce. Um estudo recente feito na Holanda com 20 mil pessoas com idade superior a 12 anos demonstrou que 27,3% destes pacientes apresentaram algum tipo de distúrbio de sono (Chattu *et al.*, 2018). Por essas razões, é importante desenvolver métodos que facilitem o diagnóstico de distúrbios relacionadas ao sono.

A classificação dos estágios do sono é considerada o padrão ouro na análise do sono (Lan; Chang, 2015), com o objetivo de diagnosticar e tratar distúrbios relacionados a este estado fisiológico. A classificação dos estágios do sono é feita geralmente por meio de um exame de polissonografia (PSG), no qual são gravados sinais referentes ao sono do paciente é gravado, utilizando sensores de eletroencefalograma (EEG), eletrooculograma (EOG), eletromiograma (EMG) e eletrocardiograma (ECG).

Os exames de PSG contêm vários canais de gravação nos quais são dispostos os sinais dos sensores citados anteriormente e o método de classificação de estágios de sono tradicional se mostra bastante susceptível a erros humanos, já que a avaliação é feita de maneira visual e manual, além de ser uma tarefa cansativa e que demanda aproximadamente de 2 a 4 horas (Hassan; Bashar; Bhuian, 2015). Além disso, alguns estudos sugerem que a taxa de concordância entre especialistas a respeito da classificação dos estágios de sono é menor que 90% (Hsu; Yang; Wang, 2013).

Considerando esses desafios, a classificação dos estágios de sono de maneira automática é uma alternativa para diminuir a demanda de tempo dos especialistas para a análise de sono dos pacientes, além de aumentar a precisão das análises e facilitar no diagnóstico de distúrbios do sono (Hassan, 2016).

Vários métodos de classificação automática dos estágios do sono são propostos

pela literatura. Esses métodos se baseiam em extrair determinadas características ou *features* dos sinais analisados e processados por diferentes métodos de processamento de sinais como a aplicação de análise de densidade espectral (PSD). Essas *features* são aplicadas em cada trecho contínuo dos sinais gravados (*epochs*) de 30 segundos, e usados como entrada para o modelo de classificação (Rohan, 2021).

Apesar de existirem diversos trabalhos que realizam a classificação automática dos estágios do sono por meio de sinais de PSG com auxílio de algoritmo de aprendizagem de máquina, é comum ver o processo de escolhas de *features* a partir de um único método de processamento de sinais. Tendo isso em vista, este trabalho tem como objetivo geral estudar alternativas de mais de um método de processamento de sinais para compor a escolha de *features* e comparar com os métodos utilizados na literatura de classificação de estágios de sono por meio de sinais de PSG com o auxílio de algoritmo de aprendizagem de máquina e processamento de sinais.

1.2 Justificativa

As técnicas propostas neste trabalho permitirão a realização de estudos comparativos entre métodos para a classificação de estágios do sono a partir de sinais de PSG, comparados com métodos presentes na literatura. Será estudado o algoritmo de aprendizagem de máquina utilizando-se diferentes modelos de classificação alimentados por eventos contendo as características obtidas a partir da aplicação de análise de PSD.

A abordagem analisada do presente trabalho deve contribuir para o desenvolvimento de estudos relativos a ferramentas de diagnósticos de distúrbio do sono por meio de classificação dos estágios do sono como uma técnica com o potencial de facilitar o trabalho de especialistas nesta área, aumentando a precisão da classificação de estágios do sono e fornecendo auxílio no diagnóstico de distúrbios do sono.

1.3 Objetivos

1.3.1 Geral

Este trabalho tem como objetivo analisar diferentes algoritmos de classificação automática de estágios do sono que facilite a realização de diagnóstico de distúrbios do sono por meio de sinais de PSG com o auxílio de técnicas de aprendizagem de máquina e processamento de sinais, utilizando bibliotecas em *python*.

1.3.2 Específicos

- Analisar algoritmos de classificação de estágios do sono, detalhando os processos de leitura e processamento dos sinais, passando pela seleção de canais utilizados, filtragem de frequências, processamento dos sinais para extração de *features* até o treinamento e validação dos modelos de aprendizagem de máquina comparando com técnicas presentes na literatura.
- Aplicar dois algoritmos de aprendizagem de máquina existentes na literatura, sendo eles: *Random Forest* (RF) e *Support Vector Machine* (SVM), para realizar a classificação de estágios de sono como definido pelo padrão da *American Academy of Sleep Medicine* (AASM) por meio de sinais de polissonografia, processados por meio da análise de densidade espectral como métodos de extração de *features* dos sinais.
- Comparar o desempenho dos algoritmos de aprendizagem de máquina sugeridos para realizar a classificação de estágios de sono, utilizando para isso métricas de desempenho usualmente utilizadas para validação de modelos de aprendizagem de máquina: Acurácia, Precisão, *Recall* e *F1-Score*.

1.4 Organização do trabalho

O trabalho está estruturado da seguinte forma: no Capítulo 2, será apresentada a fundamentação teórica deste trabalho, de modo a apresentar os métodos de medição de sinais corporais para estudo e diagnóstico de distúrbios do sono por meio de exames de PSG. No Capítulo 3 é apresentada uma revisão bibliográfica sobre o estado da arte da utilização de sinais de PSG para classificação de estágios do sono e sobre a aplicação de algoritmos de aprendizagem de máquina para este fim. O

Capítulo 4 detalha a metodologia utilizada para o desenvolvimento do algoritmo de classificação de estágios de sono, detalhando o processo de leitura dos dados, filtragem de sinais de entrada, seleção dos canais das gravações de sinais de PSG, processamento dos sinais para extração de *features* e treinamento e avaliação dos modelos de aprendizagem de máquina utilizados. Na sequência, no Capítulo 5, serão apresentados os resultados do algoritmo, contendo comparações entre os modelos e métricas de desempenho. No Capítulo 6 serão apresentadas as conclusões a respeito das técnicas utilizadas, assim como a subseção de trabalhos futuros, onde serão apresentadas possibilidades de otimização e melhorias para a continuação das aplicações apresentadas a partir deste trabalho.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção, são apresentados alguns conceitos associados às características do sono, tal como sua importância e uma breve descrição de alguns fenômenos fisiológicos que o caracterizam. Além disso, será apresentada uma explicação mais detalhada de métodos de medição de alguns sinais corporais que permitem o mapeamento deste fenômeno, tal como algumas técnicas de processamento de sinais e algoritmos de aprendizagem de máquina utilizados em conjunto para classificar os estágios do sono.

2.1 Sono

O sono é definido como um estado natural e periódico de descanso no qual a consciência do mundo é suspensa, e é necessário para a sobrevivência humana tal como alimento, água ou oxigênio (Spriggs, 2009). Além disso, o sono é importante para aspectos como crescimento, aprendizagem, consolidação da memória, segurança e boa saúde. A Fundação Nacional de Sono (em inglês, *National Sleep Foundation*) recomenda que os adultos tenham de 7 a 9 horas de sono por noite (Hirshkowitz *et al.*, 2015), porém, 37% dos americanos adultos afirmam ter menos de 7 horas de sono em um período de 24 horas (Spriggs, 2009).

O sono é dividido em dois estados principais: REM (Movimento Rápido dos Olhos, em inglês, *Rapid Eye Movement*) e não-REM (NREM). O estágio REM é caracterizado pela presença de movimento rápido dos olhos, como o nome sugere, e também está associado com alguns fatores como diminuição da temperatura corporal, relaxamento muscular, memória, cognição e sensação de sono restaurador. Por outro lado, o sono NREM está dividido em 3 estágios:

N1: Considerado um estágio transitório de sono, com características simultâneas de vigília e adormecimento.


N2: Um estágio de sono mais profundo que no N1, no qual há a presença de oscilações neurais gerados pelo cérebro chamadas de *sleep spindles* e caracterizado pela diminuição de percepção de estímulos externos, como por exemplo o som.

N3: Chamado também de sono Delta, ou sono profundo. Nesse estágio é mais difícil acordar o indivíduo.

Os períodos de sono REM e NREM acontecem em ciclos de aproximadamente 90 minutos durante a noite.

A proporção de cada estágio do sono durante a noite pode ser vista na Figura 1, considerando, além dos estágios citados, o estágio onde o indivíduo se encontra acordado, ou estágio W (Endee, 2021).

Figura 1 — Histograma dos estágios do sono para um adulto saudável



Fonte: Endee, 2021.

A condição de um indivíduo quando este não atinge a duração, consistência ou estágio necessário de sono é chamada de privação de sono, a qual pode ter vários efeitos negativos sobre a saúde do indivíduo. Uma das causas de privação de sono está relacionada à incidência de distúrbios do sono, que podem ser diagnosticados por meio de exames e métodos específicos de monitoramento do sono, a fim de obter um tratamento adequado e consequente a melhora da saúde do indivíduo. Na seção seguinte são apresentados alguns métodos de monitoramento do sono.

2.2 Métodos de monitoramento do sono


Existem alguns métodos de medição de sinais fisiológicos para monitoramento do sono, a seguir serão apresentados a PSG e a actigrafia e suas aplicações.

2.2.1 Polissonografia

O exame de polissonografia (PSG) é um processo sistemático utilizado para coleta de parâmetros fisiológicos. O PSG utiliza de sinais de EEG, EOG, EMG, ECG, oximetria e sinais de fluxo de respiração para determinar vários estados comportamentais durante o estado de vigília ou durante o sono, como por exemplo o estágio rem. Atualmente, a PSG é considerada o padrão ouro para diagnóstico de distúrbios do sono relacionados à respiração, como apneia central do sono, apneia obstrutiva do sono e hipoventilação/hipoxia relacionadas ao sono (Rundo, 2019).

Para realizar o exame de PSG, o paciente é submetido a noites de sono no qual são instalados sensores como eletrodos, oxímetros e sensores de posição corporal para medir os sinais citados. Após isso, um especialista interpreta e classifica os estágios do sono baseado em trechos de 30 segundos dos sinais de saída, chamados de *epochs*, que podem ser vistos na Figura 2.

Figura 2 — Trecho de 30 segundos dos sinais de PSG



Fonte: Penzel, 2007.

