



UNIVERSIDADE DE BRASÍLIA – UNB
CAMPUS GAMA – FGA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA BIOMÉDICA

CARACTERIZAÇÃO DE PADRÕES DE ELETROENCEFALOGRAFIA COM USO DE APRENDIZADO DE MÁQUINA NA IDENTIFICAÇÃO DE PATOLOGIAS ASSOCIADAS AO SONO

ALLAN PAULO DE SOUZA

ORIENTADOR: CRISTIANO JACQUES MIOSSO



UNIVERSIDADE DE BRASÍLIA – UNB

FACULDADE UNB GAMA – FGA



**CARACTERIZAÇÃO DE PADRÕES DE ELETROENCEFALOGRAFIA COM USO DE APRENDIZADO DE
MÁQUINA NA IDENTIFICAÇÃO DE PATOLOGIAS ASSOCIADAS AO SONO**

ALLAN PAULO DE SOUZA

ORIENTADOR: **CRISTIANO JACQUES MIOSSO**

DISSERTAÇÃO DE MESTRADO EM
ENGENHARIA BIOMÉDICA

PUBLICAÇÃO: 176A/2023

BRASÍLIA/DF, SETEMBRO DE 2023

UNIVERSIDADE DE BRASÍLIA - UNB
FACULDADE UNB GAMA - FGA
PROGRAMA DE PÓS-GRADUAÇÃO

**CARACTERIZAÇÃO DE PADRÕES DE ELETROENCEFALOGRAFIA COM USO DE APRENDIZADO DE
MÁQUINA NA IDENTIFICAÇÃO DE PATOLOGIAS ASSOCIADAS AO SONO**

ALLAN PAULO DE SOUZA

DISSERTAÇÃO DE MESTRADO SUBMETIDA AO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA BIOMÉDICA
DA UNIVERSIDADE DE BRASÍLIA, COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE
EM ENGENHARIA BIOMÉDICA

DISSERTAÇÃO APROVADA POR:

DR. CRISTIANO JACQUES MIOSSO
(ORIENTADOR)

DR. LUCIANO MANHÃES DE ANDRADE FILHO
(EXAMINADOR EXTERNO)

DR. NILTON CORREIA DA SILVA (EXAMINADOR
INTERNO)

BRASÍLIA/DF, SETEMBRO DE 2023

FICHA CATALOGRÁFICA

DE SOUZA, ALLAN

Caracterização de Padrões de Eletroencefalografia com uso de Aprendizado de Máquina na Identificação de Patologias Associadas ao Sono.

[Distrito Federal], 2023.

User Field page_minus_preamble = 77p., 210 x 297 mm (FGA/UnB Gama, Mestrado em Engenharia Biomédica, 2023).

Dissertação de Mestrado em Engenharia Biomédica, Faculdade UnB Gama, Programa de Pós-Graduação em Engenharia Biomédica.

1. Processamento de sinais
2. Eletroencefalograma (EEG)
3. Sono
4. Aprendizado de Máquina

REFERÊNCIA

de Souza, Allan (2023). Caracterização de Padrões de Eletroencefalografia com uso de Aprendizado de Máquina na Identificação de Patologias Associadas ao Sono. Dissertação de mestrado em Engenharia Biomédica, Publicação 176A/2023, Programa de Pós-Graduação, Faculdade UnB Gama, Universidade de Brasília, Brasília, DF, 77p.

CESSÃO DE DIREITOS

Autor: Allan Paulo de Souza

Título: Caracterização de Padrões de Eletroencefalografia com uso de Aprendizado de Máquina na Identificação de Patologias Associadas ao Sono

Grau: Mestre

Ano: 2023

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender essas cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta dissertação de mestrado pode ser reproduzida sem a autorização por escrito do autor.

allanpaulo2@hotmail.com

Brasília, DF – Brasil

RESUMO

O sono consiste de uma série de etapas fundamentais para a qualidade de vida em várias espécies. Sua importância é comparável à alimentação e à prática de atividades físicas. No entanto, seu entendimento ainda tem lacunas que precisam ser estudadas.

Nesse sentido, duas tecnologias podem contribuir, em particular, para o entendimento do sono. A primeira diz respeito ao eletroencefalograma (EEG), que tem relevância em diversos estudos da neurociência, inclusive para o sono. A outra tecnologia é a do aprendizado de máquina, que vem ganhando espaço como ferramenta para identificação de padrões que auxiliam no diagnóstico; mas ainda há poucos trabalhos que utilizam essas técnicas na identificação de patologias associadas ao sono.

Diante disso, esse trabalho se propõe a comparar diferentes abordagens de aprendizado de máquina a partir de dados de EEG com a finalidade de automatizar análises para auxílio em diagnósticos de patologias associadas ao sono. Para isso, foram comparadas a utilização de máquinas de vetor de suporte (SVM) e florestas aleatórias (Random Forest) com diferentes hiperparâmetros a partir de características obtidas por meio de cálculo de energias em bandas de frequência dos sinais.

Nos experimentos com SVM, foram testadas abordagens com variação de kernels; com Random Forests, profundidade máxima. Adicionalmente, esses resultados foram comparados com os obtidos com uso de redes neurais convolucionais (CNN), definindo características dinamicamente por meio das camadas dessa rede. Nestas arquiteturas de CNN, foram utilizadas distintas camadas convolucionais e densas com alteração de hiperparâmetros.

Para a realização desse trabalho, foram utilizados dados de polissonografia disponíveis no portal Physionet. A partir desses dados brutos, houve seleção de característica e, com exceção dos experimentos que utilizaram CNN, extração de características utilizando transformada de Fourier, selecionando distintas derivações (eletrodos).

No estudo piloto, foram implementados algoritmos para detectar o sinal de EEG de epilepsia noturna do lobo frontal. Os resultados obtidos com SVM e Random Forest sugerem que esses classificadores podem identificar padrões relevantes a partir de sinais de EEG: a maior acurácia (média de 5 folds) foi de 60% em ambas as abordagens. Além disso, as comparações do trabalho

com essas abordagens mostraram que a distribuição espacial da informação é homogênea. Por outro lado, não foi possível distinguir os sinais de EEG de participantes com epilepsia, ainda que utilizando-se diferentes arquiteturas, variando-se quantidade de camadas, funções de ativação, quantidade de neurônios e dropout.

Em seguida, foram implementados novos experimentos utilizando os resultados dos estudos preliminares como direcionamento. Para isso, novos classificadores foram treinados com dados que passaram por outras etapas de preparação a partir de janelamento do sinal e filtro dos sinais. Com isso, houve melhoria nas métricas de desempenho dos classificadores.

Palavras-chave: Eletroencefalograma; Sono; Aprendizado de Máquina; Máquinas de Vetor de Suporte; Florestas Aleatórias; Processamento de Sinais.

ABSTRACT

Sleep consists of a series of fundamental stages for the quality of life in several species. Its importance is comparable to food and physical activity. However, their understanding still has gaps that need to be studied.

In this sense, two technologies can contribute, in particular, to the understanding of sleep. The first concerns the electroencephalogram (EEG), which is relevant in several neuroscience studies, including sleep. The other technology is machine learning, which has been gaining ground as a tool for identifying patterns that aid in diagnosis; but there are still few works that use these techniques to identify pathologies associated with sleep.

Therefore, this work proposes to compare different machine learning approaches from EEG data in order to automate analyzes to aid in the diagnosis of sleep-associated pathologies. For this, the use of support vector machines (SVM) and random forests (Random Forest) with different hyperparameters from characteristics obtained by calculating energies in signal frequency bands were compared.

In experiments with SVM, approaches with grain variation were tested; with Random Forests, maximum depth. Furthermore, these results were compared with those obtained using convolutional neural networks (CNN), defining characteristics dynamically through the layers of this network. In these CNN architectures, distinct convolutional and dense layers were used with changing hyperparameters.

To carry out this work, polysomnography data available on the Physionet portal was used. From these raw data, there was feature selection and, with the exception of experiments that used CNN, feature extraction using Fourier transform, selecting different derivations (electrodes).

In the pilot study, algorithms were implemented to classify the EEG signal of nocturnal frontal lobe epilepsy. The results obtained with SVM and Random Forest suggest that these classifiers can identify relevant patterns from EEG signals: the highest accuracy (mean of 5 folds) was 60% in both approaches. In addition, comparisons of the work with these approaches showed that the spatial distribution of information is spatially homogeneous. On the other hand, it was not possible to distinguish the EEG signals of participants with epilepsy, even using different architectures, varying the number of layers, activation functions, number of neurons and dropout.

Then, new experiments were implemented using the results of preliminary studies as a guideline. For this, new classifiers were trained with data that went through other stages of preparation from signal windowing and signal filtering. As a result, there was an improvement in the performance metrics of the classifiers.

Keywords: Electroencephalogram; Sleep; Machine Learning; Support Vector Machines; Random Forests; Signal Processing.

SUMÁRIO

1	INTRODUÇÃO.....	1
1.2	Objetivos.....	3
1.2.1	Objetivo Geral.....	3
1.2.2	Objetivos Específicos.....	3
2	FUNDAMENTAÇÃO TEÓRICA.....	5
2.1	Sono.....	5
2.2	Caracterização do Sistema Nervoso.....	7
2.3	Ondas Cerebrais e o EEG.....	8
2.4	Caracterização e Monitoramento de Estágios de Sono.....	11
2.5	Processamento e Classificação de Sinais.....	16
2.6	Aprendizado de Máquina.....	24
2.7	Classificadores.....	40
2.8	Patologias Associadas ao Sono.....	50
3	MATERIAIS E MÉTODOS.....	52
3.1	Descrição do Conjunto de Dados.....	52
3.2	Ingestão, Pré-processamento e Extração de Características.....	55
3.3	Implementação de Classificadores.....	59
4	RESULTADOS E DISCUSSÕES.....	64
5	CONCLUSÃO.....	70
	LISTA DE REFERÊNCIAS.....	71

LISTA DE TABELAS

Tabela 4.1. Comparação de acurácia de modelos utilizando SVM, com a derivação “F4-C4” e variando o kernel.....	65
Tabela 4.2. Comparação de acurácia de modelos utilizando RF, com a derivação “F4-C4” e variando a profundidade das árvores.....	65
Tabela 4.3. Arquiteturas e hiperparâmetros utilizados nos modelos de redes neurais convolucionais.	67

LISTA DE QUADROS

Quadro 2.1. Principais características das fases de sono e da vigília.....	12
Quadro 2.2. Trabalhos em aprendizado de máquina.....	25
Quadro 3.1. Descrição geral do conteúdo dos arquivos disponibilizados no conjunto de dados utilizado.....	53
Quadro 3.2. Mapeamento dos registros de polissonografia.....	54

LISTA DE FIGURAS

- Figura 2.1. Divisões anatômica e funcional do SN. Esse sistema pode ser dividido morfológicamente em SNC e SNP. Na perspectiva funcional, por outro lado, pode ser dividido em função sensitiva e função integradora. Além disso, ainda se divide o SNP em somático (SNS), autônomo (SNA) e entérico (SNE).....7
- Figura 2.2. Representação do modelo de regulação dos processos do sono. A figura mostra a Curva S e a Curva C - que também podem ser chamados de processos, respectivamente, S e C. A primeira curva representa o débito de sono associado aos eventos homeostáticos. A segunda, por sua vez, representa o ciclo circadiano. A intensidade do processo (eixo vertical) está em função do período do dia (eixo horizontal, em horas)..... 15
- Figura 2.3. Esquema do diagrama dos sistemas de comunicação. Nessa representação, há a mensagem é transmitida partindo de uma fonte de informação; o sinal recebido pelo receptor é composto pelo sinal inicial e, de uma forma geral, por um ruído. Por fim, uma mensagem resultante chega ao destino..... 17
- Figura 2.4. Representação de sinais de tempo contínuo (a) e de tempo discreto (b). No sinal de tempo contínuo (a), os valores assumidos pela variável de tempo são contínuos; no sinal de tempo discreto (b), por sua vez, há valores específicos inteiros que podem ser assumidos pela variável de tempo. O eixo vertical representa a amplitude do sinal em ambos os gráficos. O eixo horizontal representa o tempo: em (a), assume valores reais; em (b), apenas valores inteiros..... 18
- Figura 2.5 - Sobreposição das representações de um sinal de tempo contínuo e tempo discreto amostrado a partir do primeiro. Nesse sentido, o sinal de tempo discreto corresponde ao sinal de tempo contínuo para os valores definidos no tempo discreto .O eixo vertical representa a amplitude do sinal; o eixo horizontal representa o tempo..... 19
- Figura 2.6. Representação de um sistema de tempo discreto: a entrada é um sinal “ $x(n)$ ”; a saída, “ $y(n)$ ”. Esses dois sinais são de tempo discreto..... 20
- Figura 2.7. Esquema comparando as soluções a partir de um problema no espaço original e no espaço transformado. De uma forma geral, a justificativa para transformadas integrais é a simplificação da solução no espaço resultante dessa transformada. Assim, o problema é resolvido no espaço transformado e, em seguida, aplica-se a transformada inversa nessa solução para o espaço original do problema.....22
- Figura 2.8. Representação do fenômeno de aliasing. No primeiro caso, a frequência de amostragem atende ao critério de Nyquist. No segundo, no entanto, a frequência não atende e, por isso, ocorre perda de informação. Essa perda é representada pela sobreposição na imagem “d”..... 24

Figura 2.9 - Exemplo com um conjunto de dados para aprendizado supervisionado. Nessa ilustração, cada linha é um registro de uma pessoa; as primeiras colunas (idade e massa) representam as características (“features”), que são as informações sobre os dados a partir das quais, supostamente, será possível classificar um registro; a última coluna (grupo), por sua vez, é a indicação da classe à qual cada registro pertence.....	27
Figura 2.10. Representação de (a) um conjunto de dados sem rótulos em um gráfico com características dos dados em cada eixo e com (b) uma possível separação de classes a partir de um algoritmo de aprendizado não supervisionado.....	28
Figura 2.11. Visualização de um conjunto de dados utilizando t-SNE. Nesse exemplo, as classes são objetos agrupados em um mapa de características bidimensional: pontos mais próximos tendem a pertencer à mesma classe. Esse método permitiu representar graficamente dados com múltiplas características.....	28
Figura 2.12 - ilustração de um conjunto de dados parcialmente rotulado. Cada um dos três símbolos representam uma classe. O círculo com uma interrogação (em destaque), por sua vez, representa um registro cuja classe é desconhecida.....	29
Figura 2.13. Ilustração esquematizando aprendizado baseado em reforço. Se a escolha realizada pelo agente se refletir em um resultado esperado, há um aumento de pontuação a esse caminho: reforço positivo. No entanto, se a escolha se refletir em um resultado distinto, há uma perda de pontos: reforço negativo.....	30
Figura 2.14. Ilustração de aprendizado baseado em instância com métrica de similaridade baseada em menor distância. Nesse exemplo, cada símbolo no espaço de características representa uma classe conhecida. A classe do novo registro (em destaque), por outro lado, é desconhecida. Por se tratar de uma abordagem baseada em menor distância, esse novo registro será rotulado com a mesma classe à qual o losango azul pertence. Cada um dos eixos (vertical e horizontal) representam uma característica.....	32
Figura 2.15. Ilustração de aprendizado baseado em modelo. Nesse exemplo, cada símbolo no espaço de características representa uma classe conhecida. A reta tracejada, por sua vez, separa as classes - uma representação de modelo. Nesse sentido, um registro acima dessa reta é classificado como pertencente à mesma classe do losango azul. Caso contrário, pertence à outra classe. Diante disso, o novo registro (em destaque) pertence à mesma classe do losango azul. Cada um dos eixos (vertical e horizontal) representam uma característica.....	33
Figura 2.16. Ilustração de sobreajuste (<i>overfitting</i>) após treino de conjunto de dados. Cada classe está representada por um símbolo: losango e triângulo. A curva, por sua vez, representa o modelo. O sobreajuste é evidenciado pela tentativa excessiva de ajustar a curva aos dados de exemplos que, conseqüentemente, diminui o poder de generalização. Assim, a classificação de um novo registro (em destaque na imagem) com classe desconhecida será dificultada. Cada um dos eixos (vertical e horizontal) representam uma característica.....	36

Figura 2.17. Ilustração de sub-ajuste (underfitting) no modelo de classificação. Cada classe está representada por um símbolo: losango e triângulo. Há uma reta (representando o modelo) para a separação das classes “losango” e “triângulo”. O subajuste é evidenciado pela simplificação do modelo que é linear, enquanto que a distribuição dos registros não é linear. Dessa forma, o modelo não é robusto o suficiente para classificar adequadamente um novo registro, como é o caso do registro em destaque: sua classificação é hipoteticamente desconhecida; o modelo tenderia a não classificar corretamente. Cada um dos eixos (vertical e horizontal) representa uma característica..... 37

Figura 2.18. Representação de um fluxo de trabalho em aprendizado de máquinas para a separação do conjunto de dados brutos em dados de treinamento, de validação e de teste. Cada um desses tem finalidade específica: os “dados de treinamento” são utilizados para a identificação de padrões por meio do algoritmo de treinamento do modelo; os “dados de validação” são utilizados para verificar os resultados do modelo em elaboração para auxiliar na otimização dos resultados; os “dados de teste”, por sua vez, são, de uma forma geral, desconhecidos pelo modelo e, com isso, são utilizados para avaliar a capacidade de generalização do modelo criado.....38

Figura 2.19. Representação de uma matriz de confusão. Os valores reais são uma parte dos dados conhecidos separada para fazer essa avaliação; os valores preditos são os resultados da predição realizada pelos algoritmos preditivos a partir dos modelos treinados. Para a construção dessa matriz, ambos os conjuntos de valores são comparados a com a finalidade de avaliar o desempenho do modelo criado. O “verdadeiro” representa uma convergência entre os valores reais e preditos; o “falso”, por outro lado, representa uma divergência entre esses valores. Adicionalmente, o “positivo” representa a condição “positiva” (previamente estabelecida); analogamente, o “negativo” representa a condição “negativa”.....39

Figura 2.20. Ilustração de uma árvore de decisão em situação hipotética para condições favoráveis e desfavoráveis para a realização de um experimento. Nessa árvore, cada caixa representa um nó: uma condição de uma determinada variável que será avaliada. Há dois tipos de nós particulares: o superior, que é a raiz (por onde a árvore começa); os inferiores, que são chamados de folha e remetem à condição final (para uma tarefa de classificação, essa é a classe esperada para as condições do registro de entrada).....41

Figura 2.21. Ilustração de separação de classe com vetores de suporte. Em ambos os casos, há duas retas tracejadas que buscam uma região máxima a partir da reta contínua. No entanto, a segunda situação é um candidato mais otimizado por separar com maior distinção as classes representadas por círculo e triângulo.....44

Figura 2.22 - Mapa de características para um conjunto de dados com duas classes cuja separação tende a não ser linear. Nessa representação, há duas classes: uma tem seus cada registro identificado por um círculo; outra, por triângulos..... 44

Figura 3.1. Fluxograma com uma visão geral do fluxo de trabalho. Os retângulos azuis representam os artefatos; os paralelogramos em laranja, as tarefas realizadas. Esse fluxo se inicia com a ingestão e pré-processamento dos dados brutos para gerar os dados tratados; a partir da extração de características, é gerada uma matriz de características; são implementados modelos com suas

respectivas avaliações que geram resultados a serem avaliados por meio de métricas de desempenho; com isso, são apresentadas as conclusões do trabalho.....52

Figura 3.2. Fluxograma de atividades de ingestão e pré-processamento de dados. Os retângulos azuis representam os dados; os paralelogramos em laranja, as tarefas realizadas. Esse processo parte da cópia dos dados de PSG do servidor do PhysioNet para um computador de trabalho; é aplicada uma seleção dos dados de EEG e, em seguida, o resultado é salvo em “.parquet”; é aplicada a transformada de Fourier e, no domínio da frequência, são calculadas as energias em bandas; esses dados são salvos em arquivo “.csv” para análise futura.....55

Figura 3.3. Esquema com detalhes da ingestão de dados do servidor da PhysioNet para o ambiente local. Nesse processo, apenas os arquivos “.edf” são copiados para o ambiente local. Os arquivos “.txt” e “.csv” desse servidor não são utilizados nesse trabalho.....56

Figura 3.4. Representação da etapa de seleção de dados e de carga em “.parquet”. Apenas as informações sobre o EEG são utilizados; o EKG, EMG e os metadados, embora façam parte do conteúdo dos arquivos “.edf”, não são utilizados nesse trabalho. Foram utilizadas as bibliotecas “Pandas” e “MNE” para lidar com essa extração. Como resultado, foram gerados arquivos “.parquet” com registros dos potenciais para cada um dos arquivos “.edf” originais.....56

Figura 3.5. Representação da etapa de cálculo das bandas de energia. Nesse processo, foi utilizada a transformada de Fourier para fazer a transformação dos dados que estavam no domínio do tempo (quadro à esquerda) para o domínio da frequência (quadro à direita). Com isso foi gerado o espectrograma para cada derivação.....57

Figura 3.6. Representação do padrão internacional 10-20 de montagem de eletrodos de EEG em humanos. As partes A e B da figura apresentam diferentes perspectivas da mesma montagem; a parte C mostra uma versão estendida do modelo 10-20. Cada círculo representa um eletrodo com sua respectiva denominação no centro de cada círculo.....58

Figura 3.7. Visão geral das comparações de abordagens, algoritmos e arquiteturas utilizadas nos experimentos. São três domínios de comparação: utilizando-se processamento de sinais para extração de características ou com essa extração por parte do classificador. No primeiro caso, há comparação de eletrodos, além da comparação entre utilizar SVM e RF (cada um com vários experimentos comparando alguns hiperparâmetros). No segundo caso, são comparados os experimentos com CNN que se distinguem por seus hiperparâmetros.....60

Figura 3.8. Etapas dos experimentos propostos para o estudo piloto. De início, um eletrodo é escolhido arbitrariamente para a avaliação dos algoritmos no passo (1), no qual são comparadas algumas abordagens utilizando SVM (1.1) e RF (1.2). O algoritmo com o melhor resultado é utilizado na comparação entre diferentes eletrodos (2), não apenas aquele escolhido inicialmente. O eletrodo com o melhor resultado é utilizado na última etapa de avaliação de arquiteturas utilizando CNN..... 62

LISTA DE NOMENCLATURAS E ABREVIações

EEG	Eletroencefalograma
VP	Verdadeiro Positivo
VN	Verdadeiro Negativo
FP	Falso Positivo
FN	Falso Negativo
SN	Sistema Nervoso
SNC	Sistema Nervoso Central
SNP	Sistema Nervoso Periférico
SNS	Sistema Nervoso Somático
SNA	Sistema Nervoso Autônomo
SNE	Sistema Nervoso Entérico
OMS	Organização Mundial da Saúde

1 INTRODUÇÃO

O sono diz respeito a um conjunto de estados fisiológicos caracterizados por níveis sensoriais de redução de consciência e de sonhos [54, 56]. Ainda não se sabe tudo a respeito do sono, mas evidências sugerem que o sono é fundamental para os animais [3, 5, 54, 57]. Nesse sentido, algumas complicações associadas ao sono são conhecidas e precisam ser mais estudadas.

Os diagnósticos dessas patologias são, no geral, realizados a partir da análise de um profissional com base em interações com o paciente e em resultados de exames [68]. Isso pode ocorrer por diagnóstico anatômico, funcional, sindrômico, clínico e etiológico [68]. Embora esses diagnósticos sejam essencialmente uma competência médica, poderiam ser auxiliados por análises automatizadas por meio de algoritmos que alertam os profissionais de quadros prováveis [69, 76, 77]. Essa automação favorece resultados iniciais mais rápidos e precisos por meio de diagnósticos diferenciais gerados por ferramentas computacionais para auxiliar os profissionais [69, 76, 77]; além disso, potencializa a descoberta de marcadores que auxiliam no entendimento de processos biológicos a partir de dados [76].

A Organização Mundial de Saúde (OMS) defende um mínimo de 1 médico a cada 1.000 pessoas [70]. No entanto, regiões do Ásia e África têm uma proporção de apenas 1 médico para cada 100.000 [70]. Além disso, a OMS estima uma deficiência de quase 13 milhões de profissionais da saúde até 2035 [69].

As tecnologias para auxílio a triagem e a diagnóstico. Além disso, não substituem o atendimento dos profissionais. Ainda assim, o desenvolvimento de soluções de baixo custo e escaláveis disponibilizadas de forma integrada ou independente de outros sistemas de cuidados médicos podem otimizar os recursos utilizados para soluções para a saúde [69].

O eletroencefalograma (EEG) é um exame utilizado com frequência nessa análise de patologias associadas ao sono [25, 54, 57-59, 71-75] – podendo ser complementado por outros exames [54, 75]. O EEG permite registrar atividades elétricas no encéfalo de forma não invasiva (ainda que haja a forma invasiva), relativamente barata e com boa resolução temporal [54, 75]. Assim, favorece uma análise de variações de estados ao longo do tempo. A resolução espacial, no entanto, é inferior à de outros métodos – as imagens geradas por equipamentos de ressonância magnética, por exemplo, têm resolução superior, sendo, assim,

mais apropriadas em estudos para identificação de regiões lesionadas [78]. Outra complicação é a relação entre o sinal e o ruído: as atividades cerebrais ocorrem dentro da cabeça; os eletrodos dos exames não invasivos, realizados em humanos, estão na região externa [3, 5, 75]. Assim, como há material (incluindo osso) entre a região de atividades e a de coleta de sinais, estes precisam ser cuidadosamente tratados com a finalidade de melhorar a qualidade dos dados.

Diante dessas limitações, é importante estudar sobre aplicações de técnicas de processamento de sinais e tratamento de dados. A exemplo disso, o uso de representações transformadas, de decomposições de sinais [18] e de métodos de inteligência artificial [69] podem contribuir na otimização dos processos de análise de dados de exames de EEG [75].

De um lado, o aprendizado de máquina é um campo de estudos crescente e com resultados relevantes para várias áreas da saúde [38-42, 69, 76, 79-81]. Por outro lado, o estudo do sono apresenta oportunidades de estudos para identificação de padrões relacionados a diferentes estágios do sono e de patologias [54, 79]. A esse respeito, percebe-se que há trabalhos utilizando-se o aprendizado de máquina no estudo de sono cujos resultados mostram a viabilidade dessa aplicação nesse contexto utilizando-se SVM [80, 85, 86], Random Forests [80, 87] e redes neurais convolucionais [81-84]. No entanto, foram encontrados poucos trabalhos que sejam voltados para a aplicação de aprendizado de máquina para a análise de patologias associadas ao sono, tendo como ponto de partida os sinais de EEG. Nesse sentido, autores afirmam que os trabalhos nessa área são focados em identificação de fases do sono e que a identificação de patologias com esses recursos é uma oportunidade de estudo [79].

De forma complementar à abordagem de aprendizado de máquina, as técnicas de processamento digital de sinais são valiosas no estudo de sinais biológicos, como o EEG [88-91]. A transformada de Fourier, por exemplo, permite que seja feita a análise dos dados de um sinal no domínio da frequência [18, 32]. A partir disso, calculando-se a energia em bandas de frequência, é possível obter uma representação do sinal com redução de dimensionalidade e, conseqüentemente, menor consumo de recursos computacionais [6].

