

UNIVERSIDADE ESTADUAL DE CAMPINAS
INSTITUTO DE COMPUTAÇÃO

Exame de Qualificação de Mestrado

17 de Outubro de 2024

DETECÇÃO E CLASSIFICAÇÃO DE DISTÚRBIOS DO SONO

Candidato: Eduardo Carvalheira Teixeira de Aguiar

Orientador: Prof. Dr. Zanoni Dias

Coorientador: Prof. Dr. Hélio Pedrini

Resumo

A privação de sono está associada a riscos aumentados de doenças cardiovasculares, diabetes, obesidade e problemas cognitivos, além de elevar o risco de acidentes. Esta privação pode ser causada pela presença de distúrbios do sono, como insônia e apneia. A detecção e classificação dos distúrbios do sono apresentam desafios significativos devido à diversidade, complexidade e variedade desses distúrbios. A polissonografia, padrão-ouro para avaliação do sono, registra uma ampla variedade de parâmetros fisiológicos, incluindo atividade cerebral, respiração e movimentos oculares e musculares durante o sono, auxiliando na detecção desses distúrbios. No entanto, esse método requer um ambiente de laboratório especializado, é caro e pode causar desconforto ao paciente, afetando a qualidade do sono durante a avaliação. Assim, o uso de sensores em dispositivos vestíveis, como *smartwatches*, tem sido estudado para monitorar o sono de maneira menos invasiva e mais conveniente do que a polissonografia. Neste trabalho, será explorado o uso de diferentes sensores de *smartwatches* para criar métodos competitivos na detecção e classificação de distúrbios do sono, aplicando técnicas de Aprendizado de Máquina para melhorar a eficácia da identificação dessas anomalias, tornando-as práticas e aplicáveis em ambientes domiciliares, capturando melhor os padrões de sono cotidianos dos usuários.

Sumário

| | | |
|----------|---|-----------|
| 1 | Introdução | 2 |
| 1.1 | Descrição do Problema | 3 |
| 1.2 | Questões de Pesquisa | 4 |
| 1.3 | Objetivos | 4 |
| 1.4 | Organização do Texto | 5 |
| 2 | Fundamentação Teórica | 6 |
| 2.1 | Conceitos e Técnicas | 6 |
| 2.1.1 | Estágios do Sono | 6 |
| 2.1.2 | Distúrbios do Sono | 7 |
| 2.1.3 | Séries Temporais | 8 |
| 2.1.4 | Árvores de Decisão | 8 |
| 2.1.5 | Máquina de Vetores de Suporte | 9 |
| 2.1.6 | Redes Neurais Recorrentes | 10 |
| 2.2 | Trabalhos Relacionados | 10 |
| 2.2.1 | Detecção de Apneia | 11 |
| 2.2.2 | Detecção de Insônia | 12 |
| 2.2.3 | Outros Problemas | 14 |
| 3 | Material e Métodos | 18 |
| 3.1 | Método | 18 |
| 3.2 | Métricas de Avaliação | 20 |
| 3.3 | Conjunto de Dados | 21 |
| 3.4 | Recursos Computacionais | 21 |
| 4 | Plano de Trabalho e Cronograma de Execução | 23 |
| | Bibliografia | 23 |

Capítulo 1

Introdução

O sono desempenha um papel fundamental no bem-estar e na saúde dos indivíduos [23]. Contudo, alcançar a quantidade adequada de sono para garantir uma noite de descanso adequada tem sido uma tarefa desafiadora, em virtude da extensa exposição a dispositivos eletrônicos, do estilo de vida sedentário e do estresse prevalentes na sociedade contemporânea [20, 27]. Esta privação de sono e seus distúrbios acabam influenciando negativamente o indivíduo em seu período de vigília, resultando na perturbação dos sistemas corporais, o que contribui, por exemplo, para o aumento do risco de desenvolvimento de diversas doenças cardiovasculares [23, 27], para a elevação das probabilidades de diabetes mellitus e obesidade, para a interferência nas funções cognitivas e para o aumento do risco de acidentes automobilísticos e ocupacionais [10]. Desta maneira, é de interesse da comunidade médica explorar o comportamento dos indivíduos durante o sono, além de fornecer diagnósticos mais ágeis e antecipados de distúrbios do sono.