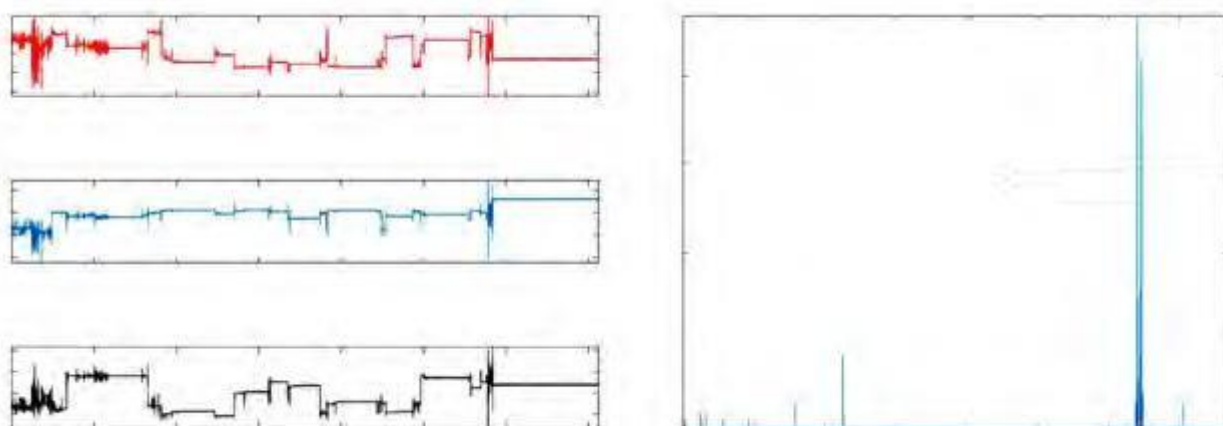
Desde 2007, a AASM padronizou por meio de seu manual as diretrizes para classificação do sono utilizando o exame de PSG. Esses padrões serão utilizados como referência para a realização deste trabalho (Rundo, 2019).

2.2.2 Actigrafia

O exame de actigrafia é feito utilizando um dispositivo geralmente fixado ao pulso do paciente. O dispositivo então coleta dados de movimento que podem ser usados para estimar parâmetros do sono, com auxílio de algoritmos ou *softwares* específicos. Esses dispositivos actígrafos podem monitorar o sinal de movimento em um ou mais eixos, como por exemplo os actígrafos uniaxiais e os actígrafos triaxiais. Uma das vantagens do exame de actigrafia é o conforto e a possibilidade de monitorar os pacientes por um longo período de tempo, uma vez que o monitoramento pode ser feito ao longo dos dias sem a necessidade de se deslocar para uma clínica médica.

Em 1995, a AASM concluiu que a actigrafia seria útil apenas como uma ferramenta de estudo do sono, porém, sua utilidade clínica era incerta. Em 2002, a AASM expandiu seu conceito a respeito da actigrafia, indicando seu potencial para monitoramento do sono em condições clínicas. Por fim, um relatório atualizado da AASM em 2007 apoiou o uso da actigrafia para aplicações clínicas, particularmente para a avaliação de distúrbios do sono como insônia, hipersonia, e apneia obstrutiva do sono (Martin, 2011). Na Figura 3 são mostrados os exemplos de sinais de um actígrafo uniaxial e um actígrafo triaxial.

Figura 3 — Representação gráfica dos sinais captados por actígrafo triaxial (esquerda) e por um actígrafo uniaxial (direita)



Fonte: Benedito, 2021.

2.3 Processamento de sinais

O processamento de sinais envolve diferentes técnicas e métodos para extrair informações úteis dos sinais provenientes de diversas fontes. Neste trabalho, serão aplicadas algumas técnicas com o intuito de extrair as informações necessárias de sinais de PSG para seu uso na classificação de estágios do sono.

A seguir serão apresentados alguns conceitos relacionados a processamento de sinais com o intuito de contextualizar os métodos que serão utilizados no presente trabalho.

2.3.1 Transformada de Fourier

Segundo (Oppenheim, 2008), qualquer sinal periódico pode ser representado como uma soma ponderada de exponenciais complexas harmonicamente relacionadas e que compartilham um período comum com o sinal representado, em outras palavras, como uma série de Fourier.

Um sinal de tempo contínuo, ou convencionalmente chamado de sinal no domínio do tempo, pode ser analisado em termos de frequência, por meio da transformada de Fourier (em inglês, *Fast Fourier Transform* (FFT)), expressa matematicamente por:

$$F(\omega) = \int_{-\infty}^{\infty} f(t)e^{-i\omega t} dt$$

Sendo:

$f(t)$ = o sinal original no domínio do tempo

$e^{-i\omega t}$ = a exponencial complexa

2.3.2 Densidade Espectral de Potência

Em alguns casos quando é necessário calcular a potência de um sinal para cada unidade de frequência, pode ser calculada a Densidade Espectral de Potência.

A PSD é calculada elevando-se componente de frequência ao quadrado ao longo de todo o período de tempo, ou seja, elevando-se ao quadrado a transformada de Fourier. A PSD é descrita matematicamente da seguinte forma (Saini, 2022):

$$S(\omega) = \frac{1}{T} |X(\omega)|^2$$

Sendo $X(\omega)$ a transformada de Fourier do sinal de duração finita $x(t)$ a ser calculado, e $S(\omega)$ a componente do cálculo da potência média do sinal $x(t)$ denotado por:

$$P = \frac{1}{2\pi} \int_{-\infty}^{+\infty} S(\omega) d\omega$$

Quando T tende ao infinito.

2.4 Aprendizagem de máquina

Algoritmos de aprendizagem de máquina se propõem a aprender regras que relacionam os dados de entrada com os dados de saída (Ray, 2019). Uma das categorias principais desses algoritmos se refere a aprendizagem supervisionada, na qual o algoritmo aprende com base em dados de treinamento, onde são conhecidas as variáveis de entrada e variáveis de saída. Dessa forma, o algoritmo tenta prever as variáveis de saída a partir dos parâmetros de entrada.

Tratando-se de aprendizagem supervisionada, podemos classificar as abordagens de aprendizagem baseado no tipo de dado que o modelo irá prever. Quando a previsão de dados de saída se refere a uma variável discreta, dizemos que é uma abordagem de classificação. Por outro lado, quando a previsão de dados de saída se refere a uma variável contínua, dizemos que é uma abordagem de regressão (Zhou, 2021).

Ao longo desta seção serão analisados alguns algoritmos de aprendizagem de máquina utilizados amplamente na literatura e como referência deste trabalho para a classificação dos estágios do sono.

○ Regressão Linear

Um dos modelos mais simples existentes de regressão, e que serve como base para outros modelos, a regressão linear calcula a relação linear entre uma variável de saída (dependente) e uma ou mais variáveis de entrada (independente) e pode ser expressa da seguinte forma, segundo (SU, X., 2012):

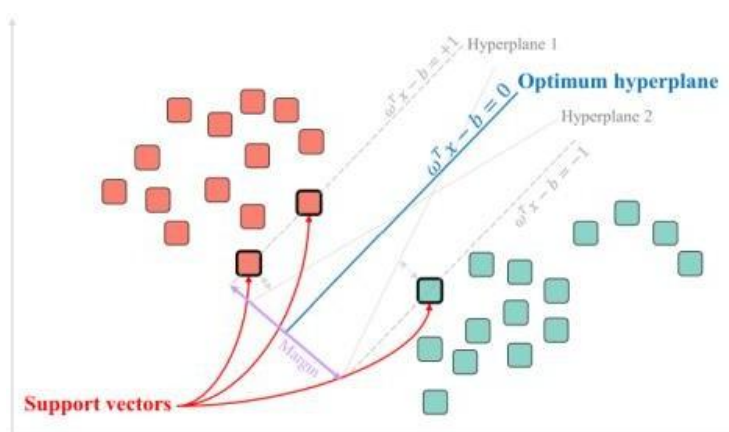
$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \varepsilon_i$$

- Support Vector Machine

O modelo de SVM é um dos modelos baseados em *kernel* mais utilizados atualmente. Modelos baseados em *kernel* envolvem utilizar técnicas lineares para resolver problemas não lineares. O modelo SVM é um classificador binário e linear que identifica os limites entre duas classes determinando um hiperplano separando o conjunto de dados em um número de classes predefinidas utilizando os dados de treinamento (Sheykhmousa *et al.*, 2020).

Uma ilustração do modelo SVM pode ser visto na Figura 4.

Figura 4 — Exemplo de SVM para dados linearmente separáveis



Fonte: Sheykhmousa *et al.*, 2020.

O modelo SVM conta com outros tipos de função para a resolução do problema, como a função polinomial, *Radial Basis Function* (RBF) e função sigmoide. Essas funções geram curvas que podem se adequar melhor ao modelo para a resolução do problema baseado nos dados de entrada.

Para o caso de classificações de múltiplas classes, podem ser utilizadas dois tipos de abordagens clássicas na literatura:

- Abordagem One-Vs-Rest (OVR)

Consiste na criação de um número definido de separadores binários, igual ao número de classificadores, em outras palavras, envolve dividir o conjunto de dados de várias classificações em múltiplos problemas de classificação binária. Desta forma,

um classificador binário é treinado em cada classificação binária, e as previsões são feitas utilizando o modelo mais confiável (Wang, 2014).