Assim, implementações de aprendizado de máquina podem potencializar os estudos desses sinais biológicos. Para um dado poder computacional, passa a ser possível treinar modelos com uma quantidade maior de dados do sinal original – pois estão em um espaço com menor dimensionalidade e, por isso, requerem menos poder computacional. Isso

viabiliza utilizar dados de EEG de polissonografia em janelas de tempo maior e com maior quantidade de participantes. Com isso, os experimentos tendem a ter melhor desempenho [92, 93].

Diante disso, esse trabalho se propõe a resolver as dificuldades de análise de dados de EEG coletados em humanos para identificação de patologias associadas ao sono. Para isso, foram implementadas rotinas de pré-processamento, extração de características e treinamento de modelos com diferentes arquiteturas de aprendizado de máquina e técnicas de processamento digital de sinais com a finalidade de otimizar a identificação de patologias associadas ao sono a partir de dados de EEG selecionados de exames de polissonografia.

1.2 OBJETIVOS

1.2.1 Objetivo Geral

Esse trabalho se propõe a comparar estratégias de classificação de patologias associadas ao sono a partir de sinais de EEG. São utilizadas características extraídas de sinais em diferentes bandas de frequência, usando classificadores com características tanto implícita, quando explicitamente definidas.

Para isso, faremos inicialmente análise em diferentes bandas com diferentes modelos (hiperparâmetros dos modelos em questão) e diferentes canais de EEG (uma região ou número de regiões podem ser mais ou menos importantes). Considerando a distribuição dos dados da base utilizada, os experimentos iniciais serão realizados por meio de classificadores binário implementados para a identificação de epilepsia noturna do lobo frontal – essa é a classe com maior quantidade de indivíduos com registros de polissonografia – dentre todos os dados.

1.2.2 Objetivos Específicos

Para que o objetivo geral seja atingido, serão realizadas as atividades abaixo:

- Análise das bases de dados de EEG com definição de quais sinais são rotulados como grupo controle e quais estão avaliados como associados a distúrbios associados ao sono
- Levantamento de todas as características de aquisição dos sinais, tais como: taxas de aquisição; eventual comprometimento do sinal em um ou mais canais

- Elaboração de um algoritmo para pre-processamento e tratamento dos sinais com base nas bandas de frequência associadas a EEG
- Elaboração de algoritmo para extração das características dos sinais para treinamento e posterior avaliação dos classificadores
- Comparação de diferentes modelos (SVM e Random Forest) identificados como oportunidades no levantamento bibliográfico para classificação aplicados às características extraídas do sinal de EEG
- Comparação de diferentes combinações de hiperparâmetros e arquiteturas propostas para classificação de sinais
- Levantamento dos desempenhos dos algoritmos de extração de características e de classificação na tarefa de detecção dos distúrbios estudados, em termos de métricas objetivas (precisão, acurácia, sensibilidade, especificidade e métrica f1).

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, serão apresentados os principais aspectos que embasam a pesquisa, destacando os conceitos essenciais para o entendimento dos métodos de análise propostos.

2.1 SONO

O sono é definido como a suspensão normal da consciência, quanto ao comportamento, e pela apresentação de ondas cerebrais específicas, quanto à eletrofisiologia. O sono ocorre em todos os mamíferos e, provavelmente, em todos os vertebrados [3, 54].

Devido à importância do sono, estudos têm sido realizados para melhor compreendê-lo. Os estudos associados ao sono ocorrem em diferentes escalas e perspectivas. São encontrados trabalhos sobre a neurobiologia do sono na perspectiva genética [96, 97], celular [96, 98, 99] e cognitiva [96, 99]. Adicionalmente, temas como processamento de sinais [88-91], análises de imagens [100, 101] e algoritmos de inteligência artificial [80, 81, 84-87], auxiliam no entendimento e potencializam as oportunidades nessa área. Quanto à captação de dados relacionados ao sono, tanto para finalidades relacionadas à pesquisa acadêmica quanto em aplicações clínicas diretas, há a possibilidade de utilização de eletroencefalograma (EEG) [88-91], eletrocardiograma (ECG) [102] e ressonância magnética (MRI) [100].

Em seres humanos, há dois estados comportamentais e fisiológicos durante o dia: podem estar acordados ou dormindo [54, 56]. Adicionalmente, o estado de sono é subdividido em níveis: o estado de vigília e o de sono [54, 56].

Outros animais também dormem. No entanto, a depender da espécie, são encontradas evidências de particularidades quanto às classificações dos níveis e da duração dos ciclos [3, 5]. Esse fato reforça a razoabilidade de um entendimento do sono como uma vantagem evolutiva. Alguns autores apontam que se trata de uma necessidade do corpo orquestrada pelo sistema nervoso, assim como é uma necessidade do sistema nervoso que está diretamente relacionada às condições dos outros sistemas [3, 5, 57].

A importância do sono é facilmente percebida por quem passou uma noite sem dormir; ou mesmo por aqueles que tiveram uma noite mal dormida [54, 94]. De fato, evidências apontam a qualidade do sono como sendo tão importante para a saúde quanto uma dieta

adequada ou a prática de atividades físicas [54]. A privação de sono pode, assim, alterar níveis de alerta, percepção, alerta, aprendizado e memória [3, 5, 94]; além disso, pode levar à formação de falsas memórias [95] e a disfunções metabólicas, cardiovasculares e imunológicas [97].

Ao adormecer, os animais ficam vulneráveis. Ainda assim, o sono é um comportamento altamente preservado em animais [3]. Por um lado, há evidências de que o sono é importante para animais; por outro, a razão pela qual dormem não é bem compreendida. [3, 5]

Do ponto de vista da conservação de energia, uma função do sono é a reposição dos estoques de glicogênio no encéfalo, os quais diminuem quando o animal está desperto. Outro fato é que à noite as temperaturas costumam ser mais baixas, o que ocasionaria maior gasto de energia para manter o organismo aquecido caso os animais não dormissem neste período. Além disso, uma hipótese acerca da vantagem do sono propõe que este é o período para informações serem consolidadas em formato de memória. [3]

Uma ampla variedade de animais apresenta ciclo diário de atividade-descanso (circadiano). Entretanto, a organização do sono depende da espécie. Como regra geral, animais predatórios têm longos e ininterruptos períodos de sono, que podem ser noturnos ou diurnos, dependendo do momento do dia no qual o animal se alimenta, acasala e lida com outras necessidades. Já os animais predados tendem a ter intervalos curtos de sono, pois precisam realizar vigilância contínua. Nestes casos, os animais dormem durante intervalos curtos que não duram além de poucos minutos. [3]

Há uma grande variedade de duração do sono entre diferentes espécies de animais. O elefante africano, por exemplo, dorme entre 3 a 4 horas por dia, enquanto que o tatu dorme 18 horas por dia. Mesmo entre humanos, a duração do sono pode variar, estando entre 5 e 10 horas por dia. A grande diferença no tempo de sono entre humanos sugere que pode existir uma justificativa genética que afeta o sono. [4]

Nos golfinhos nariz de garrafa, há um comportamento diferenciado. Esta espécie dorme com um hemisfério cerebral por vez: por volta de duas horas de sono não REM (rapid eye movement) em um hemisfério, depois uma hora com os dois hemisférios despertos, duas horas de sono não REM no outro hemisfério e assim sucessivamente, resultando em um total de doze horas por noite. Não há evidências que golfinhos tenham o sono REM. [3, 5]

Outro comportamento incomum está presente nos golfinhos cegos do Rio Indus no Paquistão. Esses golfinhos usam o sonar para nadar pelas correntes turvas e, durante a estação das monções, nunca podem parar de nadar. [5]

2.2 CARACTERIZAÇÃO DO SISTEMA NERVOSO

O sistema nervoso (SN) é responsável pela comunicação e integração de informações corporais. Sob a perspectiva da anatomia, pode ser dividido em dois componentes principais: o sistema nervoso central (SNC), também denominado “parte central do sistema nervoso”; e o sistema nervoso periférico (SNP), ou parte periférica do sistema nervoso [5, 47]. As divisões anatômicas e funcionais estão esquematizadas na figura 2.1; adicionalmente, serão explicadas e detalhadas nesse texto.

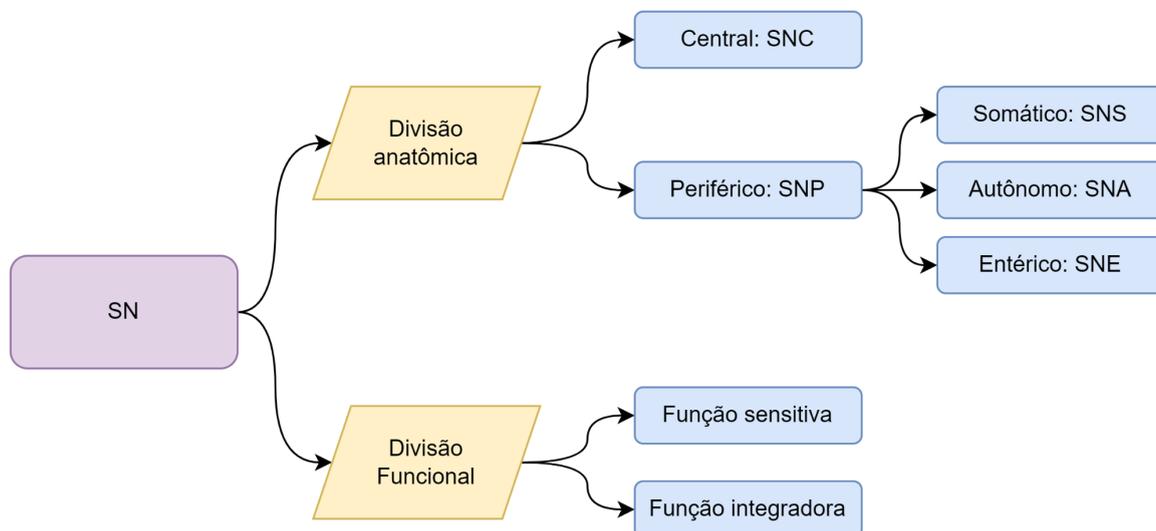


Figura 2.1. Divisões anatômica e funcional do SN. Esse sistema pode ser dividido morfológicamente em SNC e SNP. Na perspectiva funcional, por outro lado, pode ser dividido em função sensitiva e função integradora. Além disso, ainda se divide o SNP em somático (SNS), autônomo (SNA) e entérico (SNE).

O SNC, formado pelo encéfalo e medula espinal, é o principal responsável pelo processamento de diferentes informações sensitivas e motoras. Além disso, é a fonte de pensamentos e emoções. Sinais que liberam secreções também são originados no SNC [47]. Nesse contexto, é importante destacar que o SNC está relacionado diretamente com a regulação de vigília e ciclos do sono de forma direta [50, 53, 54] ou indireta, por exemplo,

interferindo em funções respiratórias [49] ou motoras [51, 52]. Esses aspectos serão discutidos em sessões futuras deste trabalho.

O SNP, por sua vez, é composto por nervos, gânglios, plexos entéricos e receptores sensitivos. Essa porção do SN é subdividida em Sistema Nervoso Somático (SNS), Sistema Nervoso Autônomo (SNA) e Sistema Nervoso Entérico (SNE) [47]. Os estudos de sono relacionam o SNP de forma indireta, com menos foco quando comparado ao SNC [50, 54].

O SN também pode ser dividido sob a perspectiva funcional. A função sensitiva detecta os estímulos internos; a função integradora processa e analisa as informações sensitivas; a função motora propaga uma resposta motora a partir de estímulos de nervos (cranianos e espinais) que, por sua vez, ativam músculos e glândulas [47]. Essas funções e, mais especificamente, aquelas associadas ao sono envolvem diversas estruturas do SNC (dentre as quais: tálamo; hipotálamo; córtex cerebral; tronco encefálico) e do SNP [53].

As células que compõem o tecido nervoso são muito especializadas e podem ser classificadas em neurônios e neuróglias. Embora haja aproximadamente o mesmo número de cada uma dessas células em um organismo, os neurônios são células que estão primariamente envolvidas na maioria das funções exclusivas do SN. Para isso, formam redes complexas de processamento no encéfalo e na medula espinal por meio de conexões entre si e com outras células. As células da glia, por sua vez, têm papel essencialmente de suporte aos neurônios, por meio de efeito isolante, de sustentação e de nutrição a estas células. [5, 47]

As informações são propagadas pelos neurônios por meio dos potenciais de ação (variações de potenciais de membrana ao longo da célula). Entre essas células, a comunicação ocorre nas sinapses, que podem ser elétricas - impulsos conduzidos diretamente entre as membranas das células adjacentes) - ou químicas - transmissão de informação por sinalizadores químicos [5, 47]. Esses sinalizadores são os neurotransmissores, que, a exemplo da serotonina e do GABA, podem ter papel importante na modularização (excitação ou inibição) de processos relacionados à regulação do sono. [54]

2.3 ONDAS CEREBRAIS E O EEG

A descoberta do EEG foi um dos principais avanços para potencializar as pesquisas sobre o sono [54]. Os estudos do psiquiatra Hans Berger [55], auxiliaram no entendimento de estado de consciência: classificação em momento “dormindo” ou “acordado” a partir de

atividades elétricas. Essa abordagem é uma das principais (em especial, no estudo de sono) por se tratar de um método que não é invasivo e que tem uma execução relativamente simples e acessível, quando comparado a exames de imagem [54].

Em alguns estudos em neurociências, é mais viável estudar neurônios isolados (experimentos que avaliam atividade da célula isoladamente). Em outros, optou-se por analisar o resultado coletivo de populações dessas células. Uma possibilidade dessa análise de populações é identificar as ondas cerebrais.

Neurônios são células excitáveis. Isso significa que os potenciais eletroquímicos nas proximidades de suas membranas, diferentemente da maioria das outras células, podem sofrer alterações significativas. Essas mudanças estão diretamente relacionadas à passagem de informação – por um neurônios que podem ser aferente (via sensitiva), eferente (via motora) ou de integração (responsável por integrar as vias).

Além dessa passagem de corrente pela membrana, é possível perceber alterações nas regiões das sinapses. No momento em que há atividade dos neurônios, é possível perceber acúmulo de cargas no exterior.

A detecção dessas atividades, em neurônios individuais, é possível; no entanto, geralmente ocorrem por procedimentos *in vitro* ou, quando *in vivo*, são invasivos. As atividades de populações de neurônio, no entanto, tendem a ser medidas por procedimentos menos invasivos.

O eletroencefalograma (EEG) é um meio para identificação dessas atividades elétricas. Trata-se de uma técnica para detecção de atividade elétrica a partir da superfície do crânio [5, 24]. Para isso, eletrodos são aplicados no couro cabeludo; o dado é captado e transmitido para equipamentos que farão o registro para análise futura (por uma análise gráfica ou não, por um humano ou algoritmo).

O potencial elétrico gerado por neurônios é resultante das atividades pós-sinápticas de neurônios corticais. Cabe ressaltar que, embora as atividades medidas sejam mais diretamente relacionadas às atividades mais superficiais do cérebro (córtex), indiretamente há uma análise secundária de reflexos de atividades de regiões subcorticais. Isso porque as estruturas subcorticais (incluindo o tálamo e o segmento superior do tronco encefálico), embora sejam regiões subcorticais, influenciam atividades de neurônios corticais [24].

As primeiras atividades elétricas em córtex cerebral foram relatadas em 1875 em um experimento com um macaco. Posteriormente, em 1929, o psiquiatra Hans Berger, da

Universidade de Jena, registrou atividades elétricas a partir de medidas em escalpo de humanos [3].

Dentre as justificativas para essa aplicabilidade e, conseqüentemente, popularidade do EEG, cabe destacar que se trata de um recurso: de simples aplicação [3]; não invasivo; com boa resolução temporal.

A avaliação de atividade elétrica por parte do EEG possibilita a avaliação funcional do sistema nervoso central. Normalmente, sua utilização ocorre como teste complementar a outros exames, como os de imagem, servindo como diagnóstico diferencial em casos que não são diretamente detectáveis pela perspectiva morfológica [23].

Embora tenha boa resolução temporal, o EEG tem baixa resolução espacial. Assim, o nível de detalhes espaciais são um fator limitante quanto à análise do EEG. Esse é um dos motivos que, em alguns casos, o EEG é utilizado de forma complementar a exames de imagens – estes, com boa resolução espacial. Ainda assim, a exemplo de análises de patologias associadas ao sono, é possível encontrar marcadores que sugerem diagnósticos.

Durante a coleta de dados de EEG, pode haver o registro de ruídos. São dados coletados pelo EEG que não são gerados pelo cérebro. Esses artefatos podem ser gerados a partir de condições do indivíduo ou do equipamento [25].

O equipamento pode estar danificado, por ter funcionamento inadequado dos eletrodos, amplificadores ou cabos [25]. Com isso, os dados coletados não representam adequadamente a realidade.

O ambiente pode contribuir com os ruídos. A exemplo disso, os eletrodos do EEG podem ter seus registros alterados por campos gerados por tomadas (pontos de energia) e equipamentos eletrônicos (computador, monitor, telefones, motor de movimento da cama e respiradores) que estejam próximos [25]. Essa situação pode ser evitada com um isolamento elétrico baseado em uma gaiola de Faraday: a coleta de dados é realizada dentro de uma região protegida por malhas de metais e que, com isso, terá eventuais campos elétricos externos atenuados.

Os ruídos no EEG também podem ter origem no próprio indivíduo que está passando pelo exame, em especial, devido a atividades musculares. Isso pode ocorrer como consequência de atividades respiratórias, movimentos (voluntários ou involuntários) do corpo, movimento dos olhos, movimento da língua, dentre outros.

O movimento dos olhos gera ruído devido a potenciais gerados em células musculares e nervosas, como outros movimentos. A particularidade desse movimento é que, como o globo ocular é um dipolo (a córnea é positiva; a retina, negativa), a mudança de direção dos olhos altera os potenciais elétricos captados pelos eletrodos do EEG [25]. Cabe ressaltar que há movimento dos olhos: voluntariamente (ao tentar olhar em outra direção); ao piscar os olhos; durante o sono (em especial, durante o sono REM, que será descrito em outra sessão).

Os modelos de equipamentos variam. Os parâmetros nessa comparação são a faixa de frequência de captação e a quantidade de canais para coleta de dados. A captação de informação ocorre por meio de eletrodos no escalpo. Esses recebem a resultante do sinal das atividades cerebrais.

Entre o local de captação do sinal (escalpo) e a região de produção (cérebro) há alguns materiais: as meninges; osso; pele. Com isso, o sinal não é perfeitamente captado, mas com ruídos devido às interações das ondas com esses materiais.

Por outro lado, o fato de os eletrodos estarem fora do corpo torna o procedimento não invasivo. Isso favorece o conforto do indivíduo e a simplicidade da coleta.

Uma alternativa ao EEG para coletar informações sobre ondas cerebrais é o magnetoencefalograma (MEG). Seu funcionamento está baseado na detecção de campos magnéticos decorrente das atividades cerebrais. O MEG pode ser um complemento ao EEG, considerando que tem maior resolução espacial e que consegue melhor captação de sinais gerados em regiões mais profundas. No entanto, a resolução temporal é inferior ao EEG, dificultando a detecção de padrões que são sensíveis ao tempo.

2.4 CARACTERIZAÇÃO E MONITORAMENTO DE ESTÁGIOS DE SONO

Indivíduos têm ciclos de sono que ocorrem, em condições normais, diariamente. Esse é o ciclo circadiano [48]. Experimentos mostram que, sem interferência de estímulos luminosos, os humanos têm ciclos de aproximadamente 26 horas; no entanto, com a alteração de luminosidade do dia, esse período passa a ser de 24h [54].

O ciclo circadiano é controlado por fatores endógenos e exógenos [54]. Um dos principais fatores endógenos ocorre no núcleo supraquiasmático (NSQ) [48], uma área do hipotálamo: estímulos luminosos a células fotossensíveis enviam sinalização ao NSQ e, a

partir disso, há uma sincronização de mecanismos genéticos e biomoleculares que interferem no ciclo circadiano [54].

O sono humano tem dois estágios: REM e NREM. De forma complementar a esses estágios, o indivíduo pode estar em vigília (estágio W, do inglês *wake*). A definição desses estágios é importante para a parametrização dos estudos e da prática científica. Nesse sentido, a American Academy of Sleep Medicine (AASM) tem publicações (a mais recente, em 2020) com padronizações de parâmetros para classificação desses estágios [56]. As principais características dessas etapas estão no quadro 2.1; além disso, são detalhadas em seguida.

As transições entre os estágios podem não ser bem definidas. No entanto, há um momento de transição que cabe destaque: o “período de latência de sono”, que será discutido em seguida. Esse período é um parâmetro relevante na identificação de quadros clínicos, como a insônia.

Quadro 2.1. Principais características das fases de sono e da vigília

Fase	Principais características do sinal	Outras observações	Tempo de sono
N1	Predomínio de frequências de 4 a 8 Hz	Período de latência do sono; transição entre vigília e sono; hipotonia muscular	10%
N2	50% de ondas com ritmo teta; ocorrência de complexo K e de fuso do sono	Sono mais profundo que o N1	50%
N3	Predomínio de frequências de 0,5 a 5 Hz; ondas de alta amplitude	Aumento da atividade cortical e talâmica; diminuição da temperatura corporal, da frequência cardíaca e pressão arterial	20%
REM	Frequência de 2 a 6 Hz	Atonia muscular	20%
Vigília atenta	Baixa amplitude; frequências maiores que 13 Hz (ondas beta)	Indivíduo acordado	(acordado)
Vigília relaxada	Frequências de 8 a 13 Hz (ondas alfa)	Início da sonolência; alguns movimentos aleatórios dos olhos	(acordado)

O sono NREM é um estágio de sono caracterizado pela hipotonia muscular e pode ser dividido em três fases: N1; N2; N3 [54, 56]. Os sinais coletados pelo EEG durante o NREM apresentam uma lentificação gradual [54, 56]. Ou seja, passa a haver predominância de ondas de menor frequência.

O primeiro estágio (N1) representa o sono normal e o período de transição entre o sono e a vigília [54, 57]. Normalmente ocorre de 5 a 20 minutos após o indivíduo se deitar (período de latência do sono). As ondas observadas são do tipo teta, com frequências entre 4 e 8 Hz [54].

Essa é uma etapa de sono mais leve. O aprofundamento desse sono leva ao segundo estágio NREM (N2) [54]. Neste estágio, 50% das ondas ainda são do tipo teta. Outras duas características marcantes são o aparecimento de ondas do complexo K e de fuso do sono [54, 56]. As ondas do Complexo K são trechos de onda com duração superior a 0,5s com amplitude máxima de 74 uV; enquanto que o fuso do sono são sinais elétricos com frequência de 11,5 a 14,5 Hz e duração de 0,5 a 1,5s [54].

O estágio N3 é caracterizado pelo predomínio de ondas com 0,5 a 5 Hz e alta amplitude - o que sinaliza redução nos processos de excitação encefálica e aumento na sincronização da atividade cortical e talâmica [57]. Ainda há hipotonia muscular, mas com diminuição da temperatura corporal, da frequência cardíaca e da pressão arterial [54]. Nesse estágio, também há maior atividade endócrina (liberação do hormônio do crescimento e da prolactina) e aumento da atividade parassimpática.

Após o estágio N3, o indivíduo ascende por todos os estágios e entra em um estágio REM. Esse estágio também é chamado de “sono paradoxal”, pois, embora o indivíduo esteja dormindo, os dados coletados pelo EEG são semelhantes ao estado de vigília. Ocorrem ondas chamadas “dente-de-serra” com frequência de 2 a 6 Hz. Nessa fase, há uma perda quase completa do tônus muscular (atonia muscular) [54, 57]. Os sonhos dessa fase podem ser mais vívidos - indivíduos relatam esse tipo de sonho 80 a 95% das vezes quando são acordados durante o sono REM [57].

O período com maior atividade detectada pelo EEG é o período de vigília, momento em que o indivíduo está acordado. Nesse estágio, as ondas têm baixa amplitude, dessincronização e frequências superiores a 8 Hz. Esse período pode ser dividido em “vigília

atenta” e em “vigília relaxada”. No primeiro, há baixa amplitude e frequências inferiores a 13 Hz (ondas beta); no segundo, as ondas têm frequências entre 8 e 13 Hz (ondas alfa). Além disso, é possível identificar a vigília relaxada por haver um início de sonolência e ocorrência de movimentos aleatórios nos olhos [54].

Existem diferentes modelos para a explicação dos mecanismos fisiológicos e comportamentais do sono. A exemplo disso, a regulação dos processos que levam o indivíduo a estar dormindo pode ser resumida utilizando o modelo proposto por Alexander A. Borbély [58]. Esse modelo hipotético define dois processos que ocorrem continuamente e em paralelo: o “processo S” e o “processo C”. Cada um desses com sua respectiva curva (“curva S” e “curva C”), que são representadas na figura 2.2.

O processo S está relacionado a eventos homeostáticos, pode ser interpretado como o débito ou a pressão de sono. Ou seja, quanto maior o tempo em que o indivíduo está acordado, maior o sono que sentirá. O acúmulo de adenosina no prosencéfalo basal (estrutura do SNC) é o principal fator relacionado a esse processo. [54, 55, 57]

O processo C, por sua vez, representa o ritmo circadiano endógeno. De uma forma geral, os seres humanos têm o ciclo vigília-sono em ciclos próximos a 24 horas, com tendência natural de dormir durante a noite (quando está escuro) e de permanecer acordado durante o dia [54, 55, 57]. As atividades que ocorrem no NSQ, decorrentes de estímulos luminosos, estão relacionadas a esse processo. Cabe destacar que pessoas cegas têm complicações no ciclo sono-vigília, havendo a necessidade, em alguns casos, de intervenções medicamentosas para auxiliar na regulação desse processo [54].

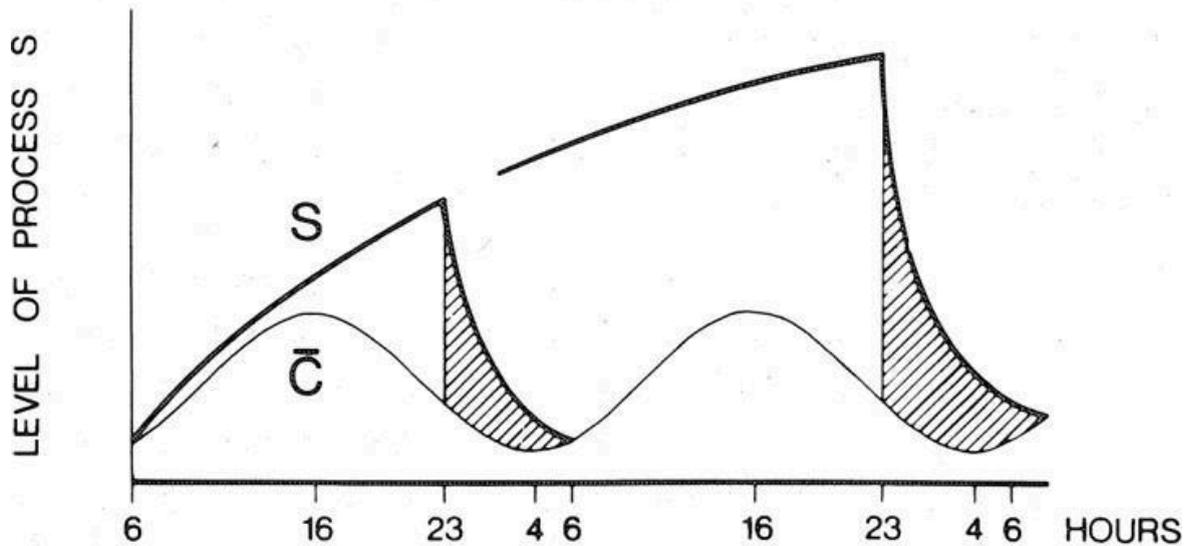


Figura 2.2. Representação do modelo de regulação dos processos do sono. A figura mostra a Curva S e a Curva C - que também podem ser chamados de processos, respectivamente, S e C. A primeira curva representa o débito de sono associado aos eventos homeostáticos. A segunda, por sua vez, representa o ciclo circadiano. A intensidade do processo (eixo vertical) está em função do período do dia (eixo horizontal, em horas). Figura adaptada de [58]

A objetividade dos estudos de sono é potencializada pelo uso de polissonografia (PSG). É considerado padrão-ouro na avaliação dos distúrbios de sono - como insônia, distúrbios respiratórios, apneias obstrutivas e síndromes de hipoventilação. Esse exame envolve a coleta e gravação de dados dos indivíduos durante o sono [1, 54, 59].