Para conseguir monitorar o comportamento do sono, diversos sensores podem ser levados em consideração. Entre eles, destacam-se os acelerômetros, que registram movimentos corporais durante o sono e fornecem dados sobre a atividade física e a qualidade dos movimentos durante o descanso [44]. Além disso, sensores de frequência cardíaca podem ser empregados para monitorar a variabilidade cardíaca e identificar padrões associados aos diferentes estágios do sono [16]. A termografia infravermelha é outra tecnologia promissora, permitindo a detecção não-invasiva de alterações na temperatura corporal durante a noite, o que pode indicar variações nos ciclos de sono [35]. A combinação desses e outros sensores oferece um vasto potencial para um monitoramento do comportamento do sono, como o seu período, duração, latência, qualidade do sono e eficiência [22].

A Polissonografia (PSG) é considerada o padrão-ouro para a avaliação do sono devido à sua capacidade de registrar uma variedade de parâmetros fisiológicos durante o sono, incluindo atividade cerebral, respiração, movimentos oculares e musculares [7]. No entanto, há a necessidade de um ambiente especializado de laboratório do sono com potencial incomodidade para o paciente devido ao equipamento, afetando resultados da noite de sono. Além disso, é um monitoramento de curto prazo, o que reduz, significativamente, a quantidade de dados viáveis devido ao fato supracitado. [31, 43]. Outra ferramenta que é utilizada no domínio médico para a análise do sono é a actigrafia. Este método envolve o uso de dispositivos compactos e portáteis localizados no pulso, geralmente equipados com acelerômetros,

que registram movimentos do corpo durante o dia e a noite [43]. Apesar de não ser capaz de distinguir com precisão os estágios do sono, permite o uso em ambientes domiciliares e comuns, realizando análises em condições mais próximas da vida cotidiana do indivíduo.

Os *smartwatches* e dispositivos *wearables* estão emergindo como uma ferramenta promissora na análise do sono devido à sua capacidade de monitorar continuamente uma variedade de parâmetros fisiológicos, como o frequência cardíaca e a temperatura da pele, e comportamentais relevantes utilizando os seus sensores durante o sono. A conveniência e o conforto de uso dos *smartwatches* os tornam uma opção de monitoramento do sono em ambientes domiciliares, refletindo com mais precisão os padrões de sono do dia a dia dos usuários, visto que há vários dispositivos disponíveis no mercado que foram previamente avaliados em termos de desempenho, precisão e experiência do usuário [19].

Estas características das tecnologias vestíveis possibilitam a realização de experimentos de maneira confortável, como os actígrafos, e precisos como a PSG. Além disso, a possível integração de algoritmos de análise de dados avançados nestes dispositivos pode permitir a identificação precoce de distúrbios do sono, como a apneia [18, 38], proporcionando aos usuários informações valiosas sobre sua saúde e incentivando intervenções preventivas e tratamentos precoces. Diversas técnicas de Aprendizado de Máquina foram empregadas para abordar questões relacionadas ao sono, desde algoritmos, adaptações de redes neurais recorrentes e aplicações de aprendizado de máquina profundo.

1.1 Descrição do Problema

A detecção e classificação dos distúrbios do sono constituem um desafio significativo devido à diversidade e complexidade desses distúrbios. Diversos tipos de distúrbios do sono, como insônia, apneia do sono, narcolepsia, síndrome das pernas inquietas e distúrbios do ritmo circadiano, apresentam características distintas que afetam o sono de maneiras variadas [3].