- Abordagem One-Vs-One (OVO)

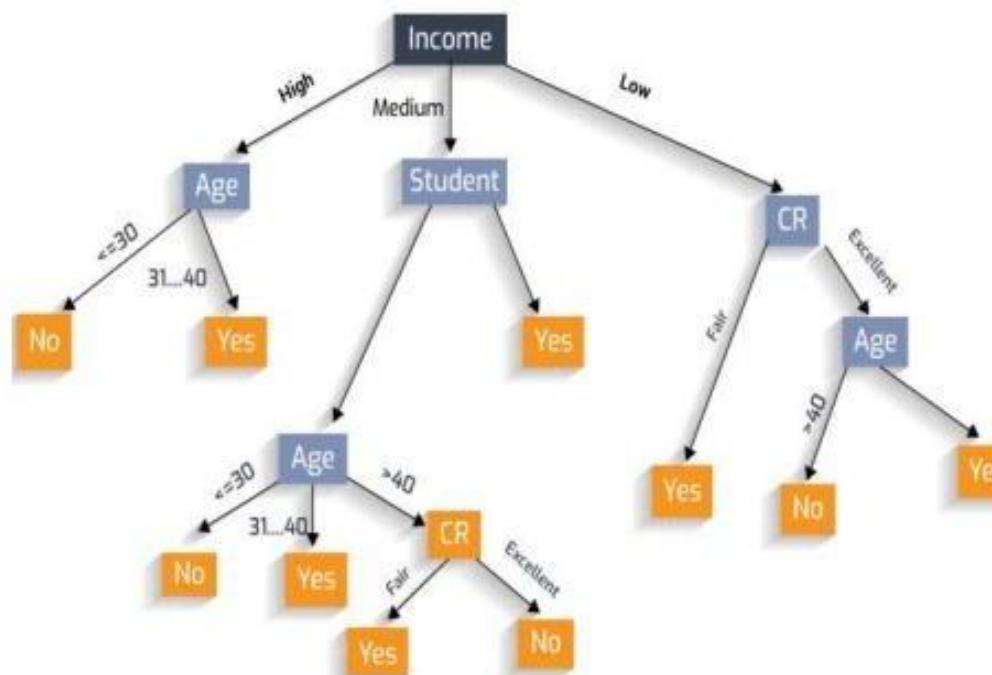
Consiste na criação de $m(m - 1)/2$ problemas de classificação binários, sendo “m” o número de classificadores. Após isso, um classificador binário é treinado em cada amostra de dados de treinamento. Para determinar a classe de uma amostra de treinamento, o número de classificadores binários obtido é usado para identificar a classe da amostra de teste, e a classe final do conjunto de teste é determinado integrando os resultados dos $m(m - 1)/2$ classificadores binários (Liu, 2017).

- Árvore de Decisão

O modelo de Árvore de Decisão (em inglês, *Decision Tree* (DT)), é bastante utilizado como modelo de classificação.

O modelo DT é composto de nós de decisão, representados por uma característica (*feature*) a ser classificada. A cada classificação feita, o modelo vai criando outros nós de decisões de acordo com a hierarquia do modelo, até concluir a classificação das *features* (Jijo, 2021). Um exemplo de árvore de decisão pode ser visto na Figura 5.

Figura 5 — Exemplo de árvore de decisão



Fonte: Jijo, 2021.

Na seção seguinte será apresentada uma revisão bibliográfica de alguns trabalhos que utilizam sinais de PSG em conjunto com técnicas de processamento de sinais e diferentes modelos de aprendizagem de máquina para a classificação de estágios do sono, com o intuito de favorecer a interpretação dos resultados obtidos deste trabalho.

3 REVISÃO BIBLIOGRÁFICA

As mudanças contínuas das atividades do corpo humano que caracterizam o sono podem ser medidas por meio de sinais de polissonografia, composto por diferentes tipos de sinais fisiológicos como eletroencefalograma (EEG), eletrooculograma (EOG), eletromiograma (EMG) e eletrocardiograma (ECG).

Após a etapa de seleção e leitura dos canais é sugerido pela literatura uma etapa de pré-processamento dos sinais, com o intuito de minimizar os efeitos de contaminação dos sinais, sobretudo os de EEG, que podem ser afetados por espasmos musculares e movimento dos olhos. Uma forma de realizar esse processamento é utilizando um filtro passa-faixas nas frequências 0,2 Hz e 40 Hz (03). Ainda nesta etapa, alguns trabalhos presentes na literatura sugerem a divisão dos sinais em trechos de 30 segundos, chamados de *epochs*, baseados nas regras da *American Academy Sleep Medicine* (AASM) para a classificação de cada um dos cinco estágios do sono (N1, N2, N3, REM ou W) (Berry, 2012).

Em seguida, alguns trabalhos realizam a etapa de extração de *features*, que são os dados que servirão de entrada para o modelo de aprendizagem de máquina e cuja escolha pode variar de acordo com a escolha dos canais de gravação de PSG e a escolha dos métodos de pré-processamento dos sinais.

Por fim, as *features* são utilizadas como entrada para o modelo de classificação. Na literatura são utilizadas diferentes modelos, sendo os mais comuns os modelos DT e *Support Vector Machine* (SVM). Ao final do processo, esses modelos são avaliados por meio de métricas de desempenho descritas na literatura, a fim de avaliar a precisão do modelo. (Aboalayon, 2016).

Nesta seção serão apresentadas algumas técnicas utilizadas na literatura a respeito de classificação de estágios de sono por meio de sinais de PSG com auxílio de algoritmos de aprendizagem de máquina. Ao longo do capítulo serão abordados alguns métodos que utilizam múltiplos canais de PSG e processamento de sinais para extração de *features* e classificação de estágios do sono com um ou mais modelos de aprendizagem de máquina.

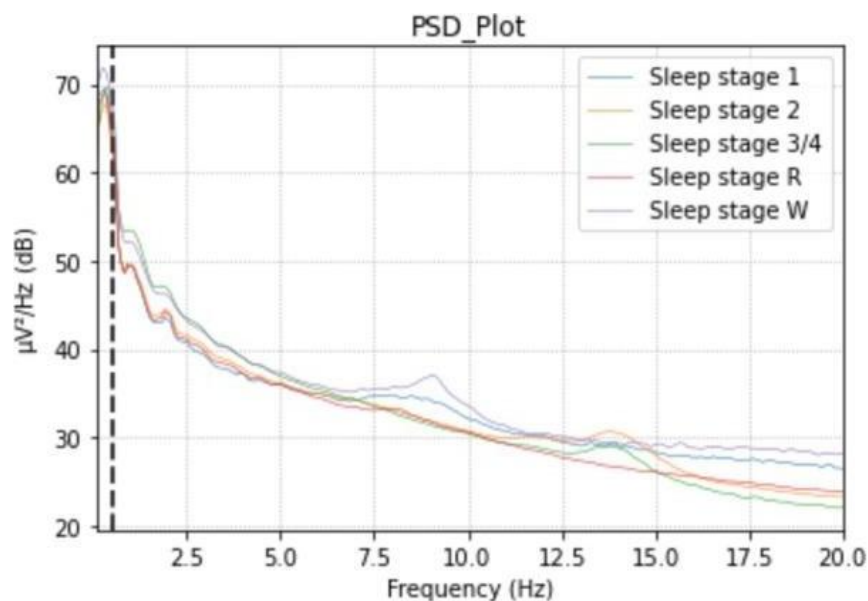
3.1 Método utilizando-se de múltiplos canais, com modelo híbrido de aprendizagem de máquina

Ao se utilizarem múltiplos canais de PSG, é possível extrair *features* de cada um desses canais. A classificação de estágios de sono pode ser obtidas por diversos tipos de *features*, que podem ser amplamente classificadas como lineares e não-lineares. Um exemplo de *features* lineares inclui *features* no domínio de tempo e no domínio da frequência, como a análise de densidade espectral de potência, que descreve a distribuição de potência em componentes de frequências que compõem um determinado sinal (Stoica, 2015). O processamento do sinal de PSG utilizando-se a função PSD é então utilizada para cada faixa de frequência associada com as seguintes ondas cerebrais, de acordo com o padrão da AASM:

- Delta (0.5 – 4.5 Hz);
- Theta (4.5 – 8.5 Hz);
- Alpha (8.5 – 11.5 Hz);
- Sigma (11.5 – 15.5 Hz);
- Beta (15.5 – 32.5 Hz).

Após essa etapa, é possível extrair *features* como potência total e potência relativa, para cada *epoch* de 30 segundos. O sinal de PSD para as frequências acima é mostrado na Figura 6.

Figura 6 — Exemplo de sinal PSD gerado a partir de sinal de EEG




Fonte: elaborado pelo próprio autor.

Além disso, é possível extrair *features* não lineares como a entropia de permutação, que caracteriza a complexidade da série temporal. De maneira resumida, quando nos sinais de EEG prevalecem altas frequências, o valor de entropia é próxima de 1, e quando prevalecem baixas frequências, o valor de entropia atinge valores mínimos (Bandt; Pompe, 2002).

Extraindo *features* lineares e não lineares por meio da utilização de múltiplos canais de PSG, é possível extrair mais de cem *features* que irão compor os dados que servirão de entrada para o modelo de aprendizagem de máquina. Um dos métodos utilizados na literatura para modelo de classificação se refere ao modelo de classificação *Multi-Class SVM* baseado em abordagem de DT. O modelo de *Multi-Class SVM* consiste em utilizar *frameworks* para modificar o modelo SVM – que tem um melhor desempenho para classificação binária, isto é, entre duas classes – e possibilitar seu uso em um maior número de classificações (N1, N2, N3, REM ou W) (Lajnef, 2015).

Uma técnica estudada pela literatura para integrar ao modelo de *Multi-Class SVM* um *framework* baseado em um modelo de DT, no qual há um modelo hierárquico, que pode ser dividido de forma recursiva em conjuntos menores, com base nas regras aprendidas no processo de treinamento (Alpaydin, 2020) é o chamado *Dendro-Support Vector Machine* (DSVM), que consiste em incluir em cada nó de decisão um sistema binário de classificação SVM (Lajnef, 2015). Um diagrama deste método é mostrado na Figura 7.

Figura 7 — Exemplo de algoritmo DSVM



Fonte: Lajnef , 2015

Este método consegue atingir altas medidas de desempenho. Porém trata-se de um modelo complexo e com um custo computacional elevado quando se trata de utilizar mais dados de entrada.

3.2 Método utilizando-se de múltiplos canais e classificação pelo modelo *Decision Tree*

Um dos métodos presentes na literatura sugere a utilização de múltiplos canais e extração de *features* baseadas nos padrões da AASM (Gunnarsdottir, 2018).

Este método realiza o pré-processamento dos sinais, dividindo-os em *epochs* de 30 segundos, excluindo-se eventos contaminados por sinais de movimentos musculares. Em seguida, são extraídas as *features* no domínio do tempo e da frequência, como a potência das ondas alpha, theta, beta e delta, tal como os valores de energia do canal de EMG, relacionado aos estímulos musculares, e sinais de EOG. A escolha das *features* foi feita tomando como base os padrões da AASM, e podem ser vistas na Tabela 1.