As padronizações da PSG são realizadas pelo manual da American Academy of Sleep Medicine (AASM). Essas definições de procedimentos, estágios do sono e marcação de eventos auxiliam na coerência dos diagnósticos, no tratamento e acompanhamento de pacientes e nas pesquisas [54].

Os procedimentos da PSG podem ocorrer em clínicas ou na residência do indivíduo de forma supervisionada ou não. São documentados 4 tipos de polissonografia que variam de acordo com o local, com a supervisão e com a quantidade de canais. O exame do tipo 1 é o mais completo: é uma polissonografia laboratorial supervisionada com monitoramento de EEG, EOG, EMG, fluxos aéreos nasal e oronasal, esforço respiratório torácico e abdominal, saturação periférica de oxigênio, posição corporal e gravação de imagem do paciente. Esse tipo serve de referência para a prática clínica e para a pesquisa: além de compreender mais variáveis fisiológicas, é supervisionado; assim, permite maior confiabilidade [54, 56].

O exame do tipo 2 ocorre na residência do indivíduo e não é supervisionado por um técnico. Sua montagem pode ocorrer no laboratório do sono ou no domicílio do indivíduo. O exame do tipo 3 é um monitoramento cardiorrespiratório com menor complexidade e maior facilidade de uso. No entanto, a ausência do EEG neste tipo dificulta o pareamento dos eventos do sono com os eventos respiratórios. Por fim, o exame tipo 4 registra fluxo aéreo e frequência cardíaca - por não ter o EEG, tem as limitações relatadas sobre o tipo 3. De uma forma geral, busca-se a solução mais conveniente, acessível e custo-efetiva. No entanto, em alguns grupos específicos, escolhe-se a opção mais segura e confiável: o exame tipo 1 [54, 56].

O EEG utilizado deve ter seus eletrodos preenchidos com pasta condutora, fixados com fita adesiva e posicionados no escalpo de acordo com o Sistema 10-20 de Colocação de Eletrodos. Além disso, a pele deve ser preparada antes de receber os eletrodos - para isso, pode-se utilizar gaze com álcool [54, 56].

Os eletrodos do EOG são colocados 1 cm acima e 1 cm lateral ao canto externo dos olhos. Isso favorece a identificação dos movimentos dos olhos (auxiliando na identificação do sono REM). Os eletrodos do EMG, por sua vez, são posicionados na linha média do queixo e 1 cm acima do osso da mandíbula, permitem a observação da diminuição do tônus muscular (característico do sono REM). Os eletrodos do ECG, no entanto, seguem a derivação D2 modificada: dois eletrodos sobre o tórax do indivíduo e outro na linha axilar externa esquerda na altura do 6º ou 7º espaço intercostal. Em todos esses casos, assim como no EEG, há preparo da serial que receberá os eletrodos [54, 56].

Além dos eletrodos, também são fixados sensores para registro de fluxo aéreo e, opcionalmente, de ronco. Isso pode ocorrer por meio de microfone, sensor pizoelétrico ou cânula de pressão nasal. Por fim, para registro da saturação periférica de oxigênio, deve-se usar oxímetro de pulso. Este, no entanto, tem alteração de qualidade perceptível de acordo com o posicionamento e com o tamanho do sensor [54, 56].

2.5 PROCESSAMENTO E CLASSIFICAÇÃO DE SINAIS

Os sinais são uma representação que podem descrever fenômenos físicos. Matematicamente, são expressos em funções de uma ou mais variáveis independentes [18]. Uma das principais bases para a estruturação dos conceitos e ferramentas a esse respeito é a

“Teoria Matemática da Comunicação” proposta por Shannon [28] em 1948. Em seu trabalho, é proposto um sistema para comunicação conforme o diagrama da figura 2.3.

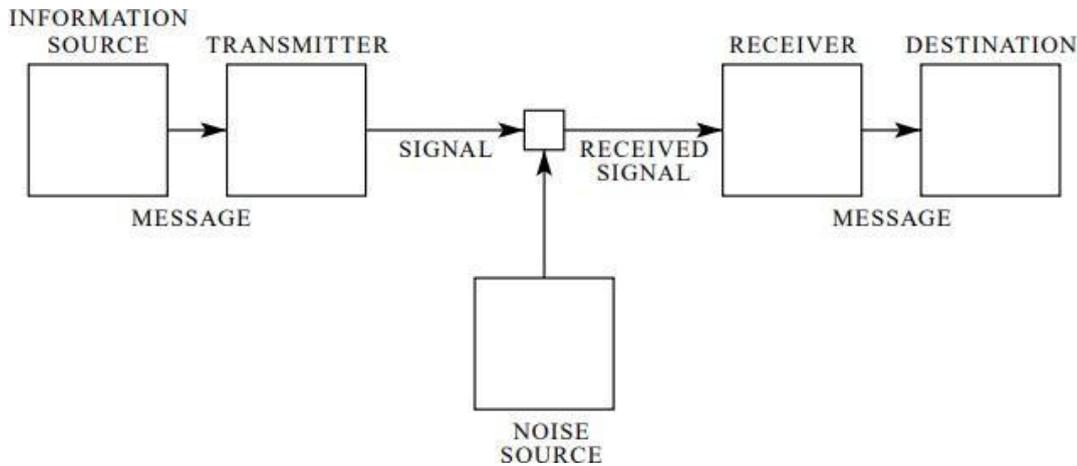


Figura 2.3. Esquema do diagrama dos sistemas de comunicação. Nessa representação, a mensagem é transmitida partindo de uma fonte de informação; o sinal recebido pelo receptor é composto pelo sinal inicial e, de uma forma geral, por um ruído. Por fim, uma mensagem resultante chega ao destino. Figura adaptada de [28]

Nessa proposta, a fonte de informação (“information source”) produz uma ou várias mensagens que serão transmitidas. Essas mensagens podem ser uma sequência de letras, uma função temporal, uma função de múltiplas variáveis, várias funções de uma ou múltiplas variáveis, conjuntos de pontos ou uma combinação desses [28]. A televisão é um exemplo em que há combinação de fontes: áudio e vídeo.

Um transmissor (“transmitter”) cria o sinal que será transmitido pelo canal (“channel”) [28]. A exemplo da telefonia: o transmissor gera sinais elétricos nos quais a corrente é proporcional às diferenças de pressões que são geradas pelo som. O canal pelo qual o sinal passa é o meio - que pode ser um cabo coaxial, uma banda de frequências de rádio ou um feixe de luz.

Durante a transmissão, idealmente, a mensagem é inalterada. No entanto, de uma forma geral, há ruído: uma perturbação no sinal produzido por uma fonte externa (“noise source”).

Os receptores (“receiver”), por sua vez, têm operação inversa ao transmissor. Reconstruem a mensagem a partir do sinal. Por fim, esse sinal chega ao destino (“destination”) - que pode ser uma pessoa ou uma máquina [28].

Quanto ao tempo, os sinais podem ser classificados em tempo discreto ou contínuo. Os sinais de tempo contínuo são aqueles em que a variável independente é contínua. Para os sinais de tempo discreto, por outro lado, a variável independente é amostrada apenas dentro de um conjunto discreto de valores [18].

A exemplo disso, um registro de temperatura de uma cidade a cada hora é um sinal de tempo contínuo. No entanto, a temperatura em si pode ser modelada por uma função em que o tempo (instante da coleta de temperatura) é uma variável contínua; nesse caso, o sinal é de tempo contínuo. Nesse exemplo, no qual as temperaturas no sinal de tempo discreto é um registro de parte das temperaturas, diz-se que foi realizada uma amostragem dos dados.

A Figura 2.4. é uma representação de um sinal de tempo contínuo (denotado por “ $X_c(t)$ ”) e outro de tempo discreto (denotado por “ $X[n]$ ”). Os valores deste são obtidos a partir da amostragem do primeiro sinal.

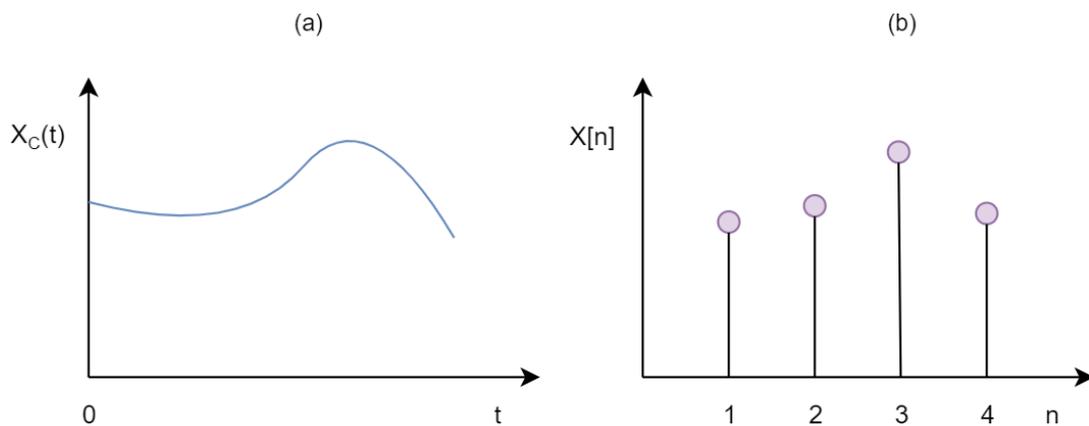


Figura 2.4. Representação de sinais de tempo contínuo (a) e de tempo discreto (b). No sinal de tempo contínuo (a), os valores assumidos pela variável de tempo são contínuos; no sinal de tempo discreto (b), por sua vez, há valores específicos inteiros que podem ser assumidos pela variável de tempo. O eixo vertical representa a amplitude do sinal em ambos os gráficos. O eixo horizontal representa o tempo: em (a), assume valores reais; em (b), apenas valores inteiros.

A sobreposição desses dois gráficos evidencia a amostragem descrita. A figura abaixo ilustra isso.

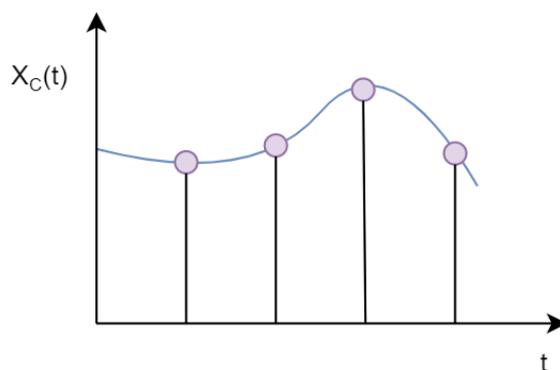


Figura 2.5 - Sobreposição das representações de um sinal de tempo contínuo e tempo discreto amostrado a partir do primeiro. Nesse sentido, o sinal de tempo discreto corresponde ao sinal de tempo contínuo para os valores definidos no tempo discreto. O eixo vertical representa a amplitude do sinal; o eixo horizontal representa o tempo.

Algebricamente, a expressão

$$x[n], n \in \mathbb{Z}$$

representa um sinal de um tempo discreto representado por uma sequência de números $x[n]$ para n inteiro [28]. Nessa representação, $x[n]$ corresponde à amplitude do sinal em cada n . Assim, se cada intervalo estiver igualmente espaçado por um tempo T , é possível relacionar um sinal de tempo discreto $x[n]$ a um sinal digital $x(t)$, em que $t = nT$. A relação entre esses sinais pode ser expressa pela equação

$$x[n] = x_a(nT), \quad n \in \mathbb{Z},$$

onde x_a é o sinal analógico correspondente a $x(t)$, n é um número inteiro e T é o intervalo de tempo entre as amostras.

Quando é necessário processar um sistema de tempo contínuo $x(t)$ usando-se um sistema no tempo discreto, é preciso fazer uma transformação nesse sinal chamada amostragem [28]. Esse sinal (inicialmente analógico, mas convertido em digital) pode ser reconstituído (para analógico) [28]. A esse respeito, o teorema da amostragem (que será discutido mais à frente) apresenta as condições para que essa reconstrução seja possível.

Um sistema no tempo discreto tem como entrada e saída sinais discretos. A figura 2.6 (abaixo) representa um sistema de tempo discreto para uma entrada $x[n]$ e uma saída $y[n]$, ambos sinais discretos.

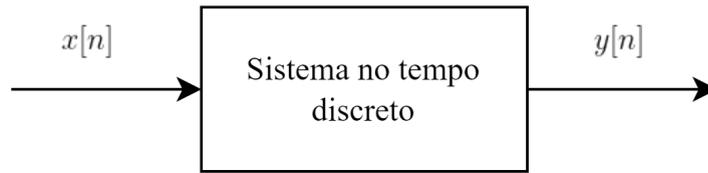


Figura 2.6. Representação de um sistema de tempo discreto: a entrada é um sinal “ $x[n]$ ”; a saída, “ $y[n]$ ”. Esses dois sinais são de tempo discreto. Figura adaptada de [18]

Analogamente a fenômenos físicos, pode-se calcular a energia de um sinal. Para um sinal de tempo discreto $x[n]$, a expressão

$$E(n_1, n_2) = \sum_{n=n_1}^{n_2} |x[n]|^2,$$

representa a energia $E(n_1, n_2)$ do sinal $x[n]$ entre os pontos $n = n_1$ e $n = n_2$.

São exemplos de sinais os áudios [18, 26, 28], fotografias [27], vídeos, dados sismográficos [28] e informações de exames (como EEG, ECG e tomografia) [18, 28]. Além disso, por uma extensão do conceito, podem ser consideradas sinais as informações de séries temporais com preços de ações do mercado financeiro.

O conjunto de análises, modificações e síntese desses sinais é chamado processamento de sinais. As técnicas relacionadas a esse processamento estão relacionadas a ferramentas matemáticas e computacionais que potencializam o uso das informações. Isso porque otimizam a transmissão, aumentam a eficiência do armazenamento e facilitam a detecção de componentes de interesse no sinal [18].

Há diferentes técnicas, a depender do contexto e do tipo de sinal. Pode envolver análise de frequência, modificações na escala de tempo, compressões, ampliações e remoção de ruídos [26, 27].

A depender do tipo dos sinais, há características e abordagens específicas. A imagem, por exemplo, tem pixels: pontos que podem ser representados em matrizes nas quais cada item indica a cor ou a intensidade. Os vídeos, por sua vez, são sequência de imagens. Em todos esses casos, há técnicas para otimizar o reconhecimento, tratamento e análise desses sinais durante o processamento.

Na Física Matemática, área de estudos responsável pela modelagem matemática de

fenômenos físicos, frequentemente encontra-se pares de funções relacionadas por expressão da forma [32]

$$g(a) = \int_{-\infty}^{\infty} f(t)K(a, t)dt$$

onde $g(a)$ é a transformada integral de $f(t)$ por um núcleo $K(a, t)$. Essa é uma relação entre dois espaços: t uma função; a para outra. Esse núcleo é uma função que determina como cada componente de frequência contribui para o sinal a ser transformado.

A Transformada de Fourier é um exemplo disso: relaciona o espaço de tempo com o espaço de frequência. Nesse sentido, a transformada de Fourier de um sinal f é dada por

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

onde $\mathcal{F}f(t)$ é a transformada de Fourier para toda frequência angular e sendo i a unidade imaginária.

As transformadas têm várias interpretações e aplicações. A transformada de Fourier é uma técnica importante em processamento de sinais. Permite fazer a transformação do sinal a partir do domínio do tempo para o domínio da frequência. É aplicável em diversos contextos, como música, gravação de voz, análise de imagens e análise de dados biológicos. Por meio da transformada de Fourier, é possível que um sinal seja expresso como a combinação de ondas com frequências bem estabelecidas.

De uma forma geral, essas operações da transformada de Fourier viabilizam a solução de problemas no espaço dual. Nesses casos, a solução do problema no espaço original pode ser mais complicada ou inviável; por outro lado, a solução no espaço da transformada pode ser viável ou mais simples.

Assim, a partir de uma transformada, o problema passa do espaço original para o espaço transformado, onde a solução será encontrada; em seguida, de uma forma geral, é possível retornar ao espaço original por meio de uma transformada inversa (embora, em alguns casos, este último passo seja desnecessário). Esse procedimento pode ser repetido. A figura 2.7 sistematiza esses passos.

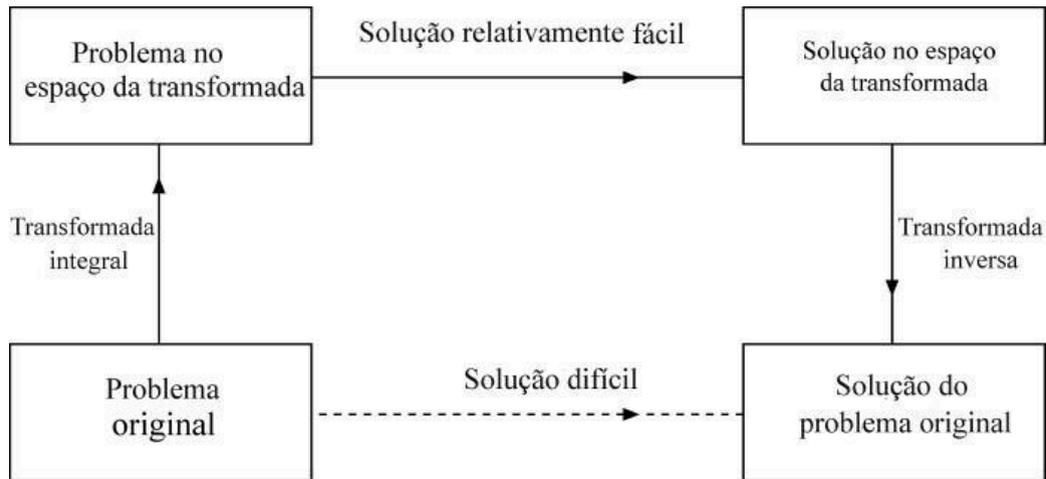


Figura 2.7. Esquema comparando as soluções a partir de um problema no espaço original e no espaço transformado. De uma forma geral, a justificativa para transformadas integrais é a simplificação da solução no espaço resultante dessa transformada. Assim, o problema é resolvido no espaço transformado e, em seguida, aplica-se a transformada inversa nessa solução para o espaço original do problema. Figura adaptada de [32]

Em geral, as funções podem ser decompostas, por exemplo, em séries de potências ou de Fourier. Nesse sentido, para uma função $f(x)$ que atenda a determinadas condições, uma representação possível é por meio de séries de potências conforme a equação [31]

$$f(x) = \sum_{n=-\infty}^{\infty} c_n x^n,$$

onde $f(x)$ é uma função a ser decomposta, c_n são os coeficientes da série e n é um número inteiro.

Além das séries de potência, outra ferramenta que pode ser utilizada na decomposição de entidades matemáticas é a série de Fourier. Analogamente à representação em séries de potência, um sinal $x(t)$ pode ser representado por uma série de Fourier com coeficientes c_n , conforme a equação

$$x(t) = \sum_{n=-\infty}^{\infty} c_n e^{in\omega t},$$

na qual há uma expansão em exponenciais complexas. Diante disso,

$$c_n = \frac{1}{T} \int_{-T/2}^{T/2} x(t) e^{-in\omega t} dt$$

representa os coeficientes c_n

Nesse contexto, cabe ressaltar que a decomposição de sinais em conjuntos de sinais básicos é uma operação desejável em alguns casos. A transformada de Fourier é uma abordagem que viabiliza essa decomposição. Nesse sentido, a equação

$$X(k) = \sum_{n=0}^{N-1} x(n)e^{-i\frac{2\pi}{N}nk}$$

apresenta o sinal transformado $X(k)$ a partir de um sinal $x[n]$.

Essas representações são para a transformada contínua de Fourier. No entanto, em especial no contexto de situações em que se utilizam computadores para processamento e representação, é importante trabalhar com valores discretos - inclusive para o tempo e para a frequência [28, 32]. Para isso, é necessário que os valores de ω , que estão relacionados ao domínio da frequência, sejam discretos.

O teorema da amostragem de Nyquist-Shannon aponta condições para que a amostragem do sinal não implique em perda de informação. Ou seja, é uma condição para que o sinal analógico seja convertido em digital e, sem perda de informação, possa ser perfeitamente recuperado (convertido novamente a analógico).

Segundo esse teorema, proposto por Nyquist [29] e Shannon [30], um sinal $x(t)$ de banda limitada w_m pode ser determinado unicamente por uma amostra $x_s[n]$, desde que essa amostra x_s tenha frequência w_s superior ao dobro frequência do sinal original. Ou seja, se $w_s > 2w_m$ (chamado de condição ou critério de Nyquist), então $x(t)$ é representado unicamente por $x_s[n]$ e este, portanto, pode ser restaurado a $x(t)$ sem perda de informação[18, 28].

A figura 2.8 (abaixo) representa o efeito da amostragem em duas situações. Na primeira, a frequência de amostragem atende ao critério de Nyquist; na segunda, por não atender, há o fenômeno de aliasing (uma sobreposição que representa perda de informação).

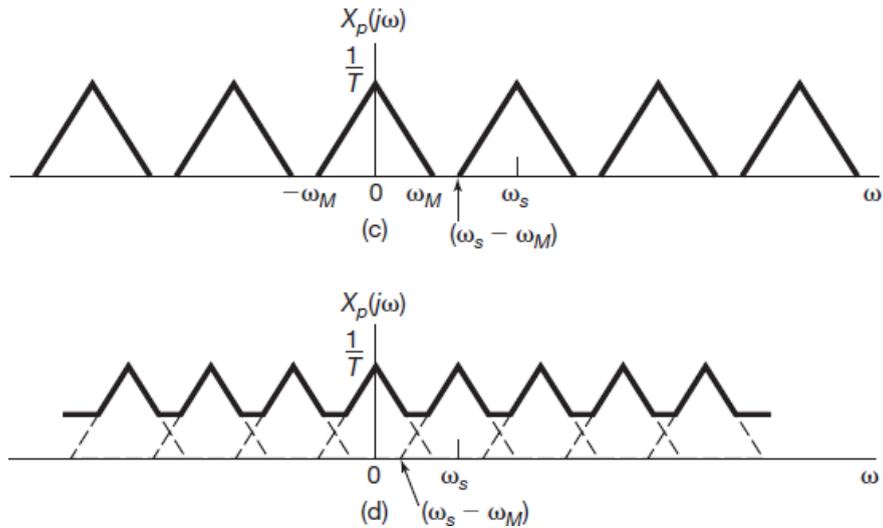


Figura 2.8. Representação do fenômeno de aliasing. No primeiro caso, a frequência de amostragem atende ao critério de Nyquist. No segundo, no entanto, a frequência não atende e, por isso, ocorre perda de informação. Essa perda é representada pela sobreposição na imagem “d”. Figura adaptada de [18]

2.6 APRENDIZADO DE MÁQUINA

Atualmente, há alta disponibilidade e coleta de dados ocorrendo em diferentes contextos. No entanto, a análise e extração de informação útil desses dados pode ser um desafio de implementação que requer técnicas de mineração de dados e aprendizado de máquina [35].

A combinação de volume e heterogeneidade de fontes de dados, aliada ao poder de extração e processamento de informações, refletem-se em complexidade na organização dos processos.

Os pipelines de dados são fluxos de operações – normalmente automatizadas – sobre essas bases de dados. Essencialmente, esse fluxo parte de uma ou mais fontes e finaliza em armazenamentos ou provisionamentos de dados para partes interessadas (interna ou externamente aos sistemas principais).

O destino final dos dados varia de acordo com a aplicação. No geral, esse destino será para uma ferramenta de visualização [60, 61], modelos de aprendizado de máquina (ML, do inglês “*machine learning*”) [62, 63] ou modelos de aprendizado profundo (DL, do inglês “*deep learning*”) [64, 65].

O entendimento de arquitetura para organização de pipelines é importante para prover maior qualidade na coleta de múltiplas fontes. Isso favorece um resultado mais otimizado para o esforço aplicado [2]. A organização desses fluxos favorece uma automação no monitoramento, na detecção de falhas e na migração.

Aprendizado de máquina é uma área que estuda programação de computadores que podem aprender com os dados [6]. Esse aprendizado é a criação de modelos (ou, ainda, modelos preditivos ou mineração de dados). Em geral, esses modelos são desenvolvidos para prever possíveis saídas para novos dados [33]. Essa área é uma parte da inteligência artificial, que é usada para identificar relações entre os dados históricos e padrões de tendência [35]. As técnicas de aprendizado de máquina são aplicáveis, em geral, na resolução de problemas nesses contextos [6].

As soluções existentes requerem grandes esforços ou o uso de muitas regras. Nesse caso, os algoritmos de aprendizado de máquina podem simplificar o código e melhorar o desempenho. Quando os problemas não têm soluções satisfatórias utilizando as abordagens convencionais, os algoritmos de aprendizado de máquina podem encontrar uma solução.

Embora não seja necessário ou viável aplicar aprendizado de máquina em todos os contextos, essas técnicas são potencialmente úteis em alguns desses. As aplicações mais sofisticadas tecnicamente em aprendizado de máquina ainda não estão tão presentes na prática clínica [39], mas vários trabalhos ressaltam esse potencial de aplicabilidade com entrega de valor. A exemplo disso, há relatos de sua aplicabilidade nessas áreas: bioinformática; detecção de invasão; jogos; marketing; detecção de malware; identificação de imagens [34]. O quadro 2.2 faz alguns apontamentos a respeito desses materiais.

Quadro 2.2. Trabalhos em aprendizado de máquina

Referência	Descrição do trabalho
[41]	Apresenta aplicações de aprendizado de máquina em epilepsia utilizando dados de eletroencefalografia, vídeo, imagens, planejamentos de cirurgias e de movimentos.
[42]	Pesquisa baseada em aprendizado de máquina utilizando dados epidemiológicos tendo em vista identificar mecanismos que afetam a qualidade do sono de humanos tendo em vista elaborar estratégias de intervenção.