A identificação e categorização de distúrbios do sono abrangem também a identificação dos estágios do sono, e a diferenciação entre vigília e sono é conduzida como um passo preliminar para uma categorização mais precisa desses estágios [19]. Em relação à apneia, distúrbio cujo sintoma é a respiração anormal durante o sono, ela é normalmente detectada a partir do uso do PSG [34], podendo ser dividida em três diferentes tipos, a apneia obstrutiva do sono (OSA), apneia central do sono (CSA) e apneia complexa. A OSA, afeta consideravelmente os estágios *Non-Rapid Eye Movement* (NREM) e *Rapid Eye Movement* REM do sono, aumentando a quantidade de transições presentes entre os estágios durante o sono de um indivíduo [8], evidenciando a importância da categorização dos estágios do sono.

Atualmente, existem modelos que apresentam resultados promissores na detecção de apneia do sono, empregando tecnologias avançadas, incluindo o uso de fotopletismografia (PPG), redes neurais convolucionais (CNN), análise da variabilidade da frequência cardíaca (HRV) e detecção acústica [41]. No entanto, a precisão desses modelos geralmente não é suficiente para fornecer um diagnóstico clínico [30]. Além disso, há uma lacuna significativa de dados quanto ao diagnóstico da síndrome das pernas inquietas e de distúrbios circadianos, áreas que carecem de estudos e pesquisas para desenvolver abordagens eficazes de detecção utilizando dispositivos vestíveis [41].

Devido à natureza progressiva do sono, os seus dados são considerados de varredura, ou seja, as variáveis são capturadas continuamente ao longo do tempo [5]. Os sensores de PPG e o acelerômetro dos dispositivos móveis disponibilizam dados de movimentação do usuário e de seu batimento cardíaco, porém, é possível realizar a extração de informações e características adicionais a partir destes dados [2]. É importante notar que essas análises podem ser realizadas de forma *online*, utilizando dados à medida que estão sendo gerados, ou de forma *offline*, utilizando dados em torno do momento atual, com a aplicação de métodos de pós-processamento. Logo, é de interesse investigar os resultados que podem ser obtidos ao combinar características computadas e modelos de aprendizado de máquina para resolver esse tipo de desafio.

1.2 Questões de Pesquisa

Este trabalho busca investigar e responder às seguintes questões de pesquisa:

- Os *smartwatches* têm sensores adequados para a realização da detecção e da classificação dos distúrbios do sono?
- Como combinar as informações dos dados de diferentes sensores de *smartwatches* para obter um método competitivo de detecção de distúrbios do sono?
- Como combinar as informações dos dados de diferentes sensores de *smartwatches* para obter um método competitivo de classificação de distúrbios do sono?
- Qual seria a melhor técnica de classificação a ser utilizada no contexto de distúrbios do sono?
- Qual o tipo de abordagem (*online* ou *offline*) é mais adequada para a detecção e classificação de distúrbios do sono?

1.3 Objetivos

O objetivo deste trabalho é aplicar técnicas de Aprendizado de Máquina para melhorar a precisão da detecção e classificação de anomalias do sono. Para desenvolver a metodologia proposta, alguns objetivos específicos devem ser alcançados:

- levantamento bibliográfico e estudo das abordagens utilizadas para a detecção e classificação de distúrbios de sono;
- exploração da combinação de dados dos diferentes sensores presentes em *smartwatches*;
- realização de experimentos;
- avaliação e comparação do método proposto com outras abordagens disponíveis;
- documentação e publicação dos resultados.

Este projeto visa contribuir com o desenvolvimento de um método para a classificação e detecção de distúrbios do sono aplicando Inteligência Artificial, a fim de obter um modelo para a tomada de decisão automática com dados disponíveis, e limitados, para esse tipo de problema.

1.4 Organização do Texto

Este projeto está organizado em 4 capítulos. No Capítulo 1, é apresentado o problema de pesquisa a ser abordado neste projeto e também os principais objetivos e contribuições esperadas. Em seguida, no Capítulo 2, são descritos conceitos e técnicas importantes para o entendimento do projeto, além de apresentar trabalhos relacionados existentes na literatura. No Capítulo ??, é abordada o método, a base de dados, as métricas de avaliação e os recursos computacionais que serão empregados no desenvolvimento do projeto. No Capítulo 4, são mostrados o plano de trabalho e o cronograma de execução.