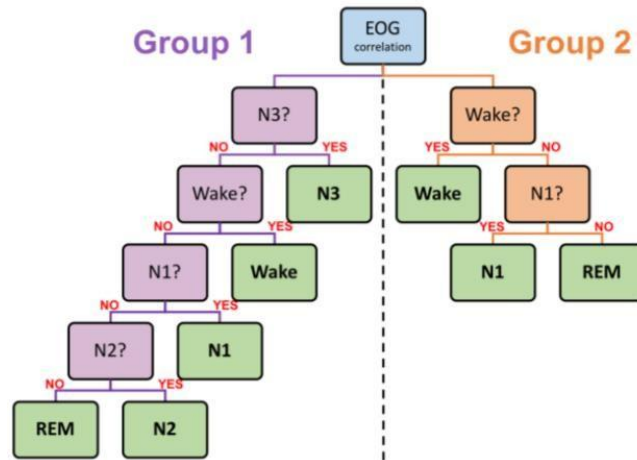
Tabela 1 — Escolha de *features* utilizadas para treinamento do modelo de *Decision Tree*

Sleep stage	Quantitative feature	Signal	AASM feature
Group 1 vs. Group 2	EOG ₁ ^{0.3-35}	Right EOG and Left EOG	Eye movements present/absent
Wake	EMG Energy	EMG Chin, Left Leg, Right Leg	Increased EMG activity
	Alpha Power	O1-A2 EEG	Alpha rhythm observed
	Theta Power	O1-A2 EEG	Low theta activity
N1	EOG ₂ ^{0.1-0.45}	Right EOG and Left EOG	Eye movements present
N2	Maximum Spindle Duration	F3-A2 EEG	Spindles present
	Number of Spindles	C4-A1 EEG	Spindles present
	Delta Power	F3-A2 EEG	Moderate to high delta activity
	EOG ₃ ^{0.3-0.45}	Right EOG and Left EOG	Little to no rapid eye movements
N3	Delta Power	F4-A1 EEG	High delta activity
	Beta Power	F3-A2 EEG	Low beta activity

Fonte: Gunnarsdottir; Gamaldo, 2018.

As *features* extraídas servem então como entrada para o modelo de classificação de DT, onde o autor a divide em dois grupos, G1 e G2, nos quais a quantidade de movimento dos olhos, obtido por meio de sinal de EOG, define como cada *epoch* de 30 segundos será classificado. Em um primeiro momento, caso haja pouco ou nenhum movimento ocular, a classificação será direcionada para G2, no qual está a possibilidade do evento ser classificado como W, N1 ou REM, enquanto no G1 pode ser classificado como N3, N2, N1, W ou REM, como mostrado na Figura 8.

Figura 8 — Árvore de decisão utilizada para classificar os estágios do sono



Fonte: GUNNARSDOTTIR; GAMALDO, 2018.

Este método consiste em uma técnica mais simples de classificação, com uma acurácia de geral de 80,7% utilizando-se de um modelo de classificação de DT amplamente encontrado na literatura utilizando-se de múltiplos canais de PSG.

3.3 Método utilizando-se de múltiplos canais e classificação pelo modelo CNN

Um modelo bastante presente na literatura é o modelo *Convolutional Neural Network* (CNN) utilizando a arquitetura *DeepSleepNet*, que consiste em duas partes. A primeira parte é o aprendizado de representação, que pode ser treinado para aprender filtros para extrair as *features* de cada um dos eventos de sinais brutos de EEG. A segunda parte é o aprendizado residual, que pode ser treinado para codificar as informações temporais a partir de uma sequência de eventos de EEG das *features* extraídas (Supratak, 2017).

No trabalho de Kim (2020), as *features* foram extraídas a partir do pré-processamento dos sinais de entrada utilizando um filtro passa-faixas nas faixas de frequências correspondente às ondas delta, theta, alpha e beta. Os sinais foram divididos então em grupos de controle e experimental. No primeiro, foram utilizados os canais de EEG e EOG limitando a frequência máxima em 50 Hz. No segundo grupo foi aplicado o processamento por meio da arquitetura CNN, que consiste em quatro camadas de convolução e duas camadas de agrupamento máximo. As *features* escolhidas e os detalhes de cada camada estão descritos na Tabela 2.

Tabela 2 — Escolha de *features* utilizadas para treinamento do modelo de CNN

Number	Layer type	Number of filters	Kernel size	Stride	Activation function	Output size
1	Convolution 1	10	200×1	1×1	ReLU ^a	$10 \times 2801 \times 6$ ($10 \times 2801 \times 2$)
2	Max-pooling 1	10	-	2×1	-	$10 \times 1400 \times 6$ ($10 \times 1400 \times 2$)
3	Convolution 2	20	32×2 (32×1)	1×1	ReLU	$20 \times 1369 \times 5$ ($20 \times 1369 \times 2$)
4	Convolution 3	30	128×2 (128×1)	1×1	ReLU	$30 \times 1242 \times 4$ ($30 \times 1242 \times 2$)
5	Convolution 4	40	512×4 (512×2)	1×1	ReLU	$40 \times 731 \times 1$
6	Max-pooling 2	40	-	2×1	-	$40 \times 365 \times 1$
7	Fully-connected 1	1	-	-	ReLU	100×1
8	Fully-connected 2	1	-	-	Softmax	5×1

Fonte: Kim, 2020.

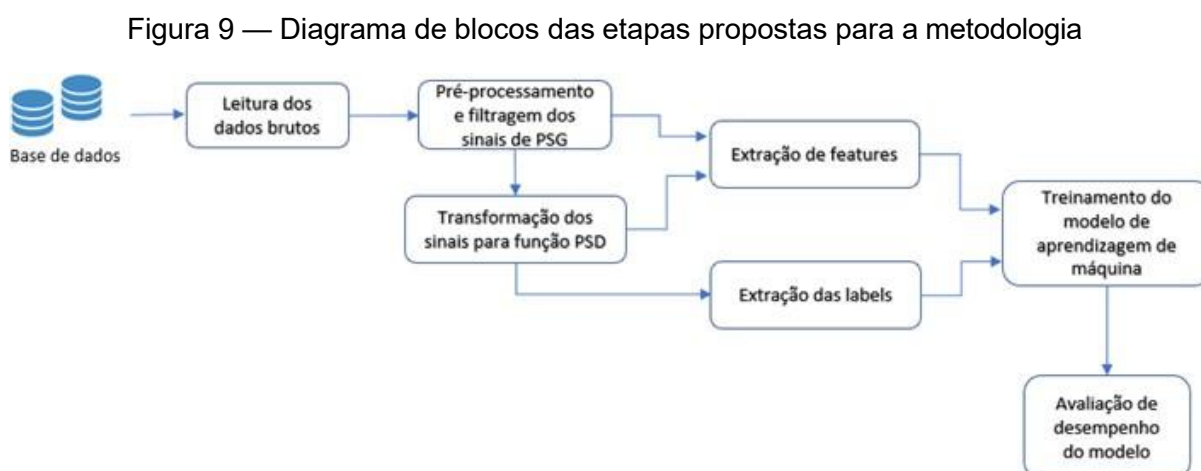
Adicionalmente foram analisados os PSDs em cada estágio com o intuito de investigar o que o modelo está aprendendo. O modelo apresentado atinge uma acurácia geral de 85,6%, utilizando de técnicas de redes neurais e de dados provenientes da base de dados *sleep-edf (expanded)*, a mesma utilizada para a realização do presente trabalho.

Os trabalhos apresentados nesta seção representam uma parte do que a literatura sugere para a classificação de estágios do sono por meio de sinais de PSG e serviram de motivadores para a realização deste trabalho.

4 METODOLOGIA

Nesta seção serão descritas as etapas do que envolvem os algoritmos estudados propostos neste trabalho. Para a estruturação do algoritmo, do ponto de vista de código, a principal referência foi o trabalho de Chambon et al. (2018), enquanto do ponto de vista de procedimentos para tratamento dos sinais e modelo de classificação foram utilizados como referência os trabalhos de Kim (2020) e Gunnarsdottir (2018).

Na Figura 9 é apresentado um diagrama de blocos com as etapas propostas e que serão detalhadas nas seções a seguir.



Fonte: elaborado pelo próprio autor.

4.1 Seleção da base de dados

Com o intuito de cumprir com o objetivo do trabalho de classificar os estágios do sono por meio de sinais de PSG, foi utilizada a base de *dados sleep-edf database expanded* disponibilizada pela *PhysioNet* contendo 153 registros de dados de PSG. Esta base de dados foi utilizada nos trabalhos de Kim (2020) e Kemp (2000) e contém informações de 197 noites de sono coletadas por PSG. Os arquivos disponibilizados estão divididos em dois padrões de arquivos compostos pelos seguintes dados:

- Arquivos no padrão “*PSG.edf*”
 - Gravação dos sinais de Eletroencefalograma (EEG);
 - Gravação dos sinais de Eletro-oculograma (EOG);

- Gravação dos sinais de Eletromiografia (EMG);
- Marcadores de eventos;
- Sinais de respiração oronasal;
- Temperatura retal.
- Arquivos no padrão “*Hypnogram.edf*”
- Anotações de especialista associados aos estágios de sono do paciente.

Os sinais de EOG e EEG foram amostrados a uma frequência de 100 Hz, enquanto os sinais de respiração oronasal, temperatura retal e marcadores de eventos foram amostrados com uma frequência de 1 Hz e os sinais de EMG foram submetidos a filtros passa-altas, retificado e em seguida filtrado com um passa-baixas, tendo o sinal de saída após esses procedimentos sido amostrado com frequência de 1 Hz. Esta base de dados foi usada nos trabalhos de Kim (2020), para a classificação de estágios do sono utilizando *features* temporais e espectrais, e Chambon et al. (2018), para o desenvolvimento de uma arquitetura de *deep learning* para a classificação temporal de estágios do sono utilizando séries temporais multivariadas e multimodais.