[36]	Aplicação de aprendizado de máquina para identificar marcas de óleo em imagens de radar, a partir de imagens do Canadian Environmental Hazards Detection System (CEHDS). Embora os dados estivessem desbalanceados (o que é um desafio adicional), os autores conseguiram propor uma solução para o reconhecimento de imagens.
[37]	Utilização de Máquina de Vetor de Suporte e árvores de decisão (métodos que serão vistos mais adiante e utilizados neste trabalho) para mapeamento de áreas rurais utilizando técnicas de mineração de dados para o desenvolvimento de classificadores de imagens.
[38]	Utilização de dados gerados a partir de sensores, celulares, equipamentos médicos e de empresas de seguros. A partir desses dados, buscou-se entender possibilidades de prevenção e tratamento de obesidade.
[40]	Discute sobre possibilidades de utilização de aprendizado de máquina no processo de descoberta e desenvolvimento de novos princípios ativos com finalidades farmacológicas.

Os algoritmos de ML variam de acordo com sua aplicabilidade e requisitos. Nesse sentido, os sistemas de ML podem ser classificados a partir de alguns parâmetros isolados ou combinados.

Quanto à supervisão humana, pode-se classificar em aprendizado supervisionado, não supervisionado, semi-supervisionado e por reforço (também chamado de “aprendizado online”) [6, 33].

No aprendizado supervisionado, os conjuntos de dados são rotulados: há uma identificação prévia sobre a qual classe (identificador) o dado pertence [33]. Por exemplo: um conjunto de imagens de animais no qual cada uma destas já são previamente identificadas como gato ou cachorro. Neste exemplo, as classes são “gato” e “cachorro”.

Um outro exemplo é a classificação de patologias. Para isso, considere um conjunto hipotético de dados de pessoas que podem estar (unicamente) em cada um desses grupos (classes): controle; patologia 1; patologia 2; patologia 3. Além disso, é razoável que cada registro desses tenha algumas informações, como a idade e a massa. Esses atributos, que são chamados de características (ou “features”), podem ser utilizados na construção do modelo para treinamento. A figura 2.9 ilustra esse conjunto de dados.

Idade (anos)	Massa (Kg)	Grupo
20	45	Controle
23	77	Patologia 1
25	99	Patologia 2
39	81	Patologia 3

Figura 2.9 - Exemplo com um conjunto de dados para aprendizado supervisionado. Nessa ilustração, cada linha é um registro de uma pessoa; as primeiras colunas (idade e massa) representam as características (“features”), que são as informações sobre os dados a partir das quais, supostamente, será possível classificar um registro; a última coluna (grupo), por sua vez, é a indicação da classe à qual cada registro pertence.

De forma contrária ao aprendizado supervisionado, no aprendizado não supervisionado não há rótulos iniciais [6, 33]. Há algoritmos desse tipo para criação de “cluster” (K-means, DBSCAN, HCA), detecção de anomalia (One-Class SVM e Isolation Forest), visualização e redução de dimensionalidade (principal component analysis (PCA) e Kernel PCA) e aprendizado de regras de associação (Apriori e Eclat) [6].

Os algoritmos de clusterização criam grupos de acordo com as similaridades de suas características: buscam, como ilustrado na figura 2.10, por registros que são mais próximos em um espaço de características. Assim, utilizando o exemplo do conjunto de dados de pessoas com idade, cidade e patologia, pode-se criar uma representação na qual as características (idade e cidade) são eixos e os registros são pontos que, para essa ilustração, será assumido que representam pessoas cuja patologia é desconhecida. Cabe ao algoritmo de aprendizado não supervisionado a tarefa de identificar uma forma de segmentação.

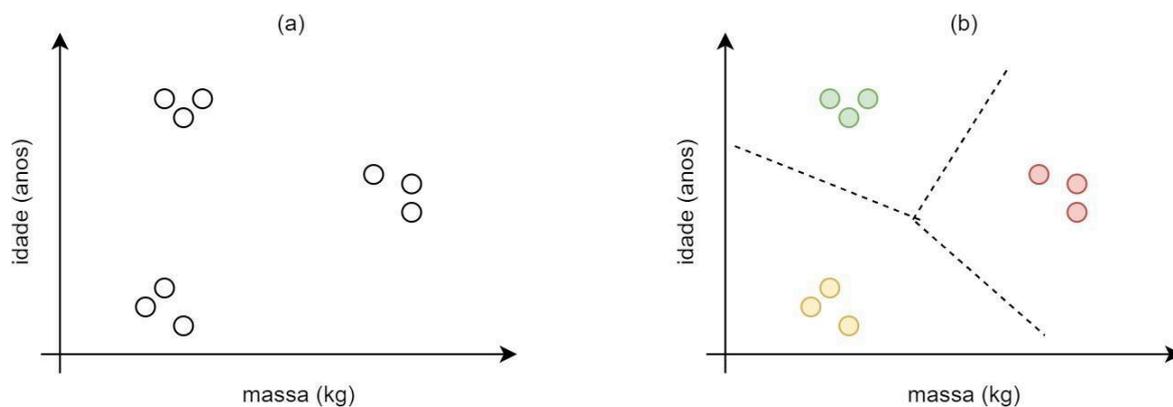


Figura 2.10. Representação de (a) um conjunto de dados sem rótulos em um gráfico com características dos dados em cada eixo e com (b) uma possível separação de classes a partir de um algoritmo de aprendizado não supervisionado.

Outra aplicação de aprendizado não supervisionado é em algoritmos de visualização. Esses são úteis para a representação gráfica (em duas ou três dimensões) de dados complexos e não rotulados. Para tanto, esses algoritmos entendem como os dados são organizados e, a partir do padrão identificado, projetam características que melhor representam esses dados de forma a preservar sua estrutura e representar em graficamente (em até três dimensões). A figura 2.11 ilustra uma representação de um conjunto de dados com múltiplas características reduzidas a uma apresentação bidimensional a partir da utilização do t-SNE.

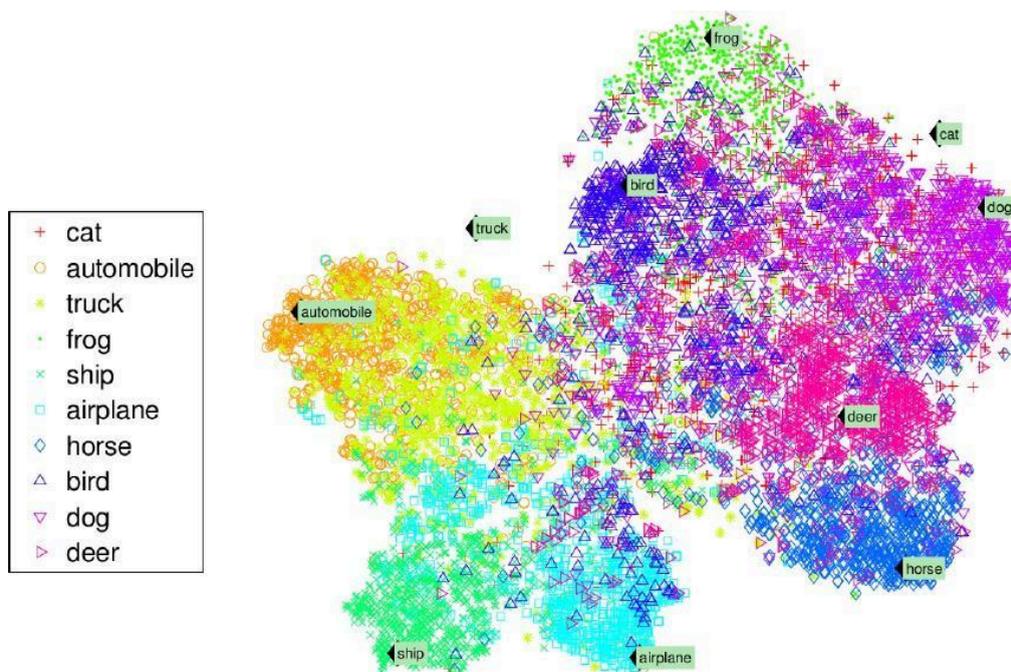


Figura 2.11. Visualização de um conjunto de dados utilizando t-SNE. Nesse exemplo, as classes são objetos agrupados em um mapa de características bidimensional: pontos mais próximos tendem a pertencer à mesma classe. Esse método permitiu representar graficamente dados com múltiplas características. Figura adaptada de [6]

No aprendizado semi-supervisionado, por sua vez, apenas parte dos dados são rotulados [33]. Ou seja, embora os registros tenham características, alguns dos registros da base de dados de treinamento são desconhecidos. Um exemplo disso é um serviço de classificação do Google Photos: a partir de algumas fotos rotuladas, há o reconhecimento de fotos semelhantes [6]. No geral, os algoritmos desse tipo de aprendizado de máquina são uma combinação de algoritmos supervisionados e não supervisionados - como o DBN (deep belief networks), que são baseados em um algoritmo não supervisionado (RBM, ou restricted Boltzmann machines) em sequência a algum passo anterior utilizando aprendizado supervisionado [6]. A figura 2.12 ilustra uma situação em que apenas alguns registros são rotulados - os demais podem ser classificados utilizando aprendizado semi-supervisionado.

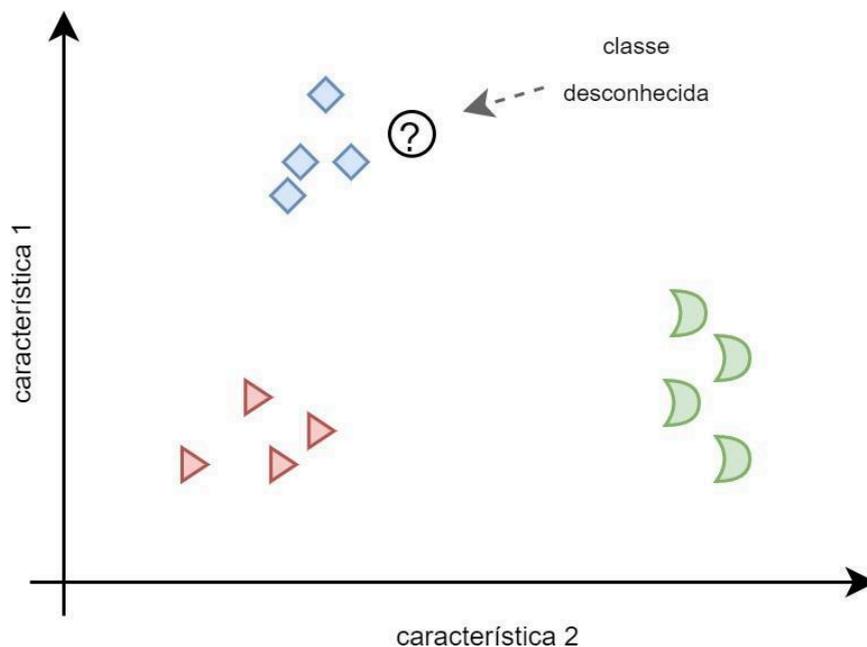


Figura 2.12 - ilustração de um conjunto de dados parcialmente rotulado. Cada um dos três símbolos representam uma classe. O círculo com uma interrogação (em destaque), por sua vez, representa um registro cuja classe é desconhecida.

No aprendizado por reforço, por sua vez, há a figura do “agente”. Esta é uma representação de uma abstração computacional que observa o ambiente e, a partir disso, escolhe e executa uma ação [6]. Conforme ilustrado na figura 2.13, caso esta ação leve a um resultado esperado, é computado um retorno positivo; caso o resultado seja diferente do esperado, há uma penalidade (retorno negativo). O objetivo do algoritmo nesse método é encontrar a melhor estratégia - chamada de política (“*policy*”) - que define como o agente deve se comportar nas próximas situações.

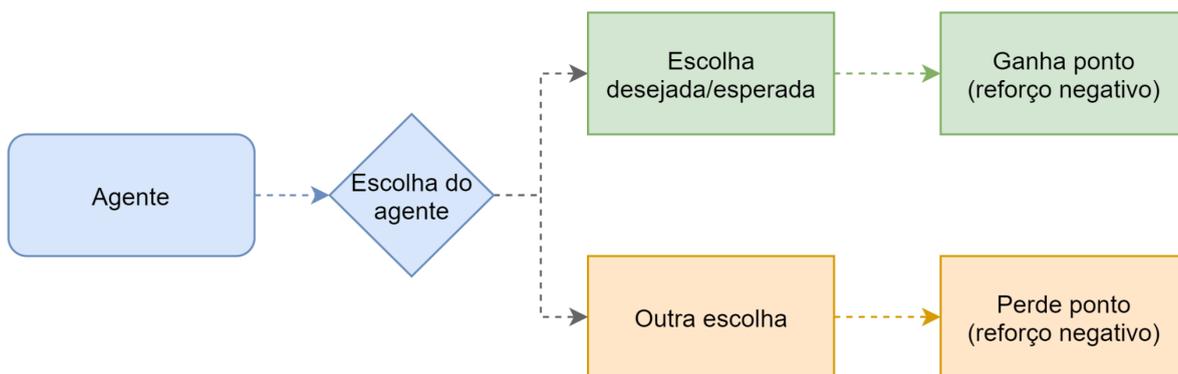


Figura 2.13. Ilustração esquematizando aprendizado baseado em reforço. Se a escolha realizada pelo agente se refletir em um resultado esperado, há um aumento de pontuação a esse caminho: reforço positivo. No entanto, se a escolha se refletir em um resultado distinto, há uma perda de pontos: reforço negativo.

Este trabalho utilizou um conjunto de dados rotulados, como será apresentado em outras sessões. Esse é um dos motivos pelos quais o foco deste trabalho está no aprendizado supervisionado.

Quanto à frequência de atualização dos dados, o aprendizado de máquina pode ser em lotes (batch) ou online. No primeiro, o sistema é treinado com os dados disponíveis no momento e, em regra, não passam por incrementos; a partir desse treino, o algoritmo passa a ser utilizado apenas com esse aprendizado inicial, sem sofrer alterações baseadas em novos dados. Para que uma nova versão seja desenvolvida, é necessário refazer o treino utilizando todos os dados (os já existentes no primeiro treino e o inicial). Esse novo treino é custoso em termos computacionais: tende a requerer recursos físicos (como espaço em memória e em disco) e um tempo relativamente maior [6]. No entanto, essa abordagem tende a ser mais facilmente implementada e a ser executada de forma mais controlada; além disso, as etapas do processo de treino podem ser automatizadas de forma que os experimentos com múltiplos

treinos sejam executados sem interação humana adicional após a execução do primeiro treino.

No aprendizado online, por sua vez, o treino pode ocorrer de forma incremental: os dados podem ser utilizados para treino à medida em que são disponibilizados. Esse novo treino pode ocorrer individualmente ou em pequenos lotes. Isso significa que cada incremento é mais rápido e barato quando comparado ao novo treino realizado pelo aprendizado em lotes - que, para um novo incremento, requer o treino com toda a base. Essa abordagem de aprendizado é útil quando os dados são alterados com frequência. No entanto, há um desafio nesse aprendizado: os dados ruins também são inseridos no sistema e, assim, pode haver uma perda na qualidade do modelo. A exemplo disso, caso um sensor passe a funcionar inadequadamente, os dados coletados irão sujar o modelo treinado.

O aprendizado de máquina está relacionado ao poder de generalização. Nessa perspectiva, há duas abordagens: o aprendizado de máquina pode ser baseado em instância ou em modelo.

No aprendizado baseado em instância, a generalização ocorre por comparação. Os exemplos iniciais são memorizados pelo sistema; os novos registros (instâncias) são comparados aos anteriores por uma métrica de similaridade [6], como uma distância euclidiana no espaço de características, com a finalidade de encontrar o mais próximo. Ou seja, busca-se classificar o novo dado comparando-o com as instâncias anteriores. Em um sistema de classificação de clientes inadimplentes, por exemplo, cada novo registro de cliente pode ser comparado aos anteriores; caso o novo registro seja mais similar aos registros (instâncias) de clientes inadimplentes, essa será a classificação esperada para esse novo registro. A figura abaixo ilustra uma classificação utilizando a abordagem de aprendizado baseado em instância: o registro novo é classificado a partir dos registros já conhecidos considerando-se a menor distância no espaço de características; nesse caso, a métrica de similaridade é essa distância e, portanto, o novo registro será classificado como pertencente à classe do losango azul.

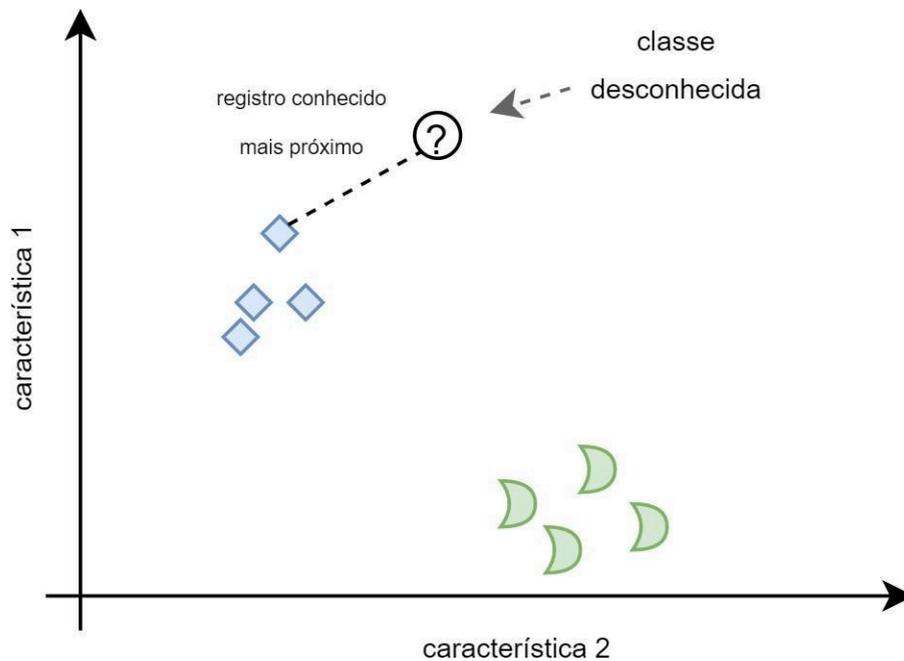


Figura 2.14. Ilustração de aprendizado baseado em instância com métrica de similaridade baseada em menor distância. Nesse exemplo, cada símbolo no espaço de características representa uma classe conhecida. A classe do novo registro (em destaque), por outro lado, é desconhecida. Por se tratar de uma abordagem baseada em menor distância, esse novo registro será rotulado com a mesma classe à qual o losango azul pertence. Cada um dos eixos (vertical e horizontal) representam uma característica.

No aprendizado baseado em modelo, por sua vez, é construído um modelo a partir dos dados já conhecidos [6]. Esse modelo é uma generalização parametrizada criada para representar os dados já conhecidos. Os novos registros são comparados com esse modelo, e não com cada um dos registros. Por exemplo, para um conjunto de dados com os preços de uma ação, é possível criar uma equação que represente esses valores (regressão); a partir dessa equação (e não comparando-se individualmente os pontos), é possível calcular os valores esperados para outros pontos. No contexto de classificação, é possível criar equações que separem o espaço de características: a partir dos dados conhecidos, é construído um modelo (representado por equações) que separa as classes; os novos dados serão comparados com essas equações e, a partir disso, serão classificados. A figura abaixo ilustra um espaço de características com retas que separam as classes; a partir dessa reta, que representa dos outros dados, o dado desconhecido será classificado; nesse caso, como está acima da reta, será classificado como pertencendo à mesma classe do losango azul.

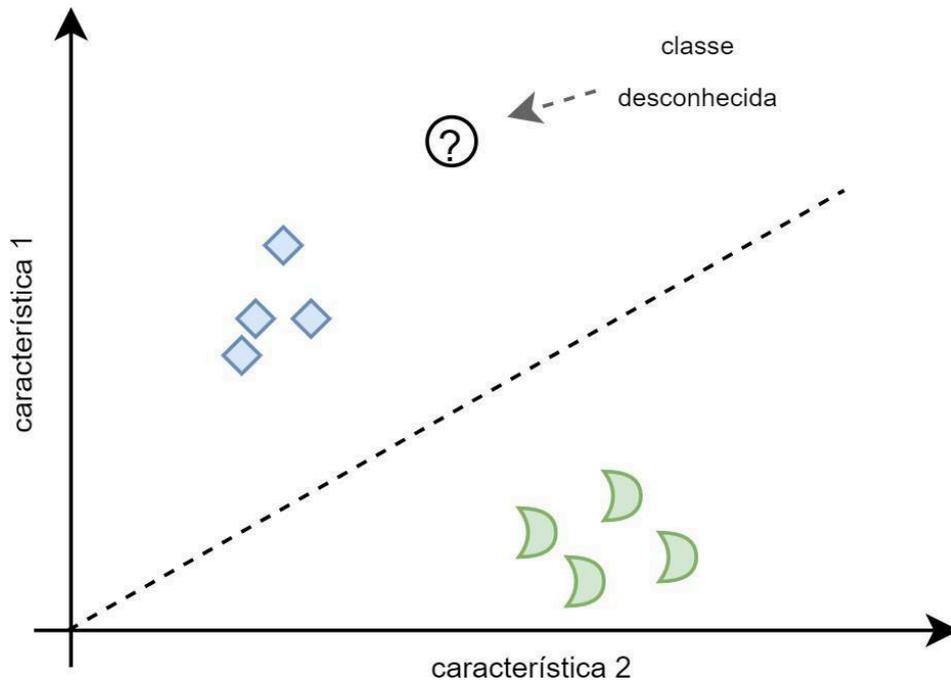


Figura 2.15. Ilustração de aprendizado baseado em modelo. Nesse exemplo, cada símbolo no espaço de características representa uma classe conhecida. A reta tracejada, por sua vez, separa as classes - uma representação de modelo. Nesse sentido, um registro acima dessa reta é classificado como pertencente à mesma classe do losango azul. Caso contrário, pertence à outra classe. Diante disso, o novo registro (em destaque) pertence à mesma classe do losango azul. Cada um dos eixos (vertical e horizontal) representam uma característica.

Os experimentos de aprendizado de máquina apresentam desafios. Dentre esses, é possível citar: quantidade insuficiente de dados; dados de treino não representativos; baixa qualidade de dados; características irrelevantes; baixo poder de generalização [6].

A quantidade de dados é um fator relevante no processo de aprendizado de máquina. Fazendo um paralelo com a forma como as pessoas aprendem: é preciso ter contato com várias situações diferentes para conseguir identificar um padrão. Em um processo de classificação de imagens de tomografia, por exemplo, um profissional precisou aprender a identificar patologias a partir de casos anteriores; analogamente, a criação de um modelo para identificar essas patologias requer uma base de dados com imagens que representem cada uma dessas classes (patologias) de forma que o algoritmo possa aprender com esses dados e, idealmente, seja capaz de classificar uma imagem de exame de uma pessoa cujo diagnóstico é desconhecido.

Cabe ressaltar que deve haver uma quantidade suficiente de dados em cada classe. É por isso que a quantidade insuficiente de dados é um ponto de atenção na criação do modelo. Para [6], tipicamente é necessário milhares de exemplos para o treinamento de algoritmos em problemas simples; ou ainda, para problemas mais complexos (como reconhecimento de imagens ou de fala), pode ser necessário ter milhões de exemplos.

Essa indisponibilidade de dados é uma barreira recorrente. Uma situação comum dessa limitação de dados é em casos de quadros clínicos raros: por não haver ocorrência desses casos, não há registros cujos dados possam servir de base de treino para os algoritmos.

Resolver esse fator de quantidade de dados pode não ser o suficiente: a qualidade desses dados é importante. Nesse sentido, é importante observar o poder de representatividade dos dados. Por exemplo, se todos os dados pertencerem a uma mesma classe, não será possível identificar padrões associados à outra classe.

Alguns problemas nos dados podem ser resolvidos, mas essa pode ser uma tarefa complexa e trabalhosa. Isso pode ocorrer em conjuntos de dados nos quais há registros incompletos. Para ilustrar essa situação, considere um conjunto de dados levantado a partir da coleta de exames de EEG; se um eletrodo estiver danificado e não coletar os dados, esse registro não constará nos dados. Nesse caso é necessário tratar esses dados com a finalidade de preencher o registro (por exemplo, com a média dos outros valores medidos pelos demais eletrodos) ou eliminar esse eletrodo da análise de dados. O modelo deve ser treinado com uma base que represente adequadamente a realidade; assim, esse cuidado de, por exemplo, tratar os dados que têm dados inconsistentes é fundamental para a adequação do modelo treinado. Construir um modelo com dados inconsistentes significa ter um aprendizado de uma realidade equivocada.

As características dos dados precisam ser relevantes para a sua classificação. Não é suficiente ter parâmetros associados aos dados que não são determinantes na sua classificação. A exemplo disso, considere uma tarefa de identificar uma patologia associada ao sono de humanos: o CPF de cada indivíduo não é um parâmetro que auxilia na classificação em questão. Ou seja, uma pessoa que tenha um CPF parecido não necessariamente terá uma condição morfológica, fisiológica ou comportamental semelhante. Nessa situação hipotética, certamente esse atributo deveria ser descartado.

Nesse sentido, há operações de *feature engineering* que cabem ser utilizadas no processo de preparação dos dados para os experimentos. Dentre esses, é possível destacar [6]:

seleção de características; extração de características; criação de características. A seleção de características é a escolha dos parâmetros que melhor representam os dados. A extração de características, por outro lado, é a combinação de características para criar uma outra que resume essas - como é o caso dos algoritmos de redução de dimensionalidade. Por fim, é possível adicionar novas características aos dados fazendo novas coletas - entrevistas ou exames complementares com os participantes. Esses processos permitem que os conjuntos de dados sejam enriquecidos (por meio de adição de características); adicionalmente, a remoção e a recombinação de características permite que o modelo criado seja baseado em informações mais determinantes para a classificação.

Tanto a quantidade, quanto a qualidade dos dados são importantes. De fato, a depender do contexto, esses fatores mais diretamente associados aos dados podem ser mais determinantes na qualidade do modelo de aprendizado de máquina do que a escolha dos algoritmos [43]. Assim, embora ambos os fatores (característica do conjunto de dados e algoritmo de aprendizado de máquina) sejam importantes para a qualidade do modelo, em especial em pequenos conjuntos de dados, é comum haver complicações para se conseguir bons resultados [6].

Um dos pilares do aprendizado de máquina é a capacidade de generalização: a partir do treino, encontrar um padrão que pode ser aplicado para novos dados. O sobreajuste (“*overfitting*”) é a situação na qual o modelo treinado é excessivamente ajustado aos dados de treino, de uma forma tal que representa bem apenas esses dados de treino, mas não há generalização: é um modelo que não tem bom desempenho para outros dados além daqueles que foram utilizados durante a fase de treinamento [6, 33, 44]. Ou seja, o aprendizado pode estar sendo interferido mais pelos ruídos dos dados do que pela informação que define as classes [33]. A figura 2.16 ilustra um caso de sobreajuste: há uma curva que separa os dados das duas classes sem erro para os dados conhecidos; no entanto, esse modelo erra nos novos dados (incapacidade de generalização). Nesse caso, a tentativa de ter uma curva completamente ajustada aos dados de treinamento (o losango para uma classe; e o outro símbolo para a outra classe) gerou uma curva de separação entre as classes que, embora acerte a classificação dos dados de treinamento, não acerta a classificação do dado de teste (representado por um círculo com “classe desconhecida”).