Capítulo 2

Fundamentação Teórica

Neste capítulo, será apresentada a revisão bibliográfica feita para este trabalho. A Seção 2.1 contém os principais conceitos e técnicas relacionadas à definição de distúrbios do sono e ao método a ser abordado. Já na Seção 2.2, serão analisados os trabalhos relacionados ao tema.

2.1 Conceitos e Técnicas

Os principais conceitos e técnicas empregados neste trabalho estão relacionados aos estágios do sono, às séries temporais e às redes neurais convolucionais e recorrentes. Esses conceitos e técnicas são apresentados nesta seção.

2.1.1 Estágios do Sono

A Academia Americana de Medicina do Sono (AASM) [7] define cinco estágios diferentes do sono:

- Vigília: alerta de vigília para sonolência, sentir-se relaxado, adormecer rapidamente ou em poucos minutos;
- *Non-Rapid Eye Movement* (NREM), que consiste em 3 estágios (N1 a N3) com grau crescente de profundidade do sono:
 - N1: indica o início do sono, transição rápida e superficial. Não sentir vontade de responder a ruídos ouvidos;
 - N2: diminuição da frequência cardíaca e temperatura corporal. Os sinais de eletroencefalograma (EEG) diminuem em frequência e aumentam em amplitude durante este período de sono leve;
 - N3: sono profundo, o tônus muscular, o pulso e a frequência respiratória diminuem. As ondas delta ocorrem no EEG;
- *Rapid Eye Movement* (REM): caracterizada por movimentos rápidos dos olhos, aumento da atividade cerebral, aproximando ao observado durante o período de vigília.

Ocorre paralisia temporária dos músculos, exceto dos olhos e os músculos que controlam a respiração.

Apesar desta designação ser a mais comumente adotada, há outras definições, dividindo em até seis estágios do sono [36].

2.1.2 Distúrbios do Sono

Os distúrbios do sono são variados, abrangendo desde dificuldades para iniciar e manter o sono até comportamentos anômalos durante o período de descanso [33]. Entre os principais distúrbios do sono, destacam-se:

- **Insônia:** caracterizada pela dificuldade em adormecer, manter o sono ou ter um sono de qualidade. Pode ser classificada como insônia aguda, durando poucos dias ou semanas, e insônia crônica, definida como a dificuldade em dormir que ocorre pelo menos três noites por semana e persiste por três meses ou mais.
- **Apneia do Sono:** A apneia do sono é um distúrbio caracterizado por pausas na respiração ou períodos de respiração superficial durante o sono. Essas pausas podem durar de alguns segundos a minutos e ocorrem várias vezes durante a noite, resultando em sono fragmentado e de má qualidade. Existem três tipos principais de apneia do sono: Apneia Obstrutiva do Sono (OSA), Apneia Central do Sono (CSA) e apneia mista ou complexa.
 - **Apneia Obstrutiva do Sono:** é o tipo mais comum de apneia do sono. Ela é definida como uma cessação do fluxo de ar por pelo menos 10 segundos, devido ao colapso das vias aéreas superiores durante o sono.
 - **Apneia Central do Sono:** diferentemente da OSA, a interrupção do fluxo de ar ocorre quando há a falta de esforço para respirar. Neste caso, o cérebro falha em enviar os sinais apropriados para os músculos que controlam a respiração.
 - **Apneia mista ou complexa:** é uma combinação de OSA e CSA. Os pacientes geralmente apresentam características de ambos os tipos.
- **Síndrome das Pernas Inquietas (RLS):** é caracterizada por uma sensação desconfortável, levando à necessidade de movimentar as pernas. Essas sensações tipicamente ocorrem durante os períodos de descanso ou inatividade, especialmente à noite, e são aliviadas temporariamente pelo movimento.
- **Narcolepsia:** é um distúrbio neurológico crônico que afeta a capacidade do cérebro de regular os ciclos de sono e vigília. Pessoas com narcolepsia experimentam sonolência diurna excessiva e episódios repentinos de sono, que podem ocorrer em qualquer momento e durante qualquer atividade. Além da sonolência diurna, a narcolepsia pode incluir outros sintomas característicos, como a paralisia do sono e alucinações, podendo causar a cataplexia, ou atonia muscular.