4.2 Leitura dos dados brutos

Os dados brutos estão dispostos em arquivos no formato EDF (em inglês, *European Data Format*), não estando, portanto, pronto para uso direto nas bibliotecas de aprendizagem de máquinas para *python*. Para que seja feita uma leitura dos dados na base de dados, será utilizada a biblioteca *MNE-Python* com o intuito de realizar a leitura dos arquivos citados na seção anterior.

Após esta etapa, já é possível ter acesso aos dados temporais dispostos em canais para cada tipo de sensor, semelhante ao formato mostrado na Figura 10.

Figura 10 — Exemplo de sinais temporais de PSG multicanal gerados após leitura utilizando

MNE-Python



Fonte: elaborado pelo próprio autor.

4.3 Pré-processamento do sinal e transformação PSD

A etapa de pré-processamento dos sinais tem como objetivo preparar o sinal para sua modelagem e determinação de variáveis de resposta tal como a extração de dados que serão usados como entrada para o algoritmo de aprendizagem de máquina, comumente chamados de *features*, e extração de *labels*, que por sua vez funcionam como variáveis de resposta para que o algoritmo desenvolvido aprenda a estimar, baseado nas *features*.

Com o intuito de facilitar o processamento dos sinais de sono, considerando que estes estão divididos em gravações de sono com durações diferentes, e seguindo as padronizações de anotações de especialistas e diretrizes da AASM (Berry, 2015), foi necessário particionar os sinais brutos de PSG em *epochs* de 30 segundos, como feito

em Kim (2020).

Ao fazer a leitura dos sinais de PSG, foi necessário fazer o corte dos 30 minutos iniciais e finais da gravação de cada paciente, com o objetivo de remover os primeiros e últimos eventos do estado *Wake*, que representam os momentos que o paciente não está em estado de sono, considerando que os eventos de estado *Wake* relevantes estão distribuídos ao longo do estado de sono.

O pré-processamento inicial proposto consiste em aplicar um filtro passa faixas com frequência mínima de corte de 0.2 Hz (Lajnef, 2015) e máxima de 50 Hz (Kim, 2020) nos sinais de EEG.

Após essa etapa, foi aplicado ao sinal de EEG a transformação para a função de densidade espectral de potência (PSD) como proposto em Kim (2020) a fim de descrever como a potência do sinal temporal está distribuído na frequência. Para tal, será utilizada a biblioteca *python scikit-learn preprocessing*. Após as etapas descritas, o sinal estará em um formato favorável para extração de *features*.

4.4 Extração de *features* e *labels*

Nesta etapa, as anotações provenientes dos arquivos *Hypnogram.edf* serão utilizados para definir os estágios de sono. Os estágios de sono propostos na realização do trabalho e presentes no arquivo de eventos serão: Acordado (em inglês, *Wake* (W)), Estágio 1 (N1), Estágio 2 (N2), Estágio 3/4 (N3/4) e REM.

Em geral, há diversos critérios para classificação de cada estágio do sono. Para a realização do trabalho, será utilizado o padrão *American Academy of Sleep Medicine* (AASM), um dos padrões dominantes, que define os estágios de sono e suas respectivas faixas de frequências de sinais de EEG, sendo elas:

- Ondas beta (W): 15 Hz a 30 Hz.
- Ondas alpha (S1): 8 Hz a 12 Hz.
- Ondas sigma (S2): 12 Hz a 15 Hz.
- Ondas delta (S3/4): 0.5 Hz a 4 Hz.
- Ondas theta (REM): 4 Hz a 8 Hz.

4.4.1 Extração de *features*

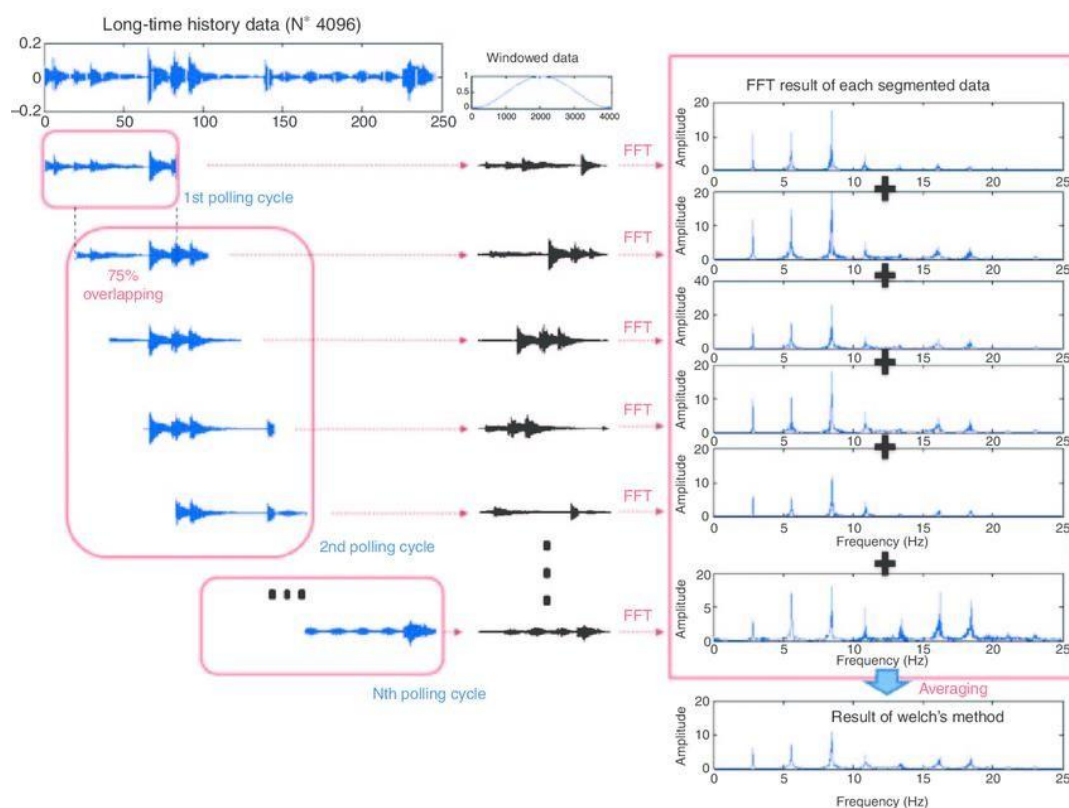
Após a passagem do sinal bruto do canal de EEG (Fpz-Cz) pela filtragem nas faixas de frequências apresentadas na seção anterior, foi obtido uma matriz com “n” linhas contendo o número de eventos e 5 colunas, representando as densidades espectrais de potência para as frequências filtradas para cada onda cerebral beta, alpha, sigma, delta e theta semelhante ao utilizado em Kim (2020). Essa matriz compõe os dados que serão utilizados como entrada para os modelos de aprendizagem de máquina.

A densidade espectral de potência (PSD) de uma série temporal, como no caso do sinal de EEG, descreve como a potência desse sinal está distribuída nas frequências que o compõem. Neste caso, a média estatística de um sinal quando analisado em termos de frequência é chamada de espectro.

A densidade espectral de potência para cada *epoch* de 30 segundos é calculada baseada no método de Welch (Ameera, 2019), no qual o sinal é dividido em diferentes janelas e para cada janela é calculada sua Transformada de Fourier para se obter o quadrado da magnitude de cada periodograma (estimativa da densidade espectral do sinal). Essa análise é feita sequencialmente com o deslocamento dos sinais escolhidos para cada janela, representando uma sobreposição em relação ao sinal da janela anterior. No caso deste trabalho, foi escolhido um valor nulo de sobreposição, ou seja, cada início da janela de sinal representa o final da janela anterior. Após isso, é calculada uma média dos periodogramas para cada *epoch* de 30 segundos. Este processo é calculado para cada frequência descrita na seção anterior. Na Figura 11 é possível ver graficamente um exemplo do método de Welch para o cálculo da densidade espectral de potência.

Figura 11 — Exemplo de cálculo da densidade espectral de potência por meio de método de

Welch



Fonte: Cho *et al.*, 2010.

4.4.2 Extração de *labels*

As *labels* são os dados que os modelos de aprendizagem deverão estimar. Nesta etapa, as anotações provenientes dos arquivos *Hypnogram.edf* serão utilizados para definir os estágios de sono. Os estágios de sono serão as *labels* propostas na realização do trabalho e presentes no arquivo de eventos. São eles: Acordado (W), Estágio 1 (N1), Estágio 2 (N2), Estágio 3/4 (N3/4) e REM.

4.5 Treinamento e avaliação dos modelos de aprendizagem

Nesta etapa, serão detalhados os procedimentos de escolha dos modelos de aprendizagem de máquina, que terão como dados de entrada as *features* extraídas nas etapas anteriores e deverão estimar os valores de saída tendo como referência as *labels* escolhidas.

Após a extração de *features* e *labels*, o conjunto de dados é dividido entre um

grupo de treino e um de teste. Os dados de entrada do modelo são compostos por uma matriz 4066 X 5 (Número de *epochs* X número de frequências analisadas), contendo os valores das *features* para cada evento dos dados das gravações. Associada a esses dados, também compõem os dados de entrada as anotações para cada evento extraídas do arquivo *Hypnogram.edf*. Os dados de treino e teste são então divididos na proporção de 80/20 (treino/teste).

Após esta etapa, os hiper parâmetros dos modelos de treinamento são escolhidos por meio da função *GridSearch*, que realiza uma busca exaustiva pelos hiper parâmetros que fazem com que os modelos tenham melhor performance. Os hiper parâmetros são valores específicos dentro de cada modelo de treinamento que podem, de acordo com o valor escolhido e a relação com outros hiper parâmetros, melhorar o desempenho do modelo. Após isso, os modelos são avaliados por meio de validação cruzada, um procedimento que testa os parâmetros do modelo para diferentes subconjuntos dos dados de treinamento. Este processo possibilita que sejam escolhidos os parâmetros para implementação do modelo de aprendizagem de forma a atingir seu melhor desempenho. Para esta etapa foram testados e comparados 2 tipos de modelos de aprendizagem: *Random Forest* (RF) e *Multi-Class SVM*. Cada um desses modelos tem hiper parâmetros próprios, explicados a seguir:

- Hiper parâmetros escolhidos do modelo RF
 - Número de estimadores (*n_estimators*): Se refere ao número de árvores de decisões no modelo.
 - Profundidade máxima (*max_depth*): O número de colunas ou camadas de hierarquia para cada árvore de decisão.
 - *Minimum Sample Split* (*min_sample_split*): Número mínimo de amostras requeridas para dividir um nó de decisão.
 - *Minimum Sample Leaf* (*min_sample_leaf*): Número mínimo de amostras para compor o bloco final de decisão da árvore de decisão.
 - *Max_features*: O número de *features* para se considerar ao tentar dividir um nó de decisão. Esse parâmetro é uma função que relaciona o número máximo de *features* necessários com o número de *features* que treinarão o modelo.