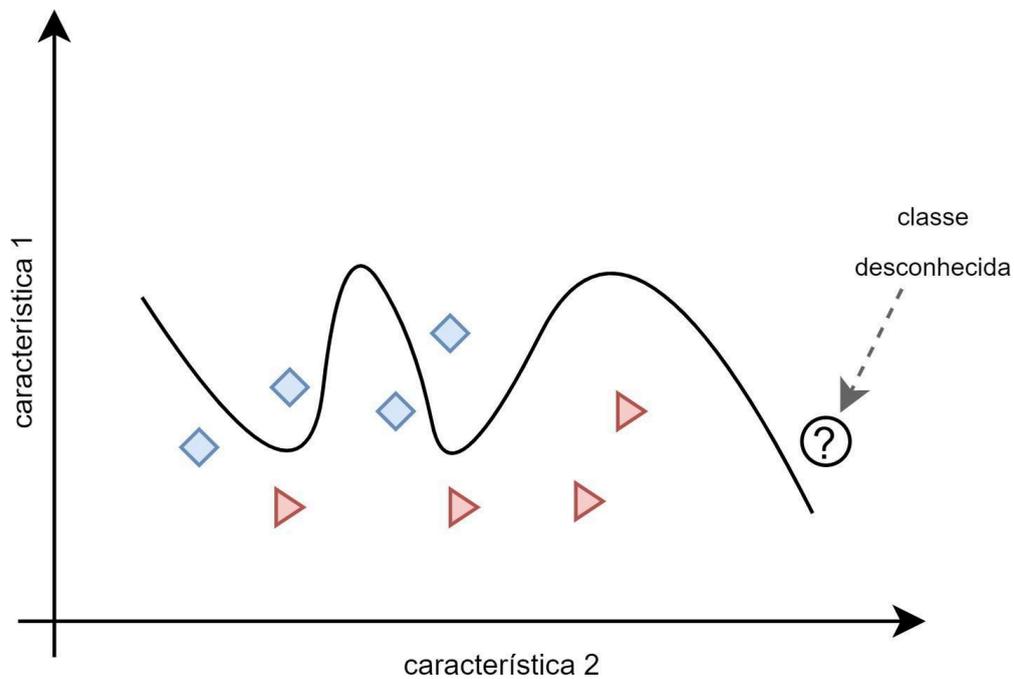


Figura 2.16. Ilustração de sobreajuste (overfitting) após treino de conjunto de dados. Cada classe está representada por um símbolo: losango e triângulo. A curva, por sua vez, representa o modelo. O sobreajuste é evidenciado pela tentativa excessiva de ajustar a curva aos dados de exemplos que, conseqüentemente, diminui o poder de generalização. Assim, a classificação de um novo registro (em destaque na imagem) com classe desconhecida será dificultada. Cada um dos eixos (vertical e horizontal) representam uma característica.

Esse cenário de sobreajuste é uma das principais complicações no aprendizado de máquina [44]. Tende a ocorrer em modelos complexos treinados em bases de dados pequenas ou com ruídos. Algumas soluções para esse problema [6]: simplificar o modelo reduzindo a quantidade de parâmetros ou de características selecionadas (no processo de “feature engineering” discutido neste trabalho); coletar mais dados para enriquecer a base existente; reduzir os ruídos dos dados de treinamento (tratando, por exemplo, os dados faltantes).

A simplificação dos modelos está relacionada aos hiperparâmetros utilizados: parâmetros do algoritmo de aprendizagem que definem sua configuração. Algumas dessas serão discutidas nesse trabalho, como a profundidade das árvores de decisão, o núcleo das máquinas de vetor de suporte e a quantidade de neurônios das redes neurais.

Por um lado, como foi visto, a perda de generalização pode ser ocasionada pelo sobreajuste. Por outro, pelo sub-ajuste (underfitting): simplificação excessiva do modelo que se reflete em um modelo com dificuldade para representar corretamente os dados [6]. Assim, se para o sobreajuste não há bom desempenho para os dados novos, para o sub-ajuste não é

bom resultado nem para os dados de treino [33]. A figura 2.17 ilustra um caso hipotético de underfitting no qual um modelo foi criado com uma reta separando os dados. Como a realidade desses dados é mais complexa, essa reta não consegue separar adequadamente o conjunto de dados nas suas classes.

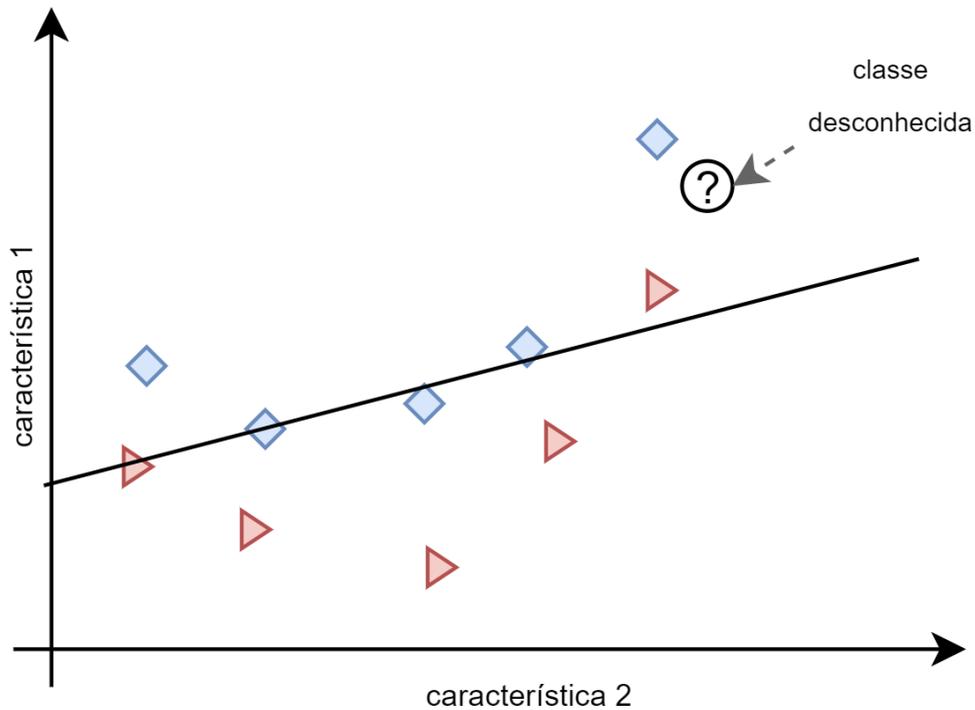


Figura 2.17. Ilustração de sub-ajuste (*underfitting*) no modelo de classificação. Cada classe está representada por um símbolo: losango e triângulo. Há uma uma reta (representando o modelo) para a separação das classes “losango” e “triângulo”. O subajuste é evidenciado pela simplificação do modelo que é linear, enquanto que a distribuição dos registros não é linear. Dessa forma, o modelo não é robusto o suficiente para classificar adequadamente um novo registro, como é o caso do registro em destaque: sua classificação é hipoteticamente desconhecida; o modelo tenderia a não classificar corretamente.

O problema de sub-ajuste pode ser resolvido por meio de uma adequação na complexidade do modelo e dos dados. Algumas abordagens para a resolução dessa situação [6]: aumentar a complexidade do algoritmo escolhendo uma arquitetura com mais parâmetros; rever o processo de feature engineering com a finalidade de buscar características mais representativas dos dados de treinamento.

No contexto de aprendizado de máquina, é comum dividir os dados em três conjuntos: dados de treinamento; dados de validação; dados de teste [33, 45]. Os dados de treinamento são a porção responsável diretamente pela construção do modelo [33]: são usados como dados de entrada para o algoritmo de indução nessa criação do modelo [46]. O conjunto de validação, por sua vez, é utilizado para a escolha entre os modelos treinados. Por fim, o conjunto de testes é utilizado para avaliar o modelo final [6, 33]; os valores encontrados que são diferentes desses dados de testes são chamados de erros de generalização [6]. A figura 2.18 representa essa separação de dados nesses três conjuntos explicados que têm como resultado, nessa ordem: os modelos criados a partir do treinamento (baseado nos dados de treinamento); o melhor modelo (selecionado com base nos dados de validação); métricas de desempenho (como resultado de comparações com os dados de testes).

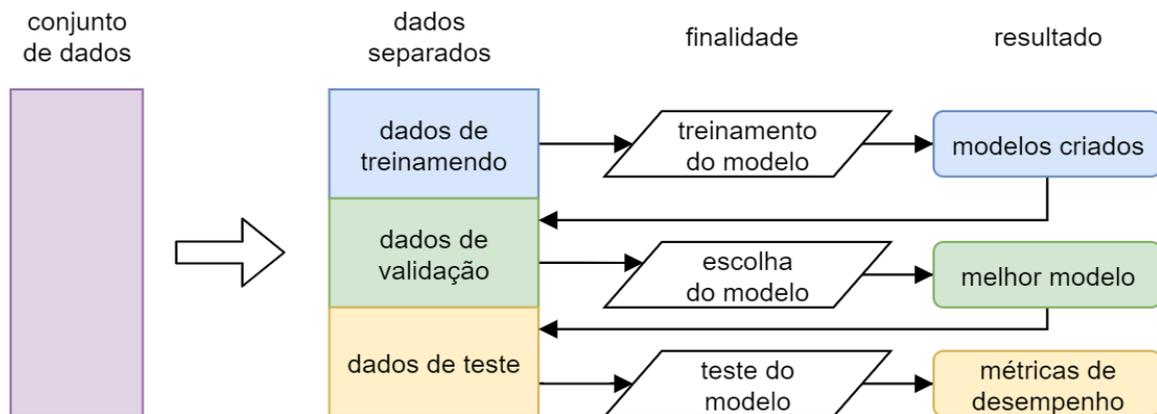


Figura 2.18. Representação de um fluxo de trabalho em aprendizado de máquinas para a separação do conjunto de dados brutos em dados de treinamento, de validação e de teste. Cada um desses tem finalidade específica: os “dados de treinamento” são utilizados para a identificação de padrões por meio do algoritmo de treinamento do modelo; os “dados de validação” são utilizados para verificar os resultados do modelo em elaboração para auxiliar na otimização dos resultados; os “dados de teste”, por sua vez, são, de uma forma geral, desconhecidos pelo modelo e, com isso, são utilizados para avaliar a capacidade de generalização do modelo criado.

Com a finalidade de se controlar os experimentos de aprendizado de máquina, é preciso que as métricas de desempenho dos algoritmos sejam mapeadas. Para isso, são comparados os valores esperados (baseando-se nos dados do conjunto de testes). São exemplos de métricas e análise de desempenho que serão utilizadas direta ou indiretamente:

precisão; acurácia; taxas (de verdadeiro positivo, de falso positivo, de falso negativo e de verdadeiro negativo); especificidade.

A matriz de confusão é uma representação que agrega várias informações relacionadas a frequências de acertos e erros a partir das quais é possível calcular direta ou indiretamente métricas de desempenho. As opções representadas diretamente nessa matriz são: verdadeiro positivo; falso positivo; verdadeiro negativo; falso negativo. A figura 2.19 ilustra uma matriz de confusão, na qual é possível identificar essa representação de frequências.

		Valores reais	
		<i>Condição positiva</i>	<i>Condição negativa</i>
Valores preditos	<i>Condição positiva prevista</i>	Verdadeiro positivo	Falso positivo
	<i>Condição negativa prevista</i>	Falso negativo	Verdadeiro negativo

Figura 2.19. Representação de uma matriz de confusão. Os valores reais são uma parte dos dados conhecidos separada para fazer essa avaliação; os valores preditos são os resultados da predição realizada pelos algoritmos preditivos a partir dos modelos treinados. Para a construção dessa matriz, ambos os conjuntos de valores são comparados a com a finalidade de avaliar o desempenho do modelo criado. O “verdadeiro” representa uma convergência entre os valores reais e preditos; o “falso”, por outro lado, representa uma divergência entre esses valores. Adicionalmente, o “positivo” representa a condição “positiva” (previamente estabelecida); analogamente, o “negativo” representa a condição “negativa”.

As linhas da matriz de confusão representam as frequências das diferentes condições preditas (a partir do modelo). As colunas, por sua vez, representam as condições reais (já conhecidas a partir dos rótulos dos dados). A “condição positiva” denota a característica em que se está focando; a “condição negativa” é o seu oposto.

O verdadeiro positivo (VP) e o verdadeiro negativo (VN) são condições nas quais o valor predito pelo modelo é o mesmo que o valor real para aquelas características. O primeiro ocorre quando esse acerto é para a condição positiva; o segundo, para a condição negativa.

Por outro lado, o falso positivo (FP) e o falso negativo (FN) contabilizam as frequências de casos em que o valor predito pelo modelo é distinto do valor real conhecido.

O primeiro ocorre quando o valor predito pelo modelo deveria ser negativo para a condição em questão, mas foi predito como sendo negativo. O segundo é o caso contrário: o modelo deveria prever um valor positivo, conforme dados conhecidos; mas a predição foi de um valor negativo.

A partir desses valores de verdadeiro e falso positivo e negativo, outras métricas de desempenho dos modelos são calculadas. A mais comum é a acurácia: um cálculo de quanto que o modelo acerta. Dessa forma, é calculada a taxa de positivos (verdadeiro e falso) dentre todos os casos. A equação abaixo sintetiza essa métrica.

$$A = \frac{VP + VN}{VP + VN + FP + FN}$$

onde A é a acurácia, VP são os verdadeiros positivos, VN são os verdadeiros negativos, FP são os falsos positivos e FN são os falsos negativos.

2.7 CLASSIFICADORES

Random Forest

Uma abordagem relativamente simples e eficaz para classificação é a utilização de árvores de decisão. Essa estrutura representa um número possível de caminhos de decisão e, para cada um desses caminhos, há um resultado possível [33].

Há dois tipos de árvores de decisão: árvore de classificação; árvore de regressão [33]. A primeira produz saídas categóricas - classes, por exemplo, para identificar se o resultado esperado é um estado fisiológico ou não. A segunda produz saídas numéricas - a exemplo disso, um preço de um ativo financeiro que está sendo estimado. Neste trabalho, o foco é para as árvores de classificação.

As árvores de decisão são classificadores atrativos devido à sua alta velocidade de execução [19], simplicidade no entendimento dos resultados e transparência no processo de previsão [33]. Além disso, é possível utilizar uma mistura de atributos numéricos e categóricos [33].

Por outro lado, há desafios na criação de uma árvore de decisão. O principal está relacionado ao processo de se encontrar a árvore ideal: pode haver um sobreajuste. Nesse caso, seu baixo poder de generalização se reflete em baixa acurácia para dados não vistos, servindo mais adequadamente apenas para os dados de treino (uma condição particular). [19, 33]

O processo de construção de árvore de decisão envolve entender as principais perguntas que devem ser feitas e em qual ordem. A exemplo disso, considere que se espera classificar as condições climáticas para identificar se é favorável ou não realizar um experimento. Nesse caso ilustrativo, podem ser utilizadas as perguntas associadas à temperatura e ao momento do dia. A figura abaixo representa uma árvore possível para essa situação hipotética.

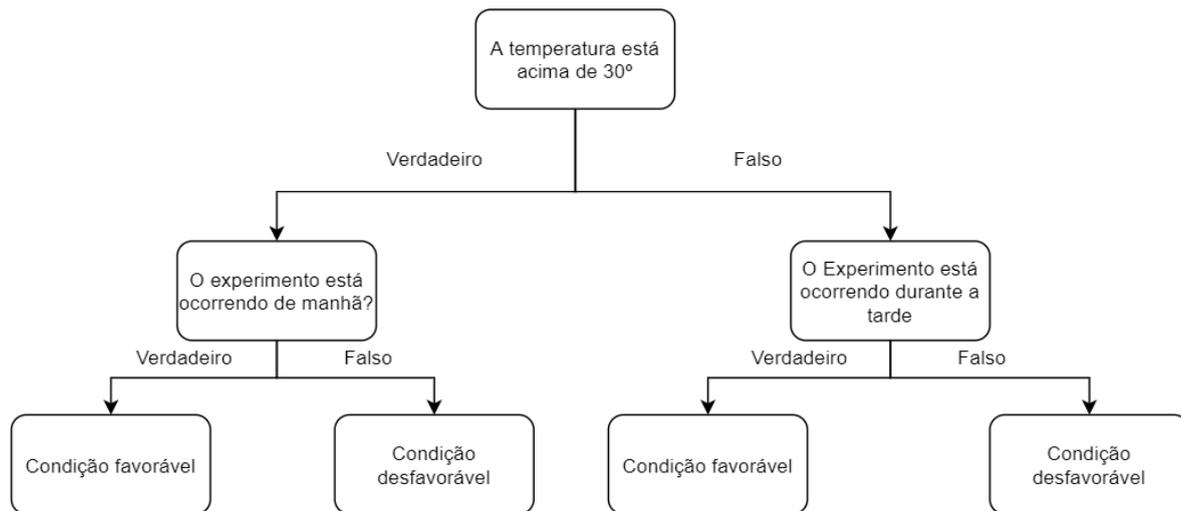


Figura 2.20. Ilustração de uma árvore de decisão em situação hipotética para condições favoráveis e desfavoráveis para a realização de um experimento. Nessa árvore, cada caixa representa um nó: uma condição de uma determinada variável que será avaliada. Há dois tipos de nós particulares: o superior, que é a raiz (por onde a árvore começa); os inferiores, que são chamados de folha e remetem à condição final (para uma tarefa de classificação, essa é a classe esperada para as condições do registro de entrada).

Embora essa seja uma representação possível, não necessariamente é a mais otimizada. Para essa otimização, deve-se buscar as perguntas cujas respostas entreguem o máximo de informação sobre a árvore que se pretende criar [33]. A métrica relacionada a essa informação é a entropia, que é utilizada para representar a incerteza associada aos dados [33].

Matematicamente, a equação

$$H_i(S) = -p_i \log_2 p_i$$

define a contribuição $H_i(S)$, em bits, da classe c_i para a entropia $H(S)$, sendo p_i a probabilidade de ocorrência da classe [6]. Nesse sentido $H(S)$ é dada, em bits, por

$$H(S) = - \sum_i p_i \log_2 p_i$$

que representa a soma dessas entropias $H_i(S)$.

Os valores de $H_i(S)$ tendem a 0 quando p_i tende a 0 ou 1. Esse comportamento significa que quando a maioria dos dados está em uma única classe, a entropia tende a zero - e, com isso, há baixa incerteza. Por outro lado, quando os dados estão espalhado em múltiplas classes, p_i está afastado de 0 e 1 e, assim, o valor de $H_i(S)$ será maior. Esse comportamento reforça a razoabilidade da equação adotada para a estimativa de entropia.

Essa entropia é base para algoritmos de árvores de decisão. A busca de uma árvore ótima requer questões (“nós”) que dividam os dados em um subconjunto com alta certeza (medida pela baixa entropia) e em outro com incerteza (maior entropia) [33]. Com isso, o nó representa uma condição que é determinante para o primeiro subgrupo: traz uma maior certeza quanto à sua classe.

Há vários métodos para a construção das árvores de decisão. Um exemplo é o ID3, um algoritmo relativamente simples. Para detalhar seu funcionamento, considere que os dados são rotulados e há uma lista de características que deve ser considerada para ramificar. A partir disso, o algoritmo segue esses passos: se os dados possuem o mesmo rótulo, é criado uma folha que prevê o rótulo; caso a lista de características está vazia, um nó folha é criado para prever o rótulo mais comum naquele subconjunto e, então, o algoritmo pára; caso contrário, deve-se tentar particionar os dados para cada uma das características restantes; na divisão com entropia mais baixa, é adicionado um nó de decisão; por fim, deve-se retornar a cada subconjunto particionado utilizando-se as outras características que ainda não foram utilizadas [33].

Embora haja as vantagens previamente citadas sobre as árvores de decisão, essa abordagem pode gerar um sobreajuste nos dados. Ou seja, o modelo gerado pode se ajustar quase perfeitamente aos dados de treinamento, no entanto, perdem o poder de generalização. Uma das formas de evitar esse sobreajuste é utilizando várias árvores de decisão simultaneamente [6, 33].

Esse método, chamado Random Forest (“florestas aleatórias”), considera múltiplas árvores que selecionam aleatoriamente amostras de dados. Cada árvore dessas é generalizada com a finalidade de aumentar a generalidade do modelo. Com isso, esse método permite bom desempenho por apresentar velocidade na execução e acurácia nos resultados [19, 20].

Esse método se mostrou importante em várias aplicações, incluindo dermatologia [20], oncologia [21], outros contextos de visão computacional [22] e no estudo de estágios de sono [23].

Um conjunto de preditores é chamado de ensemble [6]. Assim, uma Random Forest é um ensemble formado por árvores de decisão. Para um dado conjunto de teste, várias árvores de decisão são criadas; a predição ocorre a partir de votos de cada árvore; o resultado é a predição da Random Forest.

Mais precisamente, Random Forest é um ensemble do tipo Bagging [6]. Neste método, são geradas múltiplas versões de um modelo de predição que são utilizados para chegar a um modelo único por uma agregação da média a partir da saída numérica dos modelos iniciais. Ganhos substanciais na acurácia ocorreram em testes realizados em dados reais e simulados utilizando classificação e na regressão [34].

Máquina de Vetores de Suporte (SVM, do inglês *Support Vector Machine*)

A máquina de vetor de suporte (SVM, do inglês support vector machine) é um modelo de aprendizado de máquina que pode ser utilizado para classificação - além de regressão e detecção de outliers. Por sua versatilidade e qualidade de resultados em potencial, esse é um dos modelos mais populares nesse contexto. Considerando-se o escopo do trabalho, o foco da discussão será na SVM como uma ferramenta para classificação [6].

Para um certo conjunto de dados com várias classes rotuladas, a SVM procura um hiperplano que separa esses dados de cada classe com a maior margem possível. Para simplificar, pode-se discutir sobre um conjunto com duas classes e com duas características predictoras. Nesse caso, a SVM busca uma reta (um caso particular do hiperplano) para separar essas classes.

As figuras abaixo ilustram essa situação: há duas classes, representadas por círculos e triângulos; há uma reta com sua respectiva margem. Em(a), a reta tem menor margem quando comparada a(b). Nesse caso,(a) não seria uma candidata para compor a SVM - pois não é uma situação ótima.

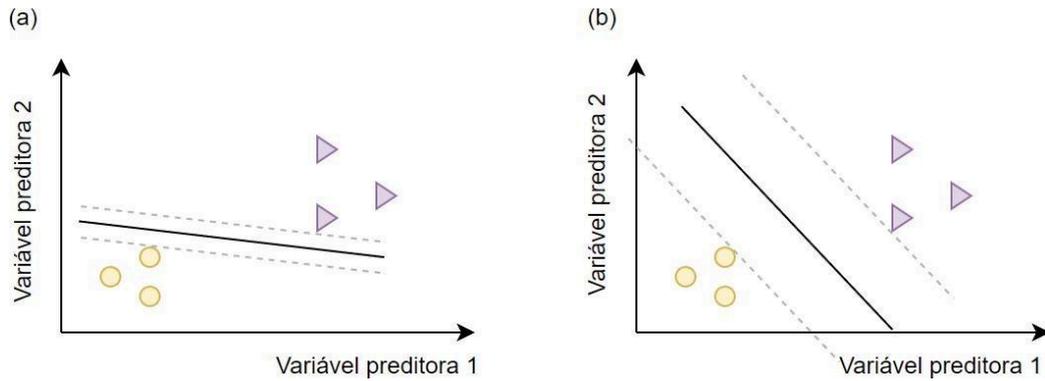


Figura 2.21. Ilustração de separação de classe com vetores de suporte. Em ambos os casos, há duas retas tracejadas que buscam uma região máxima a partir da reta contínua. No entanto, a segunda situação é um candidato mais otimizado por separar com maior distinção as classes representadas por círculo e triângulo.

Há situações, no entanto, que não são lineares. A exemplo disso, a figura abaixo ilustra uma situação em que não é razoável encontrar uma reta que separe adequadamente as duas classes.

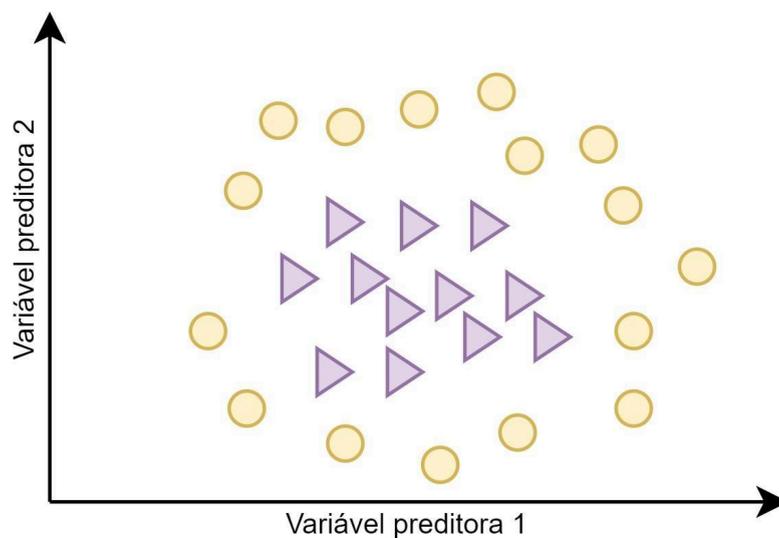


Figura 2.22 - Mapa de características para um conjunto de dados com duas classes cuja separação tende a não ser linear. Nessa representação, há duas classes: uma tem seus cada registro identificado por um círculo; outra, por triângulos.

Redes Neurais Convolucionais (CNN, do inglês *Convolutional Neural Networks*)

A natureza é inspiração para o desenvolvimento de soluções. Nesse sentido, o processo de tomada de decisão - que se baseia, essencialmente, no sistema nervoso [3, 5, 47, 57] - é inspiração para o desenvolvimento de soluções de aprendizado de máquina. De forma

mais concreta, as redes neurais artificiais são uma abordagem de aprendizado de máquina que busca mimetizar o comportamento de redes de neurônios biológicos [103]. Essa solução artificial não é tão sofisticada quanto o sistema nervoso biológico, mas permite operações que trazem bons resultados em aprendizado de máquina [6].

O neurônio biológico tem diferentes formas e comportamentos individuais e coletivos [3, 5, 47, 57]. Essa diversidade contribui para a complexidade das redes neuronais biológicas. No entanto, alta complexidade dificulta a modelagem de soluções e suas implementações computacionais. Diante disso, em 1943 foi apresentado um modelo matemático [104] por Warren McCulloch, um matemático, e Walter Pitts, um neurofisiologista, que simplifica a representação de um neurônio. Nessa representação, que é utilizada como base para modelos de redes neurais artificiais: o neurônio se relaciona com outros por meio de sinapses (junções, nesse caso de uma rede artificial, apenas entre neurônios); vários neurônios podem excitar ou inibir um neurônio seguinte, mas este neurônio somente pode ter um disparo indiferenciado (um processo “tudo ou nada”).

Esse disparo ocorre em determinadas condições que podem ser parametrizada. Dessa forma, se um neurônio atinge um limiar de excitação (“*threshold*”), ocorre o disparo [6]. Esse limiar é o resultado de todas as excitações que chegaram até o neurônio em análise, que pode, ainda, ter uma função (chamada de função de ativação) para modulazirar essa intensidade de excitações [6]. A Figura 2.23 representa esse comportamento dos neurônios utilizando as funções de ativação e o mecanismo de limiar de excitação.

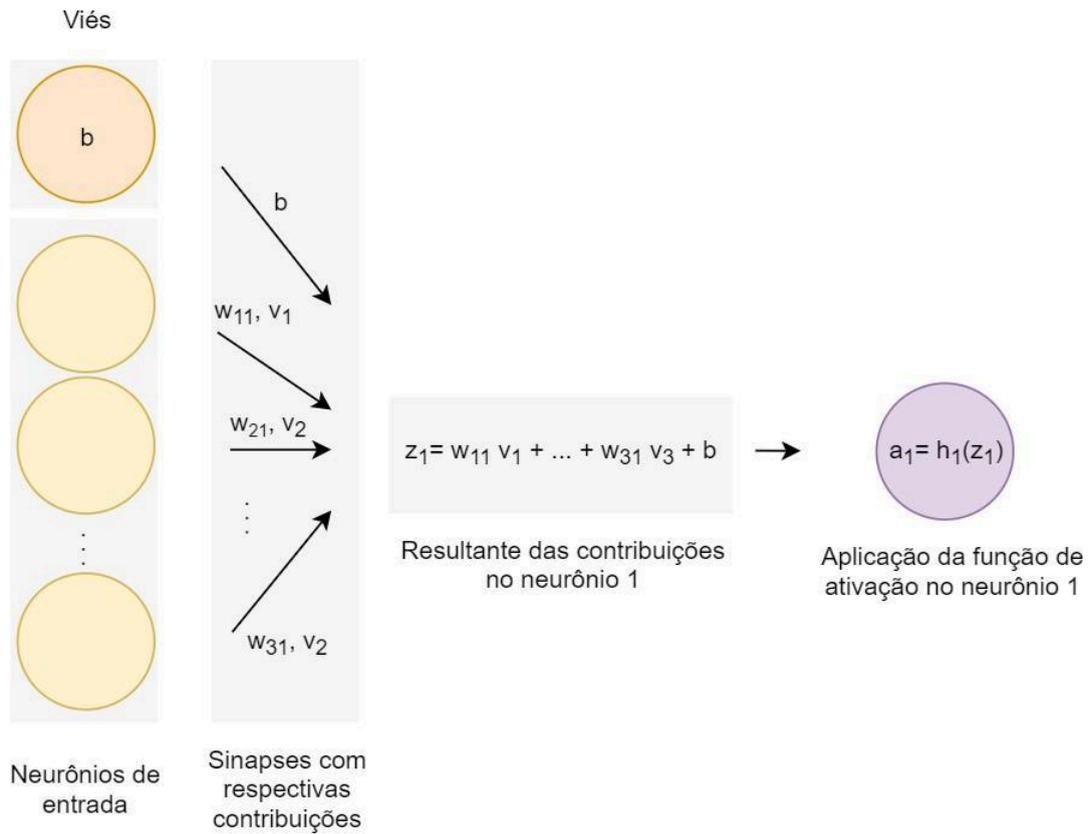


Figura 2.23. Representação de uma interação entre neurônios. Cada círculo representa um neurônio. Os neurônios à esquerda excitam (ou inibem) o neurônio da direita a partir de contribuições “v” e pesos “w” que resultam em um valor “z”. Este valor é utilizado como entrada da função de ativação. Caso esse valor resultante (saída da função de ativação) atinja um limiar definido, o neurônio em destaque irá propagar o sinal.

Algebricamente, a intensidade z que chega em um neurônio j neurônio é

$$z_j = \sum_i w_{ij} \cdot v_{ij} + b_j$$

onde w_{ij} é o peso dado a cada neurônio j , que contribui com uma intensidade v_{ij} de saída, e b é o viés [107]. Essa contribuição z_j é utilizada como entrada para a função de ativação “h”:

$$a_j = h_j(z_j)$$

onde o valor de ativação a_j para cada neurônio é a aplicação da função h_j de um neurônio j a partir daquela contribuição z_j .

A partir dessa abordagem, é possível utilizar uma função de ativação distinta para cada camada ou neurônio. Normalmente, utiliza-se a mesma função de ativação para todos os neurônios da mesma camada ou, ainda, para todas as camadas [107]. Alguns exemplos de função de ativação que são frequentemente utilizadas [6, 103, 107]: ReLU; sigmoide (“sigmoid”); tangente hiperbólica (“tanh”).

Embora o modelo de neurônio artificial proposto por McCulloch e por Pitts seja uma simplificação, é possível construir rede de neurônios artificiais que calcula as lógicas proposicionais [3]. A exemplo disso, com 3 neurônios é possível representar cálculos lógicos simples como conjunções, disjunções e negação [3, 103]. A Figura 2.24 ilustra esses cálculos lógicos a partir de neurônios artificiais.

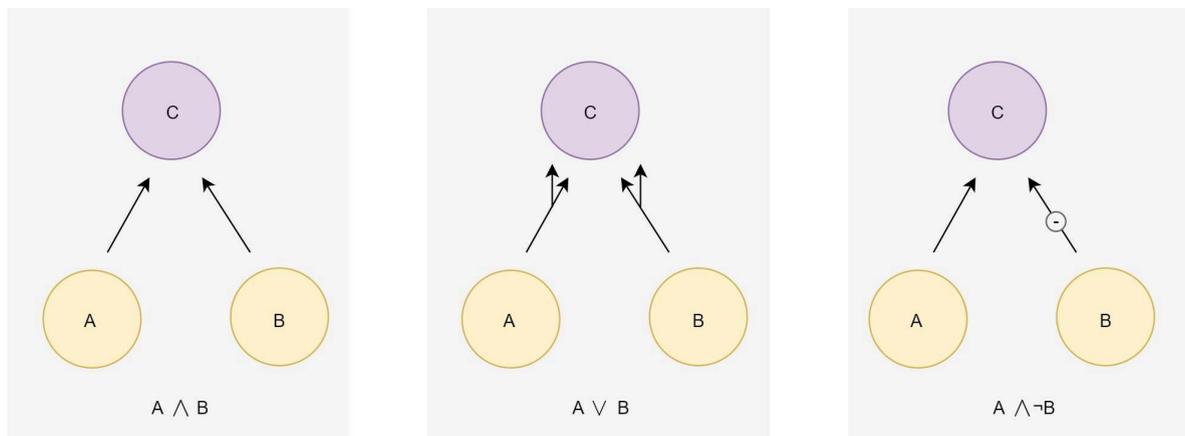


Figura 2.24. Representação de lógicas simples a partir de três neurônios artificiais. “A”, “B” e “C” representam neurônios; os dois primeiros são neurônios de entrada que, conjuntamente, modulam a entrada de “C”; este é o neurônio de saída que terá uma resposta “tudo ou nada” a partir do resultado de sua função de ativação. O primeiro diagrama representa um “e” (AND) lógico; o segundo, um “ou” (OR); o terceiro, um “e” com uma negação em “B”. Na primeira, A e B são necessários para atingir o limiar em C; na segunda, apenas um é suficiente. Na terceira, B atua negativamente.

De uma forma geral, os neurônios artificiais são aplicados em populações de neurônios organizadas em camadas, ainda que possam ser analisados individualmente. A camada de entrada tem os neurônios que representam cada unidade da entrada da rede; analogamente, no final, há uma camada de saída que contém neurônios representando cada unidade da saída [3]. A unidade da entrada é uma característica do mapa de característica utilizado na rede: por exemplo, a energia para uma banda de frequência do sinal. A unidade da saída, por sua vez, pode ser a probabilidade de ocorrência

de uma patologia. Essas são as escolhas detalhadas no capítulo de proposição de metodologia do trabalho na seção sobre aplicação de redes neurais artificiais. Entre as camadas de entrada e saída, opcionalmente há camadas intermediárias - também chamadas de camadas ocultas. A Figura 2.25 representa essas camadas utilizando-se as energias em alfa, beta, gama, delta e teta do EEG como características de entrada e patologias (além do grupo controle) como unidades de saída da rede.

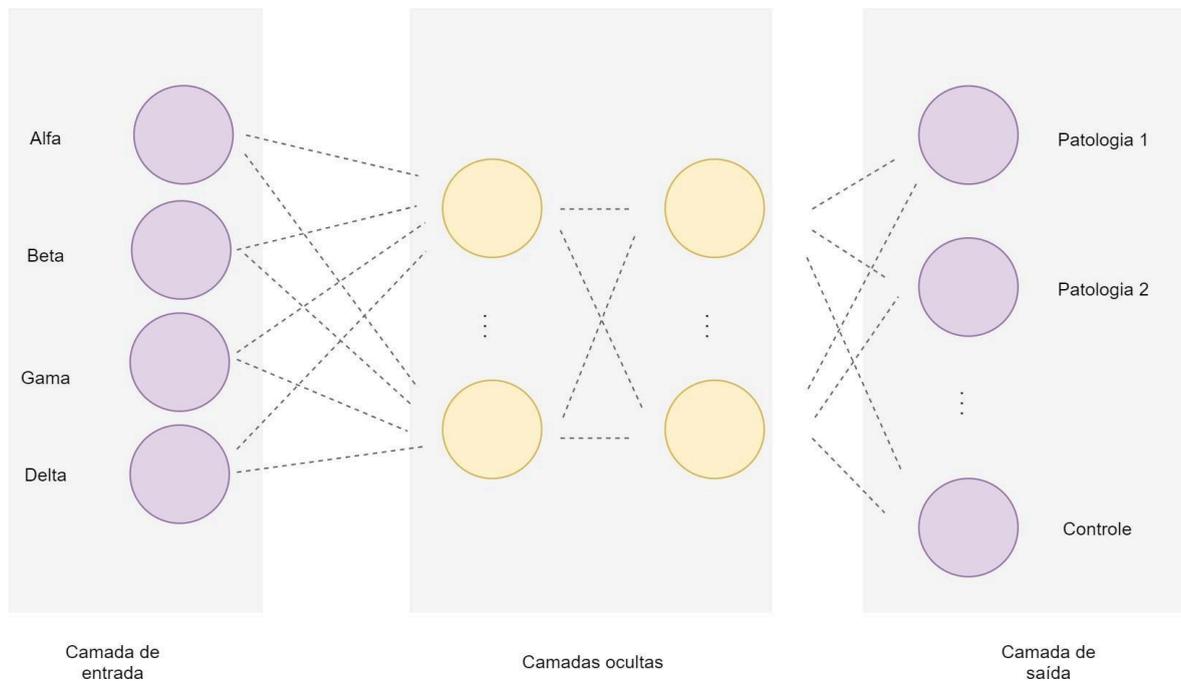


Figura 2.25. Representação de uma rede neural. Cada círculo corresponde a um neurônio. Nessa representação, cada neurônio da camada de entrada recebe a intensidade da energia em uma banda de frequência (alfa, beta, gama e delta). Na camada de saída, cada neurônio está relacionado a uma saída, que pode ser uma patologia ou o grupo controle. Os demais neurônios estão nas camadas ocultas. As linhas tracejadas são as sinapses (ligações entre esses neurônios artificiais).

É possível notar que as redes neurais permitem diferentes arranjos a partir de variações nos neurônios e nos seus relacionamentos. Nesse contexto, uma abordagem particular foi proposta: as redes neurais convolucionais (CNN, do inglês “convolutional neural networks”). A partir do uso de redes neurais convolucionais, novas características são extraídas automaticamente a partir de operações chamadas de convoluções [103, 107]. Foram apresentados trabalhos mostrando resultados positivos utilizando-se CNN [107].

A principal operação das redes neurais convolucionais é a convolução [6]. As características são extraídas a partir de operações de transformações sobre os dados de uma

camada e o resultado gera a camada seguinte em um mapa de característica por meio dessas operações [107]. Com isso, é possível extrair informações implicitamente dos dados [6, 107]. Algebricamente, a operação de convolução pode ser interpretada como uma operação em um tensor de entrada que leva a um mapa de características (outro tensor).

Outra operação importante comumente utilizada nas CNN é o “pooling”. Com isso é possível reduzir as dimensões dos mapas de características por meio da priorização de informações mais relevantes [103]. Essa operação pode ser interpretada como uma subamostragem que gera um mapa de características com resolução mais baixa [6, 107], o que permite a diminuição do custo computacional durante o treinamento da rede final. Existem alguns tipos dessa operação de pooling, como o MaxPooling [6, 103, 107] e L2 Pooling [107]. No primeiro caso, o pooling ocorre por meio da seleção do maior valor para cada região [6, 107]. As operações de pooling e convolução, representadas na Figura 2.26, podem ocorrer várias vezes em uma mesma CNN. Na representação da Figura 2.26, o fluxo do recorte finaliza em “próximas camadas”: essas camadas podem ser outras camadas convolucionais, de pooling ou camadas totalmente conectadas com os neurônios da saída.

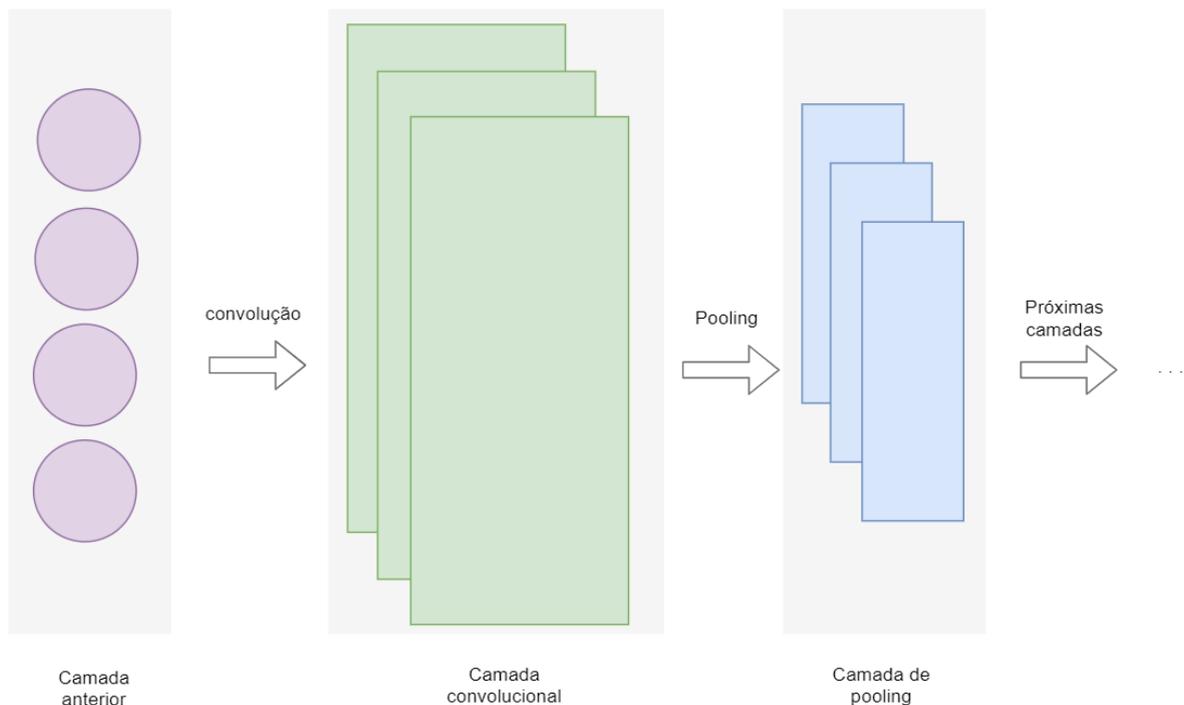


Figura 2.26. Representação de um recorte com camada convolucional e de pooling a partir de uma rede neural. Cada círculo representa um neurônio. A camada convolucional é resultante da operação de convolução; a camada de pooling, por sua vez, é resultante da operação de pooling. Após esse fluxo, pode haver outras camadas dessas ou outros tipos de camadas (inclusive a saída da rede).

2.8 PATOLOGIAS ASSOCIADAS AO SONO

Bruxismo

O Bruxismo é uma condição que pode ser caracterizada por uma atividade repetitiva nos músculos da mandíbula. Está associada a casos em que o indivíduo passa por situações de apertar ou ranger os dentes. [7]

Há duas manifestações circadianas distintas: pode ocorrer durante o sono (conhecido como “bruxismo do sono”) ou durante a vigília (conhecido como “bruxismo acordado”). [7] O estudo dessa condição é importante para diversas áreas. Dentre essas, cabe citar odontologia, neurologia e áreas relacionadas à medicina do sono. [7, 66, 67].

Insônia

A insônia é uma desordem comum para uma parcela significativa da população. É comum que a insônia ocorra como um problema inicial que evolui para outras comorbidades físicas e mentais [8]. A exemplo disso, sabe-se que a insônia impacta no risco de depressão [9] e hipertensão [10].

Narcolepsia

Narcolepsia é a principal causa de sonolência crônica [11, 12]. Pessoas com narcolepsia têm longos e frequentes períodos de sonolência. Ainda que durmam, voltam a sentir sono dentro de poucas horas [11]. Esse cenário tende a ser um complicador no contexto educacional e profissional dessas pessoas.

Epilepsia noturna do lobo frontal

A epilepsia noturna do lobo frontal é uma condição na qual ocorrem convulsões exclusiva ou predominantemente durante o sono. [13] A vídeo-polissonografia é o padrão ouro para diagnóstico [15]

Movimentos periódicos das pernas

A síndrome das pernas inquietas é uma condição patofisiológica que impacta no sono. Estudos indicam que sua causa pode ser por questões genéticas ou por disfunções no transporte de ferro e, conseqüentemente, no sistema de dopamina. [14]

Distúrbio do sono REM

Em situações normais, durante o sono REM, há situação de atonia muscular. No entanto, para pessoas com transtorno do comportamento do sono REM, há movimentos durante esse período do sono. Para [16], a polissonografia é essencial no diagnóstico desse distúrbio.

Distúrbios respiratórios do sono

Há distúrbios do sono que são associados à respiração. Dentre esses, a apneia obstrutiva do sono, a apneia central do sono, a hiperventilação relacionada ao sono e a hipoxemia [18].

3 MATERIAIS E MÉTODOS

Este capítulo descreve os conjuntos de dados e os métodos utilizados para tratamento e pré-processamento. Por fim, discute sobre a implementação dos classificadores e suas métricas. Essa abordagem foi tópico da publicação do autor no Simbópio Brasileiro de Engenharia Biomédica [106].

Para esse trabalho, os dados brutos foram coletados e tratados; em seguida, foram implementados modelos de classificação; estes foram avaliados por meio de métricas de desempenho; esses resultados foram, por fim, analisados e discutidos. A figura abaixo mostra um fluxograma com uma visão geral das etapas do trabalho, evidenciando os artefatos e as atividades de forma sequencial.

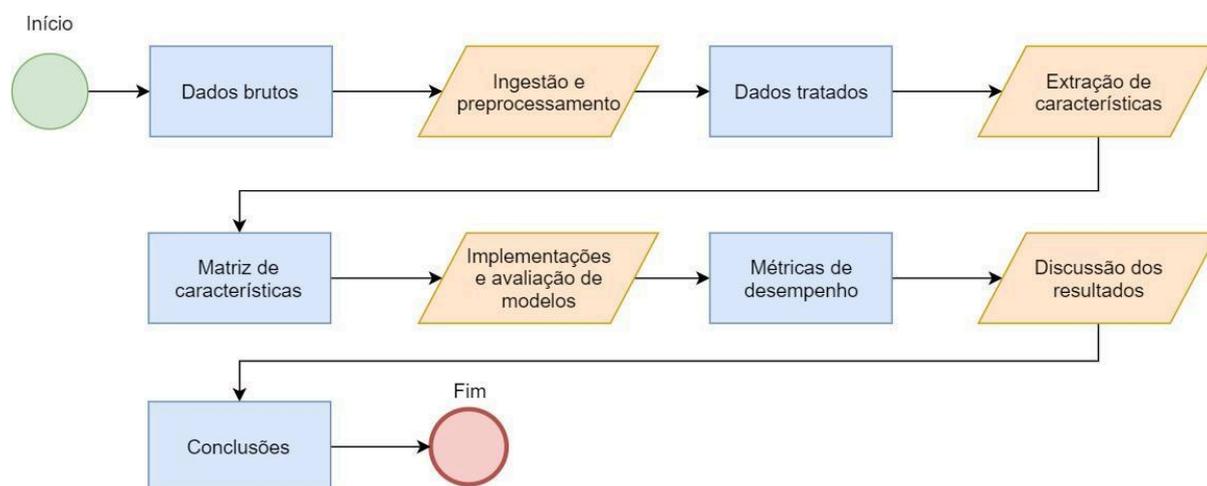


Figura 3.1. Fluxograma com uma visão geral do fluxo de trabalho. Os retângulos azuis representam os artefatos; os paralelogramos em laranja, as tarefas realizadas. Esse fluxo se inicia com a ingestão e pré-processamento dos dados brutos para gerar os dados tratados; a partir da extração de características, é gerada uma matriz de características; são implementados modelos com suas respectivas avaliações que geram resultados a serem avaliados por meio de métricas de desempenho; com isso, são apresentadas as conclusões do trabalho.

3.1 DESCRIÇÃO DO CONJUNTO DE DADOS

O conjunto de dados utilizado nesse trabalho fornece três extensões de arquivos, que estão descritos no quadro 3.1. A extensão “edf” contém os registros da polissonografia – que

são utilizados como base para os experimentos. Além disso, há um arquivo com o sexo e a idade de cada participante e um outro com as anotações de neurologistas.

Quadro 3.1. Descrição geral do conteúdo dos arquivos disponibilizados no conjunto de dados utilizado

Extensão do(s) arquivo(s)	Descrição do conteúdo
edf	Gravações de registros de polissonografia com dados de EEG, EMG e EKG; um arquivo “edf” para cada participante.
xlsx	Planilha com o sexo e idade de cada participante.
txt	Arquivo de texto contendo anotações de neurologistas.

Dentre os participantes, 16 não apresentam patologias neurológicas e estão livres de efeitos de medicamentos que afetem o sistema nervoso central. Os outros 92 participantes são pacientes com algum distúrbio neurológico: 40 diagnosticado com NFLE; 22 afetados por RBD; 10 com PLM; 9 com insônia; 5 com narcolepsia; 4 com SDB; 2 com bruxismo. Essas pessoas são mulheres (42) e homens (65) com idades que variam entre 14 e 80 anos.

Nesse conjunto de dados, os participantes são identificados por um prefixo que identifica a patologia acompanhado de um número. Por exemplo, para o registro “ins1”: o prefixo “ins” informa que é uma pessoa com “insônia”; o número “1” indica que, dentre os indivíduos com insônia, trata-se da pessoa “1”. O quadro abaixo mostra a organização desses arquivos edf por patologia.

Quadro 3.2. Mapeamento dos registros de polissonografia

Nome do grupo ou patologia	Número de participantes	Prefixo	Rótulos dos participantes
Controle (sem patologia)	16	n	n1 - n16
Bruxismo	12	brux	brux1 - brux12
Insônia	9	ins	ins1 - ins9
Narcolepsia	5	narco	narco1 - narco5
Epilepsia noturna do lobo frontal	40	nfle	nfle1 - nfle40
Movimento periódico das pernas	10	plm	plm1 - plm10
Patologia do comportamento REM	22	rbd	rbd1 - rbd22
Sleep-disordered breathing	4	sbd	sbd1 - sbd4

Todos os arquivos e as descrições originais desse conjunto de dados estão disponibilizados no PhysioNet no endereço eletrônico <https://physionet.org/content/capslpdb/1.0.0/>. Esse é um portal que oferece acesso aberto a coleções de dados clínicos e de fisiologia. Sua gestão é realizada por membros do MIT Laboratory for Computational Physiology e apoiado pelo Margret and H. A. Rey Institute for Nonlinear Dynamics do Beth Israel Deaconess Medical Center.

3.2 INGESTÃO, PRÉ-PROCESSAMENTO E EXTRAÇÃO DE CARACTERÍSTICAS

Os primeiros passos para a implementação do projeto do trabalho consistem em atividades de ingestão de dados e pré-processamento. A figura abaixo sumariza esse fluxo.

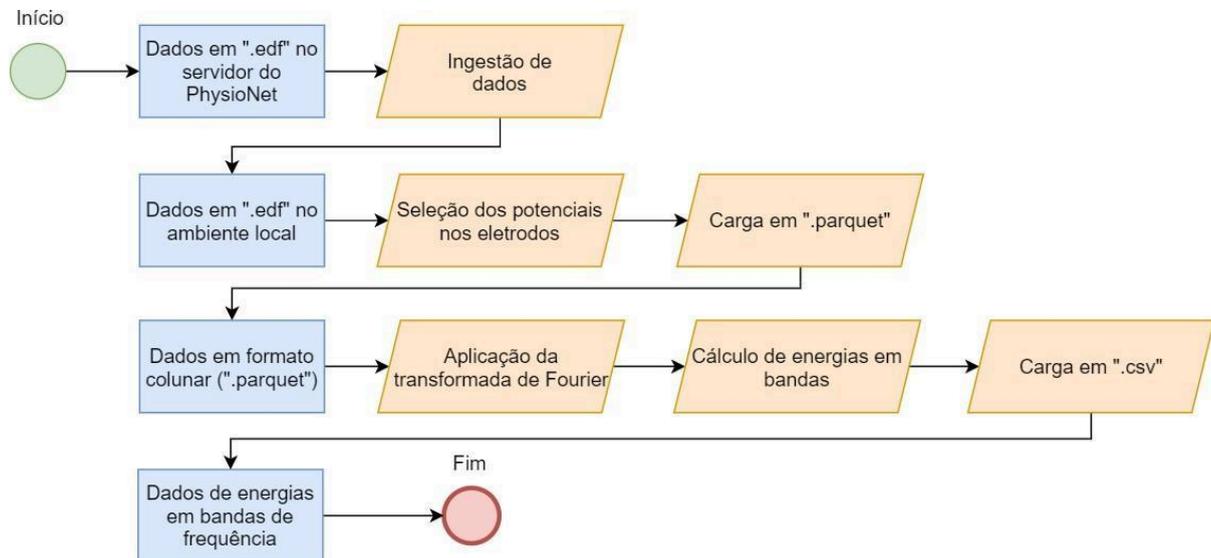


Figura 3.2. Fluxograma de atividades de ingestão e pré-processamento de dados. Os retângulos azuis representam os dados; os paralelogramos em laranja, as tarefas realizadas. Esse processo parte da cópia dos dados de PSG do servidor do PhysioNet para um computador de trabalho; é aplicada uma seleção dos dados de EEG e, em seguida, o resultado é salvo em “.parquet”; é aplicada a transformada de Fourier e, no domínio da frequência, são calculadas as energias em bandas; esses dados são salvos em arquivo “.csv” para análise futura.

O primeiro passo é a ingestão dos dados: fazer uma cópia dos arquivos “.edf” do servidor do PhysioNet para o ambiente local de trabalho - para esse estudo, um notebook com o sistema operacional Windows. Essa cópia permite um acesso mais rápido aos arquivos, por passar a ser um conjunto de dados local e, portanto, independente de acesso à internet e de disponibilidade dos servidores web do PhysioNet. Essa etapa é ilustrada na figura abaixo.