- Hiper parâmetros escolhidos para o modelo *Multi-Class SVM*
 - C: O parâmetro C indica ao modelo a precisão de escolha de cada exemplo de treinamento. Para um valor de C alto, a otimização escolherá uma margem menor no hiper plano para classificar corretamente os dados de treinamento.
 - *Gamma*: O parâmetro *gamma* indica o quanto o modelo deve se flexibilizar em relação aos dados de treinamento, influenciando na distância na qual as amostras serão consideradas para o cálculo da fronteira de decisão.
 - *Kernel*: O parâmetro *kernel* especifica a função que será utilizada no algoritmo para adequar o hiper plano do modelo aos dados.
 - *Decision_function_shape*: Especifica a abordagem que será utilizada para classificação dos dados, pode assumir os valores “ovo” ou “ovr” (Pedregosa *et al.*, 2011).

Nas Tabelas 3 e 4 estão contidos os hiper parâmetros utilizados, assim como a faixa de valores aplicados na função *GridSearch* para realizar a busca de parâmetros para melhor desempenho dos modelos.

Tabela 3 — Escolha de *features* utilizadas para treinamento do modelo *Multi-Class-SVM*

Parâmetros	Faixa de valores	Valor escolhido
C	5, 10, 100, 200, 1000	1000
<i>Gamma</i>	0.001, 0.01, 0.1, 1	1
<i>Kernel</i>	“rbf”, “linear”, “poly”, “sigmoid”	“rbf”
<i>Decision_function_shape</i>	“ovo”, “ovr”	“ovo”

Fonte: elaborado pelo próprio autor.

Tabela 4 — Escolhas de *features* utilizadas para treinamento do modelo RF

Parâmetros	Faixa de valores	Valor escolhido
n_estimators	50, 100, 200, 500	500
max_depth	5, 10, 20, 30	30
min_sample_leafs	1, 2, 4, 10	10
min_sample_split	2, 5, 10, 20	20
max_features	“sqrt”, “log2”	“sqrt”

Fonte: elaborado pelo próprio autor.

Ao final da escolha dos modelos e seus parâmetros associados, é necessário avaliar o desempenho do modelo, utilizando para isso métricas de desempenho utilizados pela literatura de referência deste trabalho.

Este processo consiste em calcular algumas métricas tomando como base a eficácia do modelo do ponto de vista de adequação a outros conjuntos de dados, ou seja, avaliar se os parâmetros escolhidos apresentam uma boa precisão apenas para os conjuntos de dados treinados ou para outros conjuntos desconhecidos de maneira geral.

Os indicadores de desempenho utilizados para avaliar os modelos de aprendizagem são calculados por meio da matriz de confusão, que consiste em uma tabela contendo a frequência de incidência dos dados em quatro classificações: Falso Negativo (FN), Falso Positivo (FP), Verdadeiro Positivo (TP) e Verdadeiro Negativo (TN), nas quais:

- TP = valores positivos corretamente previstos pelo modelo.
- TN = valores negativos corretamente previstos pelo modelo.
- FP = valores positivos erroneamente previstos pelo modelo.
- FN = valores negativos erroneamente previstos pelo modelo.

Em uma matriz de confusão binária, ou seja, com apenas duas possíveis classificações, é possível estabelecer com facilidade uma classe como positiva e outra negativa. Porém, para mais classificações, a classificação de estados positivos ou negativos são estabelecidos por um valor de referência. No caso dos estágios do sono como classificação, do ponto de vista do estágio W, os estágios N1, N2, N3/4 e REM são valores negativos. A partir destes valores é possível calcular os seguintes parâmetros de desempenho do modelo como indicado em Rohan (2021) que

representam a relação entre valores previstos e valores gerados pelo modelo:

- *Acurácia* = $\frac{TP+TN}{TP+TN+FN+FP}$ (Avalia o percentual de acertos);

- *Sensibilidade (recall)* = $\frac{TP}{TP+FN}$ (Avalia a capacidade de detectar resultados positivos);

- *Especificidade* = $\frac{TN}{TN+FP}$ (Avalia a capacidade de detectar resultados negativos);

- *Precisão* = $\frac{TP}{TP+FP}$ (Relaciona a quantidade de verdadeiros positivos sobre a soma de todos os valores positivos);

- *F1 Score* = $\frac{2*TP}{2*TP+FP+FN}$ (Média harmônica calculada com base na precisão e no recall).

Além das métricas de desempenho descritas acima, foi calculada a curva de aprendizagem do modelo, que consiste em calcular o erro de generalização e a precisão do modelo em relação ao conjunto de treinamento. A curva de aprendizagem descreve a performance do modelo em relação ao seu aprendizado. Em outras palavras, a partir da curva de aprendizagem é possível entender a evolução da capacidade do modelo em relação a valores como parâmetros do modelo ou tamanho do conjunto de dados. Além disso, a curva de aprendizagem descreve a capacidade do modelo de generalizar o aprendizado, ou seja, a capacidade de manter ou não a performance caso seja alimentado por um conjunto de dados de treinamento desconhecido.

5 RESULTADOS E DISCUSSÕES

Nesta seção serão apresentados os resultados obtidos a partir dos algoritmos estudados no presente trabalho. Inicialmente será apresentada a estrutura dos algoritmos utilizados para a classificação dos estágios do sono por meio de sinais de PSG com auxílio de processamento de sinais e algoritmos de aprendizagem de máquina. Após isso serão apresentados os resultados da utilização dos mesmos em comparação com alguns métodos utilizados na literatura como referência para este trabalho.

5.1 Estrutura dos algoritmos de referência

Os algoritmos de referência foram construídos dentro de uma sequência que vai desde a leitura dos dados brutos, passando pelo pré-processamento dos sinais, aplicação de processamento de sinais até o treinamento e validação do modelo de aprendizagem de máquina. A sequência é mostrada a seguir.

1. Importação de bibliotecas e leitura dos dados brutos

Inicialmente são importadas as bibliotecas principais utilizadas no trabalho. São elas:

- *Numpy*: Utilizada para manipular matematicamente funções em listas e matrizes.
- *Matplotlib*: Utilizada para a construção de gráficos.
- *MNE*: Utilizada para leitura e manipulação dos dados brutos em formato EDF e cálculo da densidade espectral de potência.
- *Sklearn*: Utilizada para manipulação de modelos de aprendizagem de máquina, tal como validação e cálculo de métricas de desempenho dos modelos.

Após a importação das bibliotecas, é extraído o sinal bruto de 19 pacientes, de acordo com a Tabela 5.

Tabela 5 — Dados dos pacientes escolhidos

Características do paciente	Estatística de pacientes
Gênero (M/F)	9/10
Idade (anos)	29.5±4.5

Fonte: elaborado pelo próprio autor.

2. Pré-processamento dos dados

Após a primeira etapa, os dados brutos, que são compostos de sinais dos sensores de PSG, são associados às anotações de especialistas com as classificações de estágios do sono, contidas nos arquivos de formato “*Hypnogram.edf*”. Em seguida, são removidos os primeiros e últimos 30 minutos de anotações das gravações, com o intuito de remover as anotações para estados em que o paciente está em estado acordado. Para concluir o pré-processamento, os dados são concatenados e divididos em trechos contínuos de 30 segundos.

3. Definição das *labels* e cálculo de densidade espectral de potência para extração de *features*

Na sequência, é criado um dicionário de identificadores de eventos, classificados em (W), (N1), (N2), (N3) e (REM). Após essa etapa, é criada uma função para calcular o PSD nas diferentes faixas de frequência correspondentes às ondas cerebrais delta, theta, alpha, sigma e beta utilizando o método Welch por meio do comando `psd_welch`. Isso é feito para os dois canais de EEG (EEG Fpz-Cz e EEG Pz-Oz). Nessa etapa também é aplicado um filtro passa-faixas nas frequências de 0.2 a 50Hz, com o intuito de atenuar ruídos provenientes de outros canais do PSG. O cálculo de PSD obtido para cada trecho de 30 segundos são escolhidos como as *features*, que são os dados que treinarão o modelo de aprendizagem de máquina.

4. Treinamento dos modelos de aprendizagem

Nessa etapa foram definidos os conjuntos de dados de treino e dados de teste,

seguinto uma proporção respectivamente de 80/20. Após isso, foi aplicada a função *GridSearch*, que realiza uma busca exaustiva para determinar os hiper parâmetros dos modelos de aprendizagem. Foram treinados 2 modelos de aprendizagem de máquina, sendo eles: *Multi-Class SVM* e *Random Forest* (RF).

5. Avaliação de desempenho dos modelos


Após o treinamento dos modelos, foram calculadas suas matrizes de confusão, a acurácia geral dos modelos e a curva de aprendizagem dos modelos.

5.2 Experimentos

Considerando os parâmetros e a metodologia escolhida e detalhada nas seções anteriores, são apresentados os resultados comparativos dos algoritmos de classificação de estágios do sono, utilizando sinais de PSG com auxílio de processamento de sinais e aprendizagem de máquina utilizando os modelos *Multi-Class SVM* e RF.

Na Figura 12 é possível ver a matriz de confusão de cada modelo, contendo os valores normalizados (de 0 a 1) representando a acurácia do modelo para cada condição de treinamento e teste.

Figura 12 — Matrizes de confusão do modelo SVM (esquerda) e do modelo *Random Forest* (direita)



Fonte: elaborado pelo próprio autor.

No modelo apresentado, a matriz de confusão apresenta uma baixa acurácia no estágio N1. Isso se deve à quantidade relativamente baixa de amostras identificadas neste estágio em relação aos outros estágios, e, como visto em Kim (2020), a discrepância no número de classes afeta a performance do modelo.