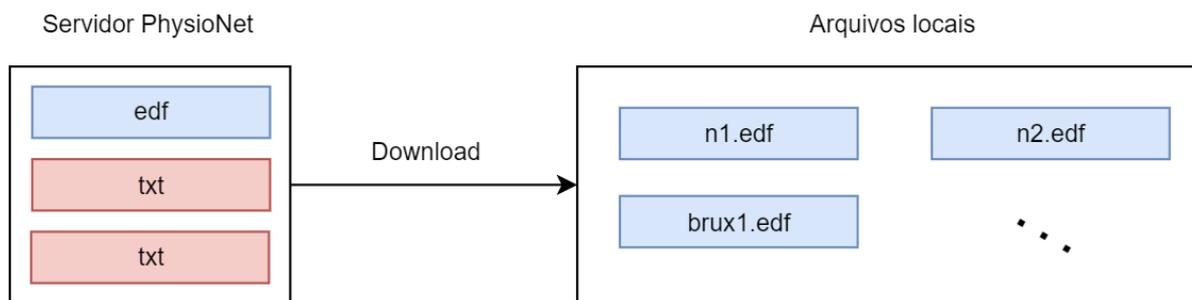


Figura 3.3. Esquema com detalhes da ingestão de dados do servidor da PhysioNet para o ambiente local. Nesse processo, apenas os arquivos “.edf” são copiados para o ambiente local. Os arquivos “.txt” e “.csv” desse servidor não são utilizados nesse trabalho.

Esses arquivos “.edf” contêm dados de potenciais elétricos do EEG, mas também outros dados (como EMG e EKG), além de metadados. Como o escopo é focado em dados de EEG, apenas estes são selecionados. Além disso, considerando que esse processo é lento, essas informações são salvas. Para isso, o formato parquet foi escolhido - considerando que permite maior compactação dos arquivos, sem perda de informação. A biblioteca “MNE” foi utilizada para essa extração dos dados nos arquivos “.edf”, que foram salvos em “parquet” utilizando o Pandas. Essas informações estão no domínio do tempo e com durações distintas. Essa etapa está representada na figura abaixo.

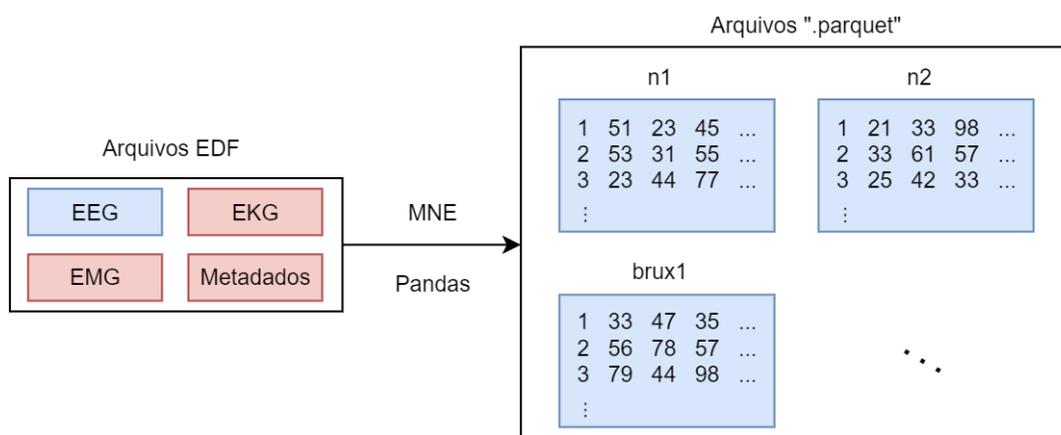


Figura 3.4. Representação da etapa de seleção de dados e de carga em “.parquet”. Apenas as informações sobre o EEG são utilizadas; o EKG, EMG e os metadados, embora façam parte do conteúdo dos arquivos “.edf”, não são utilizados nesse trabalho. Foram utilizadas as bibliotecas “Pandas” e “MNE” para lidar com essa extração. Como resultado, foram gerados arquivos “.parquet” com registros dos potenciais para cada um dos arquivos “.edf” originais.

A extração de características ocorreu por meio da Transformada Rápida de Fourier (FFT, do inglês Fast Fourier Transform). Para isso, . O resultado dessa transformação é um conjunto de dados no domínio da frequência e o respectivo cálculo da energia em cada faixa de frequência. Essa transformação, representada na figura abaixo, permite que os dados de cada participante tenham a mesma dimensão: 60 atributos, cada um representando intensidade de determinada faixa de frequência (as mesmas para todos os participantes). Os resultados são salvos em “.csv” - como os dados são bem menores, é viável armazenar nesse formato, que permite manipulação mais simples sem requerer alto tempo de carregamento.

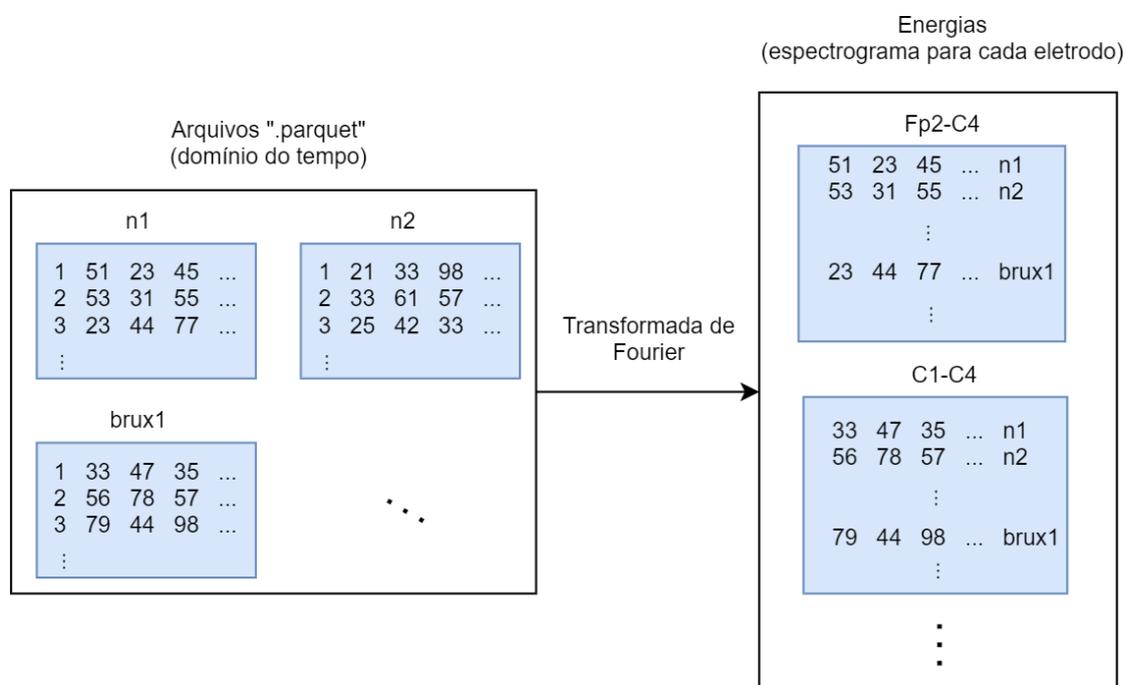


Figura 3.5. Representação da etapa de cálculo das bandas de energia. Nesse processo, foi utilizada a transformada de Fourier para fazer a transformação dos dados que estavam no domínio do tempo (quadro à esquerda) para o domínio da frequência (quadro à direita). Com isso foi gerado o espectrograma para cada derivação.

Cada um desses arquivos “csv” corresponde a um eletrodo. Nestes, cada linha é a distribuição de energia para um participante; em cada coluna, uma bandas de frequência.

De forma complementar, foram realizados experimentos com janelamento do sinal. Para isso, o pré-processamento passou a ter etapas nas quais o sinal (ainda no domínio do tempo) foi segmentado em janelas com intervalos de 10 a 100 segundos de duração.

Fragmentos vizinhos foram sobrepostos em 50%, com a finalidade de minimizar perdas de eventos de transição entre essas janelas. Essas abordagens permitiram a simulação de uma quantidade maior de amostras a partir do conjunto de dados existente.

Outro experimento comparativo foi realizado no domínio da frequência. Foi aplicado um filtro passa-banda: apenas sinais com frequências entre 0.5Hz e 15Hz foram utilizados. Essa frequência foi escolhida considerando que as principais características associadas ao sono estão nessa banda de frequência.

Os eletrodos seguem o padrão “10-20” de montagem do EEG. Esse padrão é reconhecido e recomendado mundialmente. Nesse modelo, são apresentados os pontos para posicionamento dos eletrodos. A figura 3.6 ilustra esse posicionamento. O conjunto de dados utilizado segue esse padrão. Cabe ressaltar que foram escolhidos apenas 4 derivações (diferença de potencial entre dois eletrodos): C4-A1, C4-P3, F4-C4 e P4-O2. Esse seleção de eletrodos foi realizada de modo a maximizar a quantidade de eletrodos e registros: como não há eletrodos em comum para todos os participantes, foram escolhidos esses eletrodos por estarem presentes nos registros de 97 dos 108 participantes.

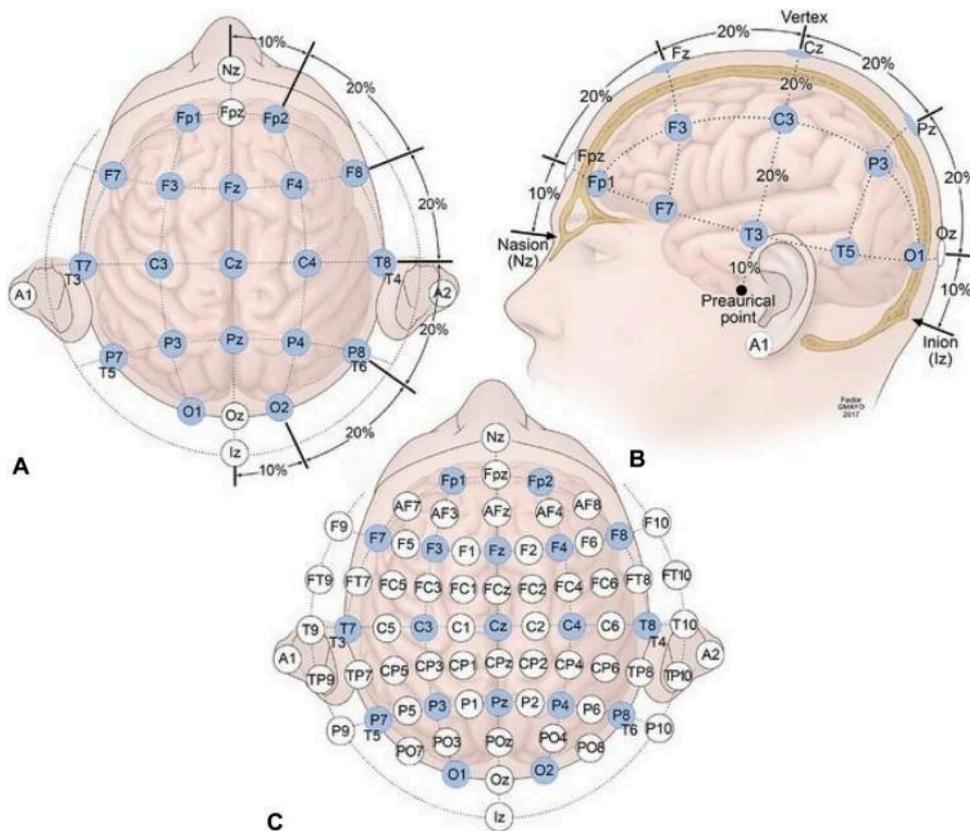


Figura 3.6. Representação do padrão internacional 10-20 de montagem de eletrodos de EEG em humanos. As partes A e B da figura apresentam diferentes perspectivas da mesma montagem; a parte C mostra uma versão estendida do modelo 10-20. Cada círculo representa um eletrodo com sua respectiva denominação no centro de cada círculo. Figura adaptada de [75]

3.3 IMPLEMENTAÇÃO DE CLASSIFICADORES

A partir dos dados tratados, foram implementados esses classificadores em Python: SVM; Random Forest; CNN. Em todos os casos, houve a separação de dados para treino e teste utilizando k-fold, com a finalidade de evitar o sobreajuste do modelo.

Os experimentos comparam diferentes classificadores e cenários de pré-processamento. Os experimentos que comparam classificadores utilizam diferentes algoritmos de classificação e múltiplas combinações de hiperparâmetros: com isso, é possível inferir, dentre as escolhas realizadas, qual é a arquitetura mais otimizada sob a perspectiva de aprendizado de máquina. Por outro lado, os experimentos que comparam cenários utilizam diferentes escolhas de pré-processamento dos dados quanto ao processamento de sinais. Adicionalmente, são comparadas essas abordagens de classificadores utilizando características extraídas por meio de técnicas de processamento de sinais com abordagens utilizando características extraídas pelo classificador (em redes neurais convolucionais). A figura 3.7 mapeia essas comparações realizadas nos experimentos.

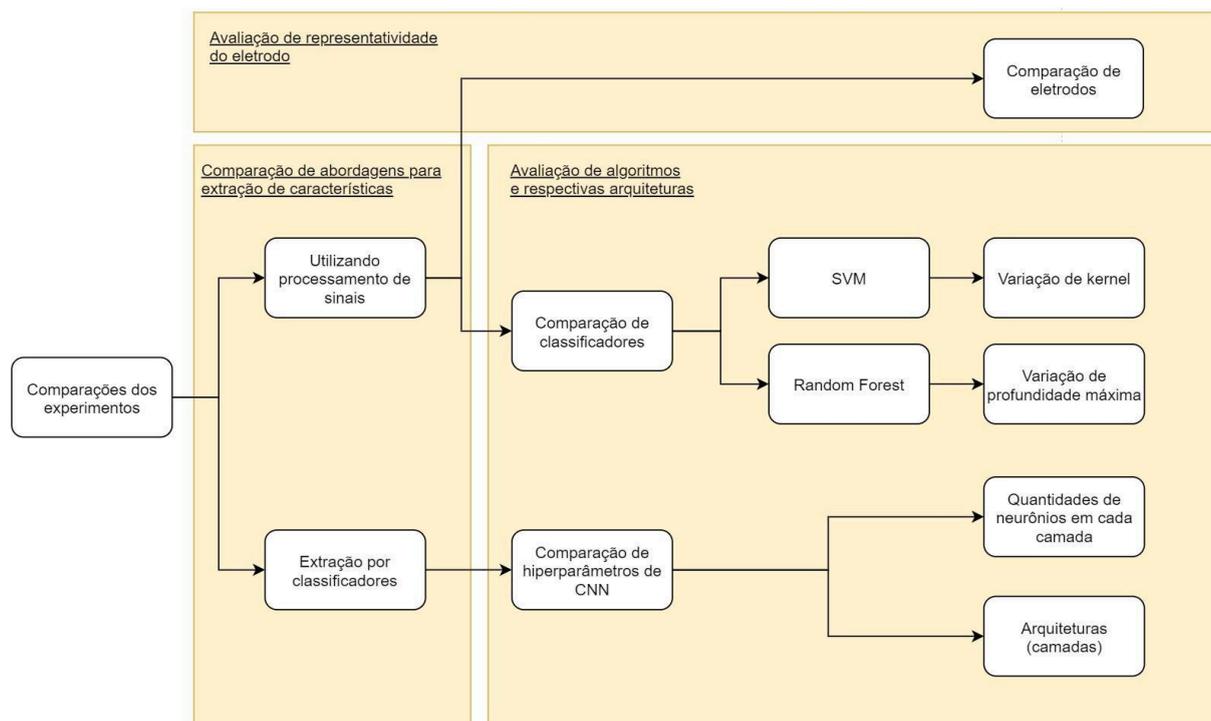


Figura 3.7. Visão geral das comparações de abordagens, algoritmos e arquiteturas utilizadas nos experimentos. São três domínios de comparação: utilizando-se processamento de sinais para extração de características ou com essa extração por parte do classificador. No primeiro caso, há comparação de eletrodos, além da comparação entre utilizar SVM e RF (cada um com vários experimentos comparando alguns hiperparâmetros). No segundo caso, são comparados os experimentos com CNN que se distinguem por seus hiperparâmetros.

Na comparação de algoritmos de classificação, a implementação de SVM e Random Forest foi feita utilizando a biblioteca Scikit Learn. Para cada algoritmo, houve comparação de hiperparâmetros: os modelos com SVM utilizados foram implementados com os kernels baseados em transformação linear, polinomial, RBF e sigmóide; com Random Forest, por outro lado, foram implementados com diferentes valores de profundidade máxima: 1; 2; 5; 10; 15; 25.

Os modelos de CNN foram implementados utilizando a biblioteca Tensor Flow. As arquiteturas variam de acordo com: quantidade e tipo de camadas; quantidade de neurônios em cada camada; filtros.

O experimento consiste em três passos para fazer as comparações dos classificadores, conforme o diagrama da figura 3.8. No primeiro passo, foram comparadas as acurácias de modelos de SVM e RF com diferentes parâmetros usando uma derivação arbitrária de eletrodos (F4-C4). Nesse passo, há variação de kernel (para SVM) e de profundidade (para

RF). A partir desses resultados, foram escolhidos os parâmetros que levam a uma maior acurácia.

No passo seguinte, foram comparadas as outras derivações de eletrodos. Essa comparação pode evidenciar regiões mais relevantes no estudo. No entanto, não é esperado um resultado tão positivo, considerando que a resolução espacial do EEG é baixa.

No último passo desse levantamento inicial, foram implementadas redes neurais convolucionais com diferentes arquiteturas usando CONV1D, com funções de ativação *relu*, *softmax* e *tanh*, com e sem *dropout* – em caso de *dropout*, foi utilizado um valor de 0.5. Foram testados oito modelos com diferentes camadas convolucionais, *pooling* e camadas densas. Essa implementação permite o aprendizado automático das características relevantes dos dados, sem a extração manual realizada nos dados - como foi feito nos dados usados para treinamento dos modelos com SVM e RF.

Uma possível desvantagem da abordagem utilizando redes neurais convolucionais é a maior complexidade. Isso implica em maior necessidade de dados e de custo computacional. Adicionalmente, a escolha das arquiteturas e hiperparâmetros também é um desafio e pode levar a um resultado de desempenho pior.

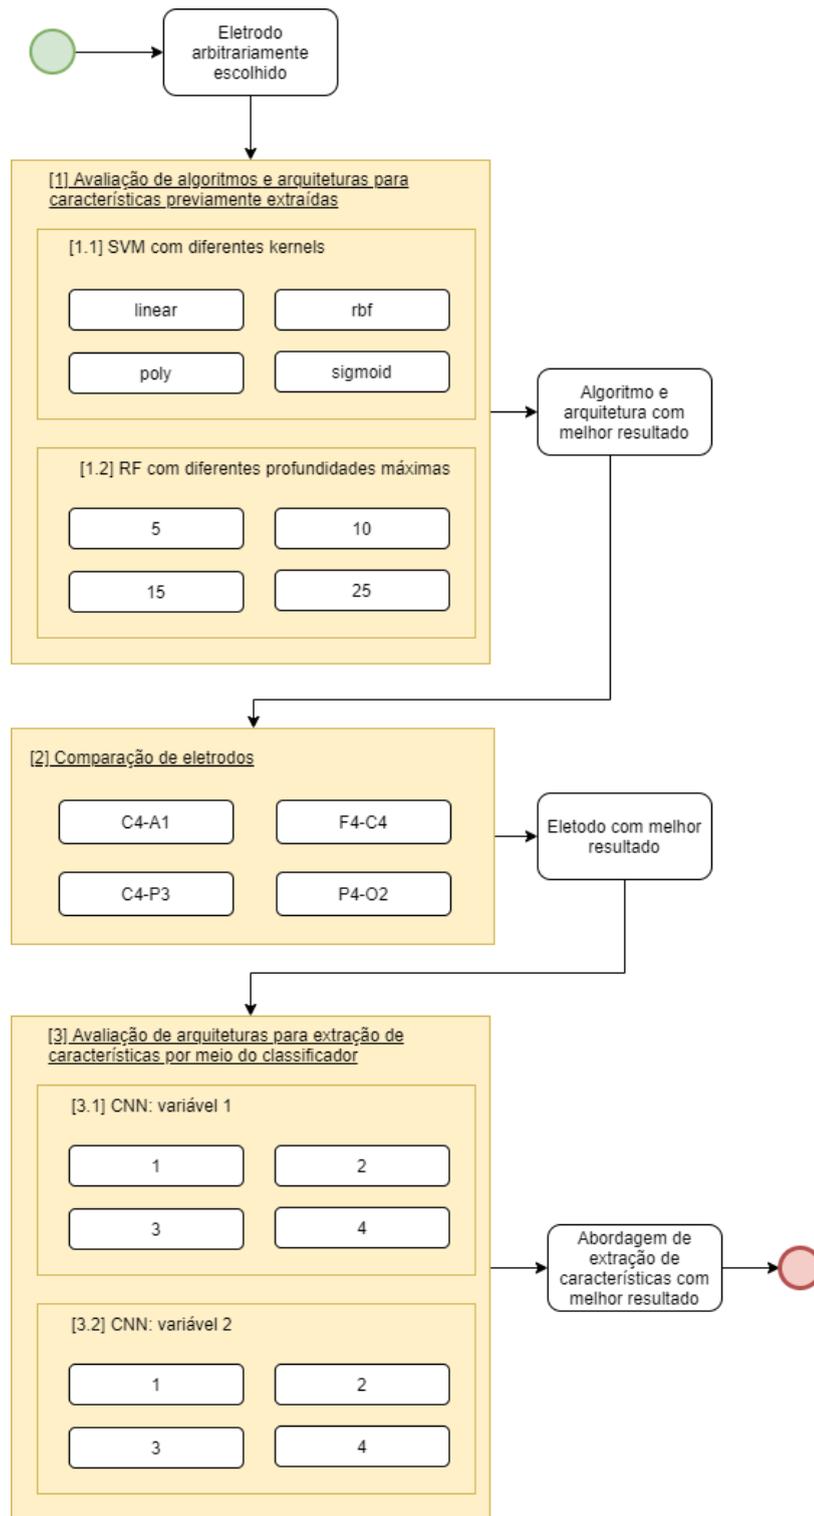


Figura 3.8. Etapas iniciais dos experimentos propostos para o estudo piloto. De início, um eletrodo é escolhido arbitrariamente para a avaliação dos algoritmos no passo (1), no qual são comparadas algumas abordagens utilizando SVM (1.1) e RF (1.2). O algoritmo com o melhor resultado é utilizado na comparação entre diferentes eletrodos (2), não apenas aquele escolhido inicialmente. O eletrodo com o melhor resultado é utilizado na última etapa de avaliação de arquiteturas utilizando CNN.

Esses estudos iniciais apontam as abordagens mais promissoras dentre as escolhidas. Isso direcionou os próximos passos. Assim, foram realizados outros experimentos complementares com a finalidade de comparar outras abordagens. Nesse segundo momento, houve três grupos de experimentos de comparação de resultados dos classificadores: utilizando janelamento no pré-processamento de dados; aplicando filtro passa-banda no pré-processamento; utilizando os canais de ECG a partir dos dados de PSG.

Esse trabalho está focado em sinais de EEG, por ser o padrão ouro no estudo de sono. No entanto, foram incluídos aqueles experimentos com ECG com a finalidade de ter outros valores de referências a partir de dados já existentes na base utilizada para treinamento.

4 RESULTADOS E DISCUSSÕES

Este capítulo apresenta os resultados do trabalho na comparação de diferentes modelos de classificação. Além disso, são comparadas as abordagens utilizando diferentes hiperparâmetros e arquiteturas.

A avaliação foi realizada utilizando classificadores SVM, variando seus parâmetros, e implementando redes neurais com diferentes arquitetura, conforme descrito na metodologia. Os resultados obtidos foram analisados com o foco em avaliar o desempenho dos modelos na tarefa de classificação de patologias relacionadas ao sono.

Inicialmente, não houve janelamento do sinal ou estratégias de reamostragem. Assim, considerando-se a baixa quantidade de participantes, foram utilizados poucas amostras (uma por participantes). Dessa forma, com a finalidade de aumentar o poder de generalização do modelo e de minimizar o viés dos dados no treinamento a partir dessa base desbalanceada, implementou-se um classificador binário (para reduzir a quantidade de classes) para identificação da classe “epilepsia noturna do lobo frontal” (classe com maior quantidade de amostras).

A partir desses resultados iniciais, que estão apresentados do passo 1 ao 3, foram elaborados experimentos complementares. Estes estão apresentados a partir do passo 4.

Seguindo a metodologia proposta, o primeiro passo compara modelos SVM e RF. Em seguida, são comparados diferentes eletrodos. Por fim, as redes neurais convolucionais

4.1 Uso de um eletrodo arbitrário (“F4-C4”) para comparar os melhores parâmetros para SVM e para RF

Os primeiros resultados compararam a acurácia de modelos usando SVM e RF com diferentes parâmetros. Esses são apresentados nas tabelas 4.1 e 4.2. A partir desses resultados, foram escolhidos os parâmetros, baseando-se na maior acurácia.

Tabela 4.1. Comparação de acurácia de modelos utilizando SVM, com a derivação “F4-C4” e variando o kernel. Para cada experimento, foi calculada a média de acurácia e o respectivo desvio padrão. A derivação do eletrodo foi mantida constante: F4-C4, com a finalidade de haver a variação de apenas uma variável (o núcleo da SVM).

Experimento	Eletrodo	Classificador	Núcleo	Acurácia média	Desvio padrão da acurácia
1	F4-C4	SVM	Linear	0.608	0.020
2	F4-C4	SVM	Polinomial	0.587	0.034
3	F4-C4	SVM	RBF	0.608	0.020
4	F4-C4	SVM	Sigmóide	0.608	0.020

Tabela 4.2. Comparação de acurácia de modelos utilizando RF, com a derivação “F4-C4” e variando a profundidade das árvores. Para cada experimento, foi calculada a média de acurácia e o respectivo desvio padrão. A derivação do eletrodo foi mantida constante: F4-C4, com a finalidade de haver a variação de apenas uma variável (o núcleo da SVM).

Experimento	Eletrodo	Classificador	Profundidade	Acurácia média	Desvio padrão da acurácia
1	F4-C4	RF	1	0.608	0.020
2	F4-C4	RF	5	0.567	0.062
3	F4-C4	RF	10	0.567	0.070
4	F4-C4	RF	15	0.567	0.070

Para a SVM, os núcleos baseados em transformações lineares, polinomiais e sigmóides forneceram resultados equivalentes em termos de acurácia. Dentre esses, foi escolhido o núcleo baseado em transformações polinomiais: o linear é mais simples e pode gerar sobreajuste; no entanto, não escolher o sigmoid foi uma escolha arbitrária.

A comparação de acurácia dos modelos usando RF, por sua vez, mostrou que o classificador com profundidade 1 teve melhor acurácia. Isso indica que a escolha da profundidade das árvores no RF pode ser um fator decisivo no desempenho desse classificador.

4.2 Comparação dos eletrodos de EEG para efeito da classificação dos sinais em NFLE

A partir desses resultados para a SVM e RF, sintetizados nas tabelas 1 e 2, foram comparados os resultados utilizando diferentes eletrodos em novos classificadores utilizando os parâmetros escolhidos no passo 1. Os resultados de acurácia não foram alterados com as variações de eletrodos.

De uma forma geral, esse resultado sugere dois pontos. Os parâmetros escolhidos no primeiro passo podem ser robustos o suficiente para lidar com as características dos dados. Outro ponto: a escolha desses eletrodos pode não ser crítica para a tarefa de classificação - os sinais podem ser distribuídos de forma espacialmente homogênea.