Além da matriz de confusão, também foram calculadas as métricas de desempenho descritas na seção de Metodologia. É possível ver os valores na Tabela 6.

Tabela 6 — Métricas de desempenho calculadas para os modelos de *Multi-Class-SVM* e RF


Estágio do sono	Precisão		<i>Recall</i>		<i>F1-Score</i>		Número de eventos avaliados
	SVM	RF	SVM	RF	SVM	RF	SVM/RF
W	0,87	0,85	0,88	0,91	0,88	0,88	848
N1	0,68	0,72	0,74	0,73	0,71	0,77	687
N2	0,54	0,57	0,19	0,24	0,28	0,33	228
N3	0,82	0,86	0,85	0,86	0,84	0,86	1732
REM	0,77	0,83	0,79	0,81	0,78	0,82	571

Fonte: elaborado pelo próprio autor.

Por fim, foi feita a validação cruzada dos dois modelos com um $k = 10$ como proposto em Lajnef (2015), ou seja, 10 blocos de treino, cada um com um subconjunto diferente para treino e teste, com o intuito de avaliar a aprendizagem dos mesmos em ambos os modelos. A curva de aprendizagem pode ser vista na Figura 13.

Figura 13 — Curvas de aprendizagem do modelo SVM (esquerda) e do modelo *Random*

Forest (direita)



Fonte: elaborado pelo próprio autor.

Considerando a tabela e as figuras apresentadas, é possível observar que o modelo *Random-Forest* obteve uma maior acurácia para todos os estágios do sono, assim também como a grande maioria das métricas de desempenho, que apresentam valores maiores do que no modelo *Multi-Class-SVM*, com exceção da precisão do estágio W e o *recall* no estágio N1. Além disso, as curvas de aprendizagem mostram que o modelo baseado em SVM tem precisão variável, e que aumenta de acordo com o tamanho do conjunto de dados, assim como a precisão do modelo para os conjuntos de dados de treino e teste apresentadas. Já o modelo RF apresenta uma precisão do modelo fixa ao longo do tamanho, do conjunto de dados de treinamento, enquanto sua precisão aumenta quanto maior for o tamanho do conjunto de treinamento. Uma observação importante é que no modelo *Multi-Class-SVM* a sensibilidade da precisão do modelo é maior do que no modelo *Random Forest*. Isso pode indicar que para valores altos para o tamanho do conjunto de treinamento, a precisão do modelo baseado em SVM pode ultrapassar os resultados do modelo de RF. Porém, um ponto a ser considerado é que a precisão fixa do modelo RF ao longo do tamanho do conjunto de dados é um forte indicador de que o modelo sofreu *overfitting*, ou sobreajuste, o que significa que o modelo se ajustou bem aos dados apresentados, mas que sua eficácia em relação a modelos desconhecidos é duvidosa. Um dos fatores que podem ter ocasionado o *overfitting* é que as *features* escolhidas para treinar o modelo foram redundantes ou insuficientes.

Após comparar os modelos treinados entre si, é possível comparar os resultados dos modelos propostos neste trabalho com os algoritmos presentes na literatura, que

foram usados de referência para a elaboração deste trabalho. A Tabela 7 mostra os resultados comparativos de acurácia dos modelos utilizados pelos trabalhos presentes na literatura, assim como o número de canais de PSG utilizados, o modelo de aprendizagem de máquina e o número de pacientes analisados.

Tabela 7 — Métricas de desempenho calculadas para os modelos de *Multi-Class-SVM* e RF

Estudo	Canais Utilizados	N° de Pacientes	Método	Acurácia (%)					
				Total	W	REM	N1	N2	N3
Lajnef, 2015	EEG + EOG + EMG	15	D-SVM	92.4	92	82	67	80	87

Kim, 2020	EEG + EOG	145	CNN	91.1	96.1	81.2	71.5	75.4	95.8
Gunnars dottir et al., 2018	EEG + EMG + EOG	19	DT	80.7	86	75.7	43.2	77.9	91.8
Proposto	EEG	19	RF	82.2	91	83	24	86	81
Proposto	EEG	19	SVM	79.2	88	74	19	85	79

Fonte: elaborado pelo próprio autor.

É possível evidenciar que os resultados em termos de acurácia dos modelos propostos neste trabalho se comparam com os trabalhos presentes na literatura, mesmo com sinais dos canais de EEG sendo escolhidos, enquanto os trabalhos utilizados como referência utilizam no mínimo três canais.

Ainda levando em consideração os resultados, é possível observar em Gunnarsdottir et al. (2018) que a acurácia para o estágio N1 é baixa em relação aos outros estágios, assim como acontece no trabalho proposto. Isso se deve ao fato de que o número de *epochs* classificadas com o estágio N1 é relativamente mais baixa comparado ao número de *epochs* classificadas com os outros estágios, afetando o desempenho do modelo nesse estágio.

Em relação ao desempenho dos modelos, apenas o trabalho de Lajnef (2015) relaciona a curva de aprendizado do modelo com outros parâmetros, como o número de *features*. Em Lajnef (2015) há evidências que o modelo tende a aumentar sua acurácia em alguns casos quando o número de *features* é maior. No trabalho proposto, o modelo de *Random Forest* apesar de atingir acurácia comparável aos trabalhos de referência, sofre de *overfitting* possivelmente pelo fato de que as *features* escolhidas são redundantes ou insuficientes. Levando em consideração Kim (2020) e

Gunnarsdottir et al. (2018) em relação ao desempenho dos modelos em relação a *overfitting*, os autores não explicitam uma medida de desempenho que possa avaliar este fenômeno.

6 CONCLUSÃO

Neste trabalho foi proposto avaliar diferentes algoritmos de classificação automática de estágios do sono que por meio de sinais de polissonografia com o auxílio de técnicas de aprendizagem de máquina e processamento de sinais, tendo como motivação facilitar o diagnóstico de distúrbios do sono.

Como resultado deste trabalho, foram estudados os modelos de classificação *Random Forest* (RF) e *Multi-Class SVM*, sendo treinados por um conjunto de dados extraídos da base de dados pública disponibilizada pela *PhisioNet* e tratados utilizando diferentes abordagens, tendo como referência principal as diretrizes da AASM (Berry, 2015) e os trabalhos de Kim (2020), Gunnarssdottir (2018) e Lajnef (2015), e sendo possível ao final do processo estudar e comparar o desempenho dos modelos propostos com os modelos presentes na literatura.

Utilizando o modelo proposto, foi possível realizar experimentos com os dados disponibilizados pela base de dados pública e uma análise comparativa dos modelos RF e *Multi-Class SVM* utilizando os hiper parâmetros principais dos dois modelos, escolhidos e ajustados com auxílio da função *GridSearch*, que executa uma busca exaustiva de melhores parâmetros dentro de uma faixa escolhida.

Após o ajuste, foi observado que a acurácia dos modelos RF e *Multi-Class SVM* atingem valores comparáveis aos valores presentes na literatura com a utilização de outros modelos como *Dendro-Support Vector Machine* (DSVM) (Lajnef, 2015), *Convolutional Neural Network* (CNN) (Kim, 2020) e *Decision Tree* (DT) (Gunnarsdottir et al., 2018), e utilizando apenas dois canais de EEG como sinal de entrada, enquanto os trabalhos da literatura utilizam três ou mais canais. Além disso, é importante ressaltar que mesmo que a acurácia obtida nos modelos do trabalho proposto seja comparável a acurácia da literatura, o modelo de *Random Forest* do presente trabalho apresentou sobreajuste aos dados apresentados, o que significa que a sua boa acurácia, quando apresentado a dados desconhecidos, não é garantida, e uma forma de resolver este problema é reavaliar a escolha de *features* para o treinamento do modelo. Por fim, vale a pena citar que os trabalhos de Kim (2020) e Lajnef (2015) não explicitam métricas de desempenho do modelo para avaliar *overfitting*.

De toda forma, os resultados obtidos com o presente trabalho sinalizam que este poderá auxiliar no estudo de aplicações de algoritmos de aprendizagem de

máquina para a classificação de estágios do sono.

6.1 Trabalhos futuros

Nesta seção são apresentadas algumas possibilidades para continuidade e melhoria do trabalho proposto.

6.1.1 Utilização de mais dados de entrada

Foram utilizados 19 pacientes para a realização do estudo no presente trabalho. Entretanto, é possível ver pela curva de aprendizagem dos modelos que quanto maior o tamanho do conjunto de dados de treinamento, maior também é a precisão do modelo. Desta forma, seria possível melhorar o desempenho dos modelos propostos com o aumento do conjunto de dados de treinamento.

6.1.2 Estudar a seleção de *features* para o modelo de RF

No trabalho proposto foi utilizado o valor de densidade espectral de potência das frequências associadas aos estágios do sono N1, N2, N3, *Rapid Eye Movement* (REM) e *Wake* (W) proveniente dos sinais de dois canais de EEG. Essa escolha de *features* gerou um *overfitting* no modelo de RF, fazendo com que sua acurácia quando apresentado a dados desconhecidos não seja garantida. Para corrigir isso, é proposto para um trabalho futuro que seja feito um estudo de seleção de *features* que melhorem a curva de aprendizagem do modelo de RF, e que sua acurácia seja garantida para dados desconhecidos.