Nesse sentido, cabe ressaltar a resolução do EEG. Embora a resolução temporal do EEG seja boa quando comparada, por exemplo, ao MRI, sua resolução espacial é inferior. Esse aspecto pode fundamentar a independência do eletrodo nos resultados.

Além disso, é possível que haja variação nos resultados entre outros eletrodos em outras áreas além das estudadas. Como foram comparadas apenas 4, é possível haver similaridade entre esses sinais.

4.3 Comparação com Redes Neurais Convolucionais para efeito da classificação dos sinais em NFLE

Em seguida, foi implementada uma rede neural convolucional com diferentes camadas convolucionais em domínio unidimensional, com funções de ativação *RELU*,

Softmax tangente hiperbólica, com e sem *dropout* (0.5). A tabela 4.3 descreve as arquiteturas utilizadas.

Tabela 4.3. Arquiteturas e hiperparâmetros utilizados nos modelos de redes neurais convolucionais

Modelo	Camadas Convolucionais	Funções de Ativação	<i>Dropout</i>	Pooling	Camadas Densas
1	2	ReLU	0.5	MaxPooling	2
2	1	Softmax	-	-	1
3	1	Tanh	-	-	1
4	1	Tanh	-	-	2
5	1	Tanh	-	-	2
6	3	Tanh, Sigmoid	0.5	MaxPooling	2
7	1	Tanh	-	-	1
8	1	Tanh	-	-	1

Todos os modelos classificavam os dados apenas em uma das classes. Isso é um indicativo de que o modelo não consegue aprender características das classes dos dados.

Uma possível razão para isso é a falta de informações discriminatórias suficientes nos dados. Como a janela de tempo de amostragem foi curta, os dados de treino não apresentam informações adequadas. Outro possível motivo é a escolha da arquitetura: camadas, número de filtros, função de ativação e taxa de *dropout*.

O desbalanceamento das classes é outro motivo que pode ter contribuído com esse problema. Como há desbalanceamento, o modelo pode se tornar viciado para a classe majoritária e ter dificuldades em reconhecer padrões de casos da outra classe. Esse cenário sugere o teste de abordagens que consideram o desbalanceamento, como o RUSBoost [105].

4.4 Avaliação de ajustes na fase de pré-processamento

A partir desse passo, os experimentos utilizaram os classificadores com base o SVM e RF, que apresentaram melhores resultados nos estudos preliminares. Além disso, com a finalidade de ser mais rigoroso com as métricas, os resultados passaram a avaliar também a precisão, a sensibilidade e a métrica f1. As classificações – que, até o passo 3 eram binárias – passaram a ser multiclasse (cada classe é uma patologia ou o controle).

A motivação para esse passo 4 é a pequena quantidade de dados disponíveis. Isso pode gerar dificuldades para o treinamento dos modelos. Assim, com a finalidade de melhorar os resultados obtidos nos estudos preliminares, foi implementado o janelamento do sinal na etapa de pré-processamento de dados.

Nesses experimentos, três parâmetros foram estabelecidos. A quantidade de janelas utilizadas no treinamento variou de 5 a 50; o tamanho de cada janela, de 5 a 100 segundos; e a taxa de sobreposição entre janelas vizinhas com um valor fixo de 50%.

Os resultados dessa fase foram positivos. Houve melhoria nas métricas de desempenho utilizadas. Os melhores resultados para a narcolepsia do lobo frontal obteve uma média de acurácia de 0.63 e 0.59 de métrica f1.

4.5 Outras investigações no processo de extração de características do sinal e treinamento do modelo de classificação

Durante o processo de investigação, outros experimentos pontuais foram realizados. Dentre esses, o uso de dados de canais de ECG. Embora o foco do trabalho seja em EEG (padrão ouro na identificação de neuropatologias relacionadas ao sono), os dados de ECG estavam disponíveis no conjunto de dados utilizados nessa pesquisa. Os resultados dos experimentos com o uso desses canais em conjunto não apresentou melhorias significativas.

Por fim, os modelos foram treinados com o uso de RUSBoost. Esperava-se uma melhoria, considerando o desbalanceamento dos dados. No entanto, essa abordagem também não mostrou melhoria na acurácia.

4.6 Discussão final e trabalhos futuros

Nossos resultados preliminares estão alinhados com a natureza complexa dos sinais de EEG e com os desafios que surgem na detecção de mudanças sutis que podem significar patologias específicas relacionadas ao sono. Detectar tais mudanças usando características

espectrais previamente extraídas, em vez de treinar uma CNN para classificar os sinais de EEG em formato bruto, parecia viável, pelo menos para o número relativamente baixo de sinais de treinamento disponíveis.

O uso de classificadores de aprendizado de máquina, especialmente SVM e RF, tem se mostrado promissor no discernimento de diferenças entre grupos de controle e experimentais, com base nas características espectrais propostas do EEG. Isso destaca o potencial dos modelos de aprendizagem de máquina na automatização da detecção e classificação de distúrbios do sono, que tradicionalmente dependem de análises especializadas. Uma implicação significativa deste estudo, que pode ser particularmente promissora para investigações futuras, é a robustez observada nos parâmetros escolhidos em diferentes eletrodos. Isso sugere que as características do EEG relevantes para distinguir a NFLE podem ser representadas uniformemente em várias regiões do escalpo, proporcionando flexibilidade na escolha do eletrodo e abrindo caminho para ferramentas de diagnóstico mais escaláveis.

Além disso, os resultados preliminares indicam que o número e a localização dos eletrodos podem não ser fatores críticos nessa tarefa de classificação, dada a homogeneidade dos dados em todo o escalpo. Isso pode ser especialmente importante em locais onde os recursos ou equipamento técnico podem ser limitados. No entanto, ainda é necessária uma análise mais extensa, incorporando mais eletrodos de várias regiões.

O desempenho das redes neurais convolucionais (CNNs) destacou um desafio bem conhecido no aprendizado de máquina: a necessidade de vastos conjuntos de dados para treinar esse modelo. As CNNs, que obtiveram grande sucesso em outros estudos, parecem ter um desempenho inferior nessa tarefa específica de classificação de EEG, devido ao conjunto de dados limitado, destacando a importância do tamanho e da qualidade dos dados de treinamento ao selecionar um modelo de aprendizado de máquina.

5 CONCLUSÃO

Esse trabalho apresentou uma comparação entre abordagens para implementação de classificadores de sinais de EEG. Foram exploradas aplicações de algoritmos de aprendizado de máquina na classificação de epilepsia noturna do lobo frontal (patologia relacionadas ao sono) a partir de dados de EEG de PSG. Os modelos utilizaram SVM, RF e CNN com o objetivo de avaliar o desempenho na tarefa de classificação.

A metodologia proposta foi composta por três passos iniciais. O primeiro compara SVM e RF; o segundo, diferentes eletrodos; o terceiro utiliza diferentes arquiteturas para uma CNN. Nos resultados, foi possível observar que a escolha dos eletrodos não refletiu alteração significativa nos resultados que usam SVM e RF – sugerindo que a distribuição espacial da informação é homogênea ou que as características utilizadas por esses classificadores são robustas o suficiente para identificar os padrões das classes. A CNN, por outro lado, não conseguiu distinguir as classes – possivelmente por conta do desbalanceamento das classes ou pela quantidade de registros utilizados.

Esses resultados mostraram haver uma oportunidade de trabalho com SVM e RF. Os classificadores utilizando essas abordagens conseguiram identificar características das duas classes; além disso, foi identificado que alguns hiperparâmetros interferem no desempenho. Por outro lado, os classificadores que utilizaram a CNN não distinguiram os grupos.

A partir desses experimentos iniciais, foram realizados outros utilizando-se SVM e RF. Para isso, foram aplicadas amostragens do sinal na etapa de pré-processamento dos dados. Houve variação de quantidade de janelas (5 a 50) e de tamanho de cada uma dessas (de 5 a 100 segundos). Houve uma melhoria nos resultados: a acurácia média aumentou para 0.63.

Diante disso, é possível afirmar que as técnicas de aprendizado de máquina têm relevância e potencial de aplicação para o diagnóstico de patologias do sono. A metodologia proposta neste estudo preliminar pode ser aplicada no desenvolvimento de soluções de classificadores para esse propósito.

LISTA DE REFERÊNCIAS

- [1] Hirshkowitz M. Polysomnography Challenges. *Sleep Med Clin*, 11(4):403-411, Dezembro de 2016.
- [2] Raj, A.; Bosch, J; Olsson, H. H. & Wang, T. J. 46th Euromicro Conference on Software Engineering and Advanced Applications (SEAA): Modelling Data Pipelines, 2020.
- [3] PURVES, D. et al. Neurociências. 4ª ed. Artmed: 2010.
- [4] Keene, A. C.; Duboue, E. R. The origins and evolutions of sleep. *The Journal of Experimental Biology*, v. 221, n. 11, 2018.
- [5] BEAR, M. F., BARRY, B. W., PARADISO, M. A. Neurociências: desvendando o sistema nervoso. 4ª ed. Artmed: 2017.
- [6] GÉRON, A. Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow. 2ª ed. O'Reilly Media, 22 de outubro de 2019.
- [7] Lobbezoo, F. et al. Bruxism defined and graded: an international consensus. *Journal of Oral Rehabilitation*, p. 2-4, n. 40, v. 1, 2012.
- [8] Cunnington, D.; Junge, M. F.; Fernando. Insomnia: prevalence, consequences and effective treatment. A. T. *The Medical Journal of Australia*, n. 199, v. 8, p 36-40, 2013.
- [9] Baglioni, C. et al. Insomnia as a predictor of depression: A meta-analytic evaluation of longitudinal epidemiological studies. *Journal of Affective Disorders*, n. 135, p 10-19, 2011.
- [10] Vozoris, N. T. The relationship between insomnia symptoms and hypertension using United States population-level data. *Journal of Hypertension*, p. 663-671, n. 31, v. 4, 2013.
- [11] Mahoney, C. E. et al. The neurobiological basis of narcolepsy. *Nature Reviews Neuroscience*, p. 93-93, n. 20, v. 2, 2018.
- [12] Silber, M. H.; Krahn, L. E.; Olson, E. J.; & Prankratz, V. S. The epidemiology of Narcolepsy in Olmsted County, Minnesota: a population-based study. *Sleep*, p. 197-202, n. 25, v. 2, 2002.
- [13] Ryvlin, P.; Rheims, S.; & Risse, G. Nocturnal Frontal Lobe Epilepsy. *Epilepsia*, p. 83-86, n. 47, v. s2, 2006.
- [14] Hening, W. The clinical neurophysiology of the restless legs syndrome and periodic limb movements. *Clinical Neurophysiology*, v. 115, n. 9, p. 1965-1974, 2004.
- [15] Zucconi, M.; & Ferini Strambi, L. NREM parasomnias: arousal disorders and differentiation from nocturnal frontal lobe epilepsy. *Clinical Neurophysiology*, v. 111, p. 129-135, 2000.

- [16] Antelmi, E.; Lippolis, M.; Biscarini, F.; Tinazzi, M.; & Plazzi, G. REM sleep behavior disorder: Mimics and variants. *Sleep Medicine Reviews*, 2021.
- [17] Foldvary-Shaefer, N. R., & Waters, T. E. Sleep-Disordered Breathing. *Continuum: Lifelong Learning in Neurology*, v. 23, n. 4, p. 1093-1116, 2017.
- [18] OPPENHEIM, A. V.; WILLISKY, A. S. Sinais e Sistemas. Editora Pearson, 2º edição, 2010.
- [19] Ho, Ti. K. Random decision forests. *Proceedings of 3rd International Conference on Document Analysis and Recognition*, p. 278-282, Agosto de 1995.
- [20] Luo, C. et. al. Locating Facial Landmarks Using Probabilistic Random Forest. *IEEE SIGNAL PROCESSING LETTERS*, n. 12, v. 22, 2015.
- [21] Pellegrino, E. et al. Machine learning random forest for predicting oncosomatic variant NGS analysis. *Science Reports*, n. 11, 2021.
- [22] Bosch, A.; Zisserman, A.; Muñoz, X. Image classification using random forest and ferns. *IEEE 11th International Conference on Computer Vision*, 2007.
- [23] Klok, A. B. et al. A new fully automated random forest algorithm for sleep staging. *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2018.
- [24] LOUIS, E.D.; MAYER, S.A.; ROWLAND, L.P.; Merritt - Tratado de Neurologia. Editora Guanabara Koogan, 13ª edição, 2018.
- [25] Sazgar, M. & Young, M. G. EEG Artifacts. *Absolute Epilepsy and EEG Rotation Review*, n 149-162, 2019.
- [26] SMITH, S. W. Audio Processing. Digital Signal Processing. Elsevier, 2003. p. 315-372.
- [27] Boyat, A. K.; Joshi, B. K. A review paper: noise models in digital image processing. Signal and Image Processing. *An International Journal (SIPIJ)*, v. 6, n. 2, 2015.
- [28] DINIZ, P. S. R.; SILVA, E. A. B.; NETTO, S. L. Processamento digital de sinais: projeto e análise de sistemas. Bookman, 2ª edição, 2014.
- [29] Nyquist, H. Certain topics in telegraph transmission theory. *AIEE Transactions*, p. 617, 1928.
- [30] Shannon, C. Communication in the presence of noise. *Proceedings of the IRE*, p. 10-21, 1949.
- [31] BUTKOV, E. Física Matemática. LTC, 1ª edição, 1978.
- [32] ARFKEN, G. B. ; WEBER, H. Física matemática: métodos matemáticos para engenharia e física. Elsevier Editora Ltda, 6ª edição, 2007.
- [33] GRUS, J. Data Science Do Zero: Noções Fundamentais com Python. Alta Books, 2ª edição, 2021.
- [34] Breiman, L. Bagging Predictors. *Machine Learning*, v. 24, n. 2, p 123-140, 1996.

- [35] Angra, S.; & Ahuja, S. Machine Learning and its applications: A review. *International Conference on Big Data Analytics and Computational Intelligence (ICBDAC)*, 2017.
- [36] Kubat, M.; Holte, R. C.; & Matwin, S. Machine Learning for the Detection of Oil Spills in Satellite Radar Images. *Machine Learning*, v. 30, n. 2, p. 195-215, 1998.
- [37] Otukei, J. R.; & Blaschke, T. Land cover change assessment using decision trees, support vector machines and maximum likelihood classification algorithms. *International of Applied earth Observation and Geoinformation*, n. 12, 2010.
- [38] DeGregory, K. W. et al. A review of machine learning in obesity. *Obesity Reviews*, n. 19, v. 5, p. 668-285, 2018.
- [39] Deo, R. C. Machine Learning in medicine. *Circulation*, n. 132, v. 20, p. 1920-1930, 2015.
- [40] Gupta, R. et al. Artificial intelligence to deep learning: machine intelligence approach for drug discovery. *Molecular Diversity*, n. 25, v. 3, p. 1315-1360, 2021.
- [41] Abbasi, D.; & Goldenholz, D. M. Machine Learning applications in epilepsy. *Epilepsia*, n. 60, p. 2037-2047, 2019.
- [42] Elgart, M.; Redline, S.; & Sofer, T. Machine and Deep Learning in Molecular and Genetic Aspects of Sleep Research. *Neurotherapeutics*, n. 18, p. 228-243, 2021.
- [43] Halevy, A.; Norvig, P.; & Pereira, F. The Unreasonable Effectiveness of data. *IEEE Intelligent Systems*, v. 24, n. 2, p. 8-12, 2009.
- [44] Bilbao, I.; & Bilbao, J. Overfitting problem and the over-training in the era of data: particularly for Artificial Neural Networks. *Eighth International Conference on Intelligent Computing and Information Systems (ICICIS)*, 2017.
- [45] COOK, D. Practical Machine Learning with H2O: Powerful, Scalable Techniques for Deep Learning and AI. O'Reilly, 1ª edição, 2016.
- [46] PROVOST, F.; FAWCETT, T. Data Science para negócios: o que você precisa saber sobre mineração de dados e pensamento analítico de dados. 1ª edição. Rio de Janeiro: Editora Alta Books, 2016.
- [47] TORTORA, G. T.; DERRICKSON, B. Princípios de Anatomia e Fisiologia. 14ª Edição. Rio de Janeiro: Guanabara Koogan, 2016.
- [48] Gentry, N.; Ashbrook, L. H.; Fu, Y. H.; Ptacek, L. J. Human circadian variations. *The Journal of Clinical Investigation*, v. 131, n. 16, 2021.
- [49] Haxshiu, M. A. et al. CNS Determinants of Sleep-related Worsening of Airway Functions: Implications for Nocturnal Asthma. *Respiratory Physiology and Neurobiology*, 2006.
- [50] Logan, R. W., McClung, C. A. Rhythms of life: circadian disruption and brain disorders across the lifespan. *Nature Reviews Neuroscience*, 2018.
- [51] Spaeth, M.; Rizzi, M.; Sarzi-Puttini, P. Fibromyalgia and sleep. *Best Practice and Research Clinical Rheumatology*, 2011.

- [52] Drakatos, P. et al. Periodic limb movements during sleep: a narrative review. *Journal of Thoracic Disease*, 2021.
- [53] Whitehurst, L. N. et al. Links between the brain and body during sleep: implications for memory processing. *Trends in Neurosciences*, 2022.
- [54] TAVARES, A. et al. Medicina do sono: diagnóstico e manejo. 1ª edição. Porto Alegre: Artmed, 2023.
- [55] Berger, H. Über das Elektrenkephalogramm des Menschen. *European Archives of Psychiatry and Clinical Neuroscience*, 1929.
- [56] Berry, r.; Quan, S. Abreu, A. The AASM manual for scoring of sleep and associated events. *Darien: American Academy of Sleep Medicine*, 2020.
- [57] KANDEL, E. R. et al. Princípios de neurociências. 5ª edição. Porto Alegre: Artmed, 2014.
- [58] Borbély, A. A. A two-process model of sleep regulation. *Human Neurobiology*, n. 1, p. 195-204, 1982.
- [59] Jafari, B.; Mohsenin, V. Polysomnography. *Clinics in chest medicine*, v. 31, n. 2, p. 287-297, 2010.
- [60] R. Matheus, M. Janssen e D. Maheshwari. Data science empowering the public: Data-driven dashboards for transparent and accountable decision-making in smart cities. *Government Information Quarterly*, p. 101-284, 2018.
- [61] J. G. Stadler, K. Donlon, J. D. Siewert, T. Franken e N. E. Lewis. Improving the efficiency and ease of healthcare analysis through use of data visualization dashboards. *Big Data*, v. 4, n. 2, p. 129–135, 2016.
- [62] G. Gautam e D. Yadav. Sentiment analysis of twitter data using machine learning approaches and semantic analysis in Seventh International Conference on Contemporary Computing (IC3). *IEEE*, p. 437–442, 2014.
- [63] S. M. S. Tanzil, W. Hoiles e V. Krishnamurthy. Adaptive scheme for caching Youtube content in a cellular network: Machine learning approach. *IEEE Access*, v. 5, p. 5870–5881, 2017.
- [64] P. Covington, J. Adams e E. Sargin. Deep neural networks for Youtube recommendations. *Proceedings of the 10th ACM conference on recommender systems*, p. 191–198, 2016.
- [65] L. Deng, J. Li, J.-T. Huang, K. Yao, D. Yu, F. Seide, M. Seltzer, G. Zweig, X. He, J. Williams et al. Recent advances in deep learning for speech research at Microsoft in 2013 IEEE International Conference on Acoustics, Speech, and Signal Processing. *IEEE*, p. 8604–8608, 2013.
- [66] Lavigne GJ, Manzini C, Kato T. Sleep bruxism. In: Kryger MH, Roth T, Dement WC, eds. Principles and practice of sleep medicine. 4ª edição. Philadelphia: Elsevier Saunders, p. 946–959, 2005.
- [67] Paesani DA. Bruxism theory and practice. New Malden, UK: Quintessence Publishing Co., Ltd, 2010.

- [68] PORTO, C. C.; PORTO, A. L. Exame clínico. 7ª edição. Guanabara Koogan, 2012
- [69] Chishti, S. et al. Artificial Intelligence-Based Differential Diagnosis: Development and Validation of a Probabilistic Model to Address Lack of Large-Scale Clinical Datasets. *Journal of Medical Internet Research*, 2020.
- [70] Global Health Observatory (GHO) Data. World Health Organization; 2023 <<https://www.who.int/data/gho/data/themes/topics/health-workforce>>
- [71] Zhao, W. et al. EEG spectral analysis in insomnia disorder: a systematic review and meta-analysis. *Sleep Medicine Reviews*, 2021.
- [72] Appleton, S. L. et al. Quantitative electroencephalography measures in rapid eye movement and nonrapid eye movement sleep are associated with apnea-hypopnea index and nocturnal hypoxemia in men. *Sleep*, 2019.
- [73] Ukhinov, E. B. et al. Features of the EEG pattern of sleep spindles and its diagnostic significance in ontogeny. *Bulletin of Experimental Biology and Medicine*, 2022.
- [74] Gu, y.; Gagnon, J. F.; Kaminska, M. Sleep electroencephalography biomarkers of cognition in obstructive sleep apnea. *Journal of Sleep Research*, 2023.
- [75] Feyissa, A. M.; & Tatum, W. O. Adult EEG. *Handbook of Clinical Neurology*. Elsevier, p. 103-124, 2019.
- [76] Payne, P. R. O. et al. Conceptual knowledge acquisition in biomedicine: a methodological review. *Journal of Biomedical Informatics*, 2007.
- [77] Sandelowski, M. Troubling distinctions: a semiotics of the nursing/technology relationship. *Nursing Inquiry*, v. 6, p.198-207, 1999.
- [78] Gelisse, P.; Genton, p.; Crespel, A.; & Lefevre, P. H. Will MRI replace the EEG for diagnosis of nonconvulsive status apipepticus, especially focal? *Revue Neurologique*, v. 177, p. 359-369, 2022.
- [79] Bandyopadhyay, A.; Goldstein, C. Clinical applications of artificial intelligence in sleep medicine: a sleep clinician's perspective. *Sleep and Breathing*, v. 27, p. 39-55, 2023.
- [80] Boostani, R.; Karimzadeh, F.; Nami, M. A comparative review on sleep stage classification methods in patients and healthy individuals. *Computer Methods and Programs in Biomedicine*, v. 140, p. 77-91, 2017.
- [81] Mutasa, S.; Sun, S.; Ha, R. Understanding artificial intelligence based radiology studies: CNN architecture. *Clinical Imaging*, v. 80, p. 72-76, 2021.
- [82] Fan, X.; Feng, X.; Dong, Y.; Hou, H. COVID-18 CT image recognition algorithm based on transformer and CNN. *Displays*, v. 72, 2022.
- [83] El Moaquet, H. et al. A deep transfer learning framework for sleep stage classification with single-channel EEG signals. *Sensors*, v. 22, 2022.
- [84] Orsulic, S.; John, J.; Walts, A. E.; Gertych, A. Computational pathology in ovarian cancer. *Frontiers in Oncology*, v. 12, 2022.

- [85] Gong, Y.; Liao, B.; Wang, P.; Zou, Q. DrugHybrid_BS: Using hybrid feature combined with bagging-SVM to predict potentially druggable proteins. *Frontiers in Pharmacology*, v. 12, 2021.
- [86] Huang, S. et al. Applications of support vector machine (SVM) learning in cancer genomics. *Cancer Genomics & Proteomics*, v. 15, n. 1, p. 41-51, 2018.
- [87] Liu, T.; Wang, Z. MASS: predict the global qualities of individual protein models using random forests and model statistical potentials. *BMC Bioinformatics*, v. 21, 2020.
- [88] Lafta, R. et al. Fast Fourier Transform ensemble model to classify epileptic EEG signals. *IEEE International Conference on Big Data*, 2022.
- [89] Zabidi, A. et al. Short-time Fourier Transform analysis of EEG signal generated during imagined writing. *International Conference on System Engineering and Technology (ICSET)*, 2012.
- [90] Amin, H. U. et al. EEG feature extraction with Fast Fourier Transform for investigating different brain regions in cognitive and reasoning activity. *IEEE 5th International Symposium in Robotics and Manufacturing Automation (ROMA)*, 2022.
- [91] Garcia, G. N.; Ebrahimi, T.; Vesin, J. M. Support vector EEG classification in the Fourier and time-frequency correlation domains. *First International IEEE EMBS Conference on Neural Engineering*, 2003.
- [92] Nguyen, V. D. et al. A combination of Fourier Transform and machine learning for fault detection and diagnosis of induction motors. *8th International Conference on Dependable Systems and Their Applications (DSA)*, 2021.
- [93] Zhang, J. et al. Coupling a Fast Fourier Transformation with a machine learning ensemble model to support recommendations for heart disease patients in a telehealth environment. *IEEE Access*, v. 5, 2017.
- [94] Killgore, W. D. S. Effects of sleep deprivation on cognition. *Progress in Brain Research*, v.185, 2010.
- [95] Lo, J. C. et al. Sleep deprivation increases formation of false memory. *Journal of Sleep Research*, v. 25, n. 6, p. 673-682, 2016.
- [96] Pace-Schott, E. F.; & Hobson, J. A. The Neurobiology of sleep: genetics, cellular physiology and subcortical networks. *Nature Reviews Neuroscience*, v. 3, n. 8, p. 591-605, 2002.
- [97] Lane, J. M. et al. Genetics of circadian rhythms and sleep in human health and disease. *Nature Reviews Genetics*, v. 24, p. 4-20, 2023.
- [98] Jones, B. E. Principal cell types of sleep-wake regulatory circuits. *Current Opinion in Neurobiology*, v. 44, p. 101-109, 2017.
- [99] Hobson, J. A.; & Pace-Schott, E. F. The cognitive neuroscience of sleep: neuronal systems, consciousness and learning. *Nature Reviews Neuroscience*, v. 3, v. 9, p. 679-693, 2002.

- [100] Volner, K.; Chao, S.; Camacho, M. Dynamic sleep MRI in obstructive sleep apnea: a systematic review and meta-analysis. *European Archives of Otorhino-Laryngology*, 2021.
- [101] Foschi, M. et al. Sleep-related disorders and their relationship with MRI findings in multiple sclerosis. *Sleep Medicine*, v. 56, p. 90-97, 2019.
- [102] Stein, P. K.; & Pu, Y. Heart rate variability, sleep and sleep disorders. *Sleep Medicine Reviews*, v. 16, n. 1, p. 47-66, 2012.
- [103] Ajit, A.; Acharya, K.; Samanta, A. A review of convolutional neural networks. 2020 *International Conference of Emerging Trends in Information Technology and Engineering*, 2020.
- [104] McCulloch, W. S., & Pitts, W. A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, v. 5, n. 4, p. 115-133.
- [105] Seiffert, C. et al. RUSBoost: Improving classification performance when training data is skewed. *IEEE: 2008 19th International Conference on Pattern Recognition*, 2008.
- [106] Souza, A; Soares, F.; Miosso, Cristiano. Preliminary evaluation of a machine-learning based characterization of electroencephalogram patterns in sleep-related pathologies. *SEB 2023: XV Simpósio de Engenharia Biomédica*. 2023.
- [107] Gonzales, R. C. Deep Convolutional Neural Networks. *IEEE Signal Processing Magazine*, v. 25, n. 6, p. 79-97, 2018.