REFERÊNCIAS

- ABOALAYON, Khald Ali I; FAEZIPOUR, Miad; ALMUHAMMADI, Wafaa S; MOSLEHPOUR, Saeid. Sleep Stage Classification Using EEG Signal Analysis: A Comprehensive Survey and New Investigation. **Entropy**, [S.], 1-31, 2016.
- ALPAYDIN, E. **Introduction to Machine Learning**. [S.]: MIT press, 2020.
- AMEERA, Anis; SAIDATUL, A.; IBRAHIM, Z. Analysis of EEG Spectrum Bands Using Power Spectral Density for Pleasure and Displeasure State. IOP Conference Series: Materials Science and Engineering, v. 557, p. 012030, 2019. Disponível em: <https://iopscience.iop.org/article/10.1088/1757-899X/557/1/012030>. Acesso em: 21 abr. 2023.
- BANDT, Christoph; POMPE, Bernd. Permutation entropy: a natural complexity measure for time series. **Physical review letters**, [S.], v. 88, n. 17, p. 17-29, 2002. Disponível em: <https://journals.aps.org/prl/abstract/10.1103/PhysRevLett.88.174102>. Acesso em: 16 abr. 2023.
- BENEDITO-SILVA, Ana; GONÇALVES, Bruno; VARTANIAN, Daniel; SANTOS, Eduardo; MIGUEL, Mario. **Especificações técnicas e recomendações sobre o uso da actigrafia**. [S.]: 2021.
- BERRY, R. B.; BROOKS, R.; GAMALDO, C. E.; HARDING, S. M.; MARCUS, C.; VAUGHN, B. V. The AASM manual for the scoring of sleep and associated events. **Rules, Terminology and Technical Specifications**, Darien, 176, 2012.
- CHAMBON, S., Galtier, M. N., Arnal, P. J., Wainrib, G., & Gramfort, A. A Deep Learning Architecture for Temporal Sleep Stage Classification Using Multivariate and Multimodal Time Series. **IEEE**, v.26, n.4, p. 758–769, 2018.
- CHATTU, V. K. *et al.* The Global Problem of Insufficient Sleep and Its Serious Public Health Implications. **Healthcare**, Basel, s.p, 2018. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6473877/>. Acesso em: 16 maio 2022.
- CHEN, Shanshan; PERERA, Robert; ENGELHARD, Matthew M.; LUNSFORD-AVERY, Jessica R.; KOLLINS, Scott H.; FUEMMELER, Bernard F. A Generic Algorithm for Sleep-Wake Cycle Detection using Unlabeled Actigraphy Data. **IEEE**, Chicago, s.p, 2019.
- CHO *et al.* Development of an Automated Wireless Tension Force Estimation System for Cable-stayed Bridges. **Journal of Intelligent Material Systems and Structures**, 21, p.361-376, 2010.
- EL-MANZALAWY, Yasser; BUXTON, Orfeu; HONAVAR, Vasant. Sleep/wake state prediction and sleep parameter estimation using unsupervised classification via clustering. **IEEE**, Kansas, p.718-723, 2017.
- ENDEE, Lisa M; SPRINGS, William H. 2021. **Sprigg's Essentials of Polysomnography: A Training Guide and Reference for Sleep Technicians**.

Burlington: Jones & Bartlett Learning, [s.d].

ENUS. **Análise de Vibração**: Tipos de Sinais, Transformada de Fourier e PSD. Disponível em: <https://ensus.com.br/analise-de-vibracao-tipos-de-sinais-transformada-de-fourier-e-psd/>. Acesso em: 12 abr. 2023.

GUNNARSDOTTIR, Kristin M.; GAMALDO, Charlene E.; SALAS, Rachel M. E.; EWEN, Joshua B.; ALLEN, Richard P.; SARMA, Sridevi V. A Novel Sleep Stage Scoring System: Combining Expert-Based Rules with a Decision Tree Classifier. **IEEE**, Honolulu, p.3240-3243, 2018.

HANAOKA, Masaaki; ASHI, Masaki Kobay; YAMAZAKI, Haruaki. Automated sleep stage scoring by decision tree learning. **Yamanashi University**, Takeda, p.1751-1754, 2001.

HASSAN, A.R.; BHUIYAN, M.I.H. Computer-aided sleep staging using complete ensemble empirical mode decomposition with adaptive noise and bootstrap aggregating. **Biomed Signal Process. Control**, [S.l.], 1–10, 2016.

HASSAN, A. R; BHUIYAN, Bashar; BHUIYAN, M I. H. On the classification of sleep states by means of statistical and spectral features from single channel Electroencephalogram. **IEEE**, [S.l.], p.2238-2243, 2015.

HIRSHKOWITZ, Max *et al.* National Sleep Foundation's sleep time duration recommendations: methodology and results summary. **Sleep health**, v. 1, n. 1, p. 40-43, 2015.

<https://www.sciencedirect.com/science/article/abs/pii/S2352721815000157>
HSU, Y.-L.; YANG, Y.-T.; WANG, J.-S.; HSU, C.-Y. Automatic sleep stage recurrent neural classifier using energy features of EEG signals. **Neurocomputing**, 104, p.105–114, 2013.

IMTIAZ, Syed Anas; RODRIGUEZ-VILLEGAS, Esther. An Open-source Toolbox For Standardized Use Of PhysioNet Sleep EDF Expanded Database. **IEEE**, Milan, p.6014-6017, 2015.

JIGO, B. T.; ABDULAZEEZ, A. M. Classification based on decision tree algorithm for machine learning. **Evaluation**, v.6, n.7, s.p, 2021.

KIM, Hyeong-Jin; LEE, Minji; LEE, Seong-Whan. End-to-end automatic sleep stage classification using spectral-temporal sleep features. **IEEE**, Montreal, p.3452-3455, 2020.

KEMP, Bastiann; ZWINDERMAN, Aeiko (koos) H.; TUK, Bert; KAMPHUISEN, Hilbert A. C.; OBERÝE, Josefien J. L. (Janine). Analysis of a Sleep-Dependent Neuronal Feedback Loop: The Slow-Wave Microcontinuity of the EEG. **IEEE**, [S.l.], v.47, n.9, 1185-1194, 2000.

LAJNEF, Tarek; CHAIBI, Sahbi; RUBY, Perrine; AGUERA, Pierre-Emmanuel;

EICHENLAUD, Jean-Baptiste; SAMET, Mounir; KACHOURI, Abdennaceur; JERBI, Karim. Learning machines and sleeping brains: Automatic sleep stage classification using decision-tree multi-class support vector machines. **Journal of Neuroscience Methods**, p.94-105, 2015.

LAN, Kun-Chan; CHANG, Da-Wei; KUO, Chih-En; WEI, Ming-Zhi; LI, Yu-Hung; SHAW, Fu-Zen; LIANG, Sheng-Fu. Using off-the-shelf lossy compression for wireless home sleep staging. **Journal of Neuroscience Methods**, [S.], v. 246, p.142-152, 2015.

LAUTESLAGER, Timo; KAMPAKIS, Stylianos; WILLIAMS, Adrian J; SIDDIQUI, Fares; MASLIK, Michal. Performance Evaluation of the Circadia Contactless Breathing Monitor and Sleep Analysis Algorithm for Sleep Stage Classification. **IEEE**, Montreal, p. 5150-5153, 2020. Disponível em: <https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=9175419>. Acesso em: 6 jul. 2023.

LIANG, Sheng-Fu; KUO, Chin-En; HU, Yu-Han; CHENG, Yu-Shian. A rule-based automatic sleep staging method. **Journal of Neuroscience Methods**, Taiwan, p.169-176, 2012.

LIU, Y.; BI, J.-W.; FAN, Z.-P. A method for multi-class sentiment classification based on an improved one-vs-one (OVO) strategy and the support vector machine (SVM) algorithm. **Information Sciences**, p.38–52, 2017.

MARTIN, J. L.; HAKIM, A. D. Wrist Actigraphy. **Chest**, v.139, n.6, p.1514–1527, 2011.

MILLERS, Scott; CHILDERS, Donald. Probability and random processes. **Academic Press**, [S.], p.370–5, 2012.

OPPENHEIM, A. V.; WILLISKY, A. S. **Sinais e Sistemas**. São Paulo: Pearson Education, 2008.

PEDREGOSA *et al.* Scikit-learn: Machine Learning in Python. **JMLR**, [S.], 12, p. 2825-2830, 2011.

PENZEL, Thomas. **Cardiovascular and respiratory dynamics during normal and pathological sleep**. [S.]: Journal article, 2007.

RAY, S. A quick review of machine learning algorithms. **IEEE**, [S.], p. 35–39, 2019. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8862451/>. Acesso em: 21 abr. 2023.

RAZA, Halder; CHOWDHURY, Anirban; BHATTACHARYYA, Saugat. Deep Learning based Prediction of EEG Motor Imagery of Stroke Patients' for Neuro-Rehabilitation Application. **IEEE**, Glasgow, s.p, 2020.

ROHAN, Remalli; KUMARI, L. V. Rajani. Classification of Sleep Apneas using

Decision Tree Classifier. **IEEE**, Madurai, p.1310-1316, 2021.

RUNDO, J. V.; DOWNEY, R. Polysomnography. **Handbook of Clinical Neurology**, [S.], p. 381–392, 2019.

SAINI, K. M. **What is Power Spectral Density**. 2022. Disponível em: <https://www.tutorialspoint.com/what-is-power-spectral-density#>. Acesso em: 19 abr. 2023.

SHEYKHMOUSA, M. *et al.* Support Vector Machine vs. Random Forest for Remote Sensing Image Classification: A Meta-analysis and systematic review. **IEEE**, s.p, 2020.

SPRIGGS, William. **Essentials of polysomnography**. [S.]: Jones & Bartlett Publishers, 2009. Disponível em: https://scholar.google.com/scholar?hl=pt-BR&as_sdt=0%2C5&q=essentials+of+polysomnography+spriggs+2009&btnG=. Acesso em: 19 abr. 2023.

STOICA, P.; MOSES, R. L. **Spectral analysis of signals**. Upper Saddle River: Pearson Prentice Hall, 2005, p.25-26.

SU, Xiaogang; YAN, Xin; TSAI, Chih-Ling. Linear regression. *Wiley Interdisciplinary Reviews: Computational Statistics*, v. 4, n. 3, p. 275–294, 2012. Disponível em: <https://wires.onlinelibrary.wiley.com/doi/abs/10.1002/wics.1198>. Acesso em: 21 abr. 2023.

SUPRATAK, Akara *et al.* DeepSleepNet: A model for automatic sleep stage scoring based on raw single-channel EEG. *IEEE*, [S.], v. 25, n. 11, p. 1998-2008, 2017. Disponível em: <https://ieeexplore.ieee.org/abstract/document/7961240>. Acesso em: 16 abr. 2023.

WANG, Z.; XUE, X. Multi-Class Support Vector Machine. **Support Vector Machines Applications**, [S.], p.23–48, 2014.

ZHOU, Z. H. Machine learning. **Springer Nature**, [S.], s.p, 2021.