2.1.3 Séries Temporais

Uma série temporal é uma sequência de observações de uma variável registradas em intervalos de tempo regulares, conforme uma determinada taxa de amostragem. Essas observações são organizadas cronologicamente, permitindo a análise de como a variável evolui ao decorrer do tempo. Assim, é possível definir uma série temporal T como uma sequência ordenada de n variáveis de valores reais conforme a Equação 2.1:

$$T = (t_1, \dots, t_n), t_i \in \mathbb{R} \quad (2.1)$$

No contexto do trabalho, o período analisado seria toda a duração do registro de sono, em que a taxa de amostragem apresentada dependeria do sensor utilizado para captar o dado.

2.1.4 Árvores de Decisão

A Arvore de Decisão (do inglês, *Decision Tree* - DT) [37] é um tipo de modelo de aprendizado supervisionado utilizado para tarefas de classificação e regressão. Sua estrutura é hierárquica, composta por nós internos que representam testes ou decisões baseados em características dos dados, e nós folhas que representam os resultados ou rótulos finais. A construção de uma árvore de decisão envolve selecionar a melhor característica em cada etapa para dividir os dados, um processo conhecido como “divisão” ou “partição”. Esse processo é repetido recursivamente para cada subconjunto de dados até que uma condição de parada seja atingida.

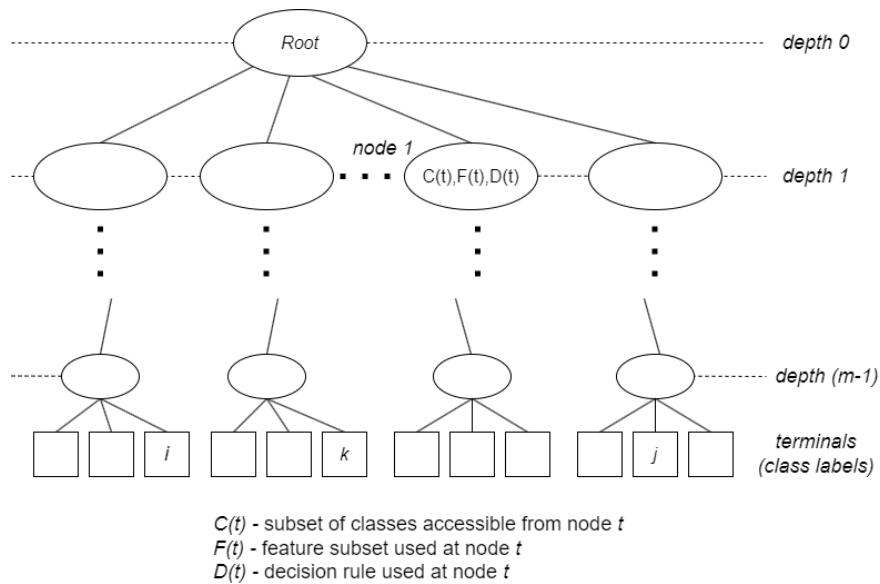


Figura 2.1: Exemplo de uma árvore de decisão genérica.

Já a Floresta Aleatória (do inglês, *Random Forest* - RT) [32] é uma técnica de *ensemble learning* que combina múltiplas árvores de decisão para melhorar a precisão de classificação e regressão. Este método baseia-se no princípio de *bagging* e na seleção aleatória de características para construir um conjunto robusto de modelos de árvores de decisão. A abordagem de

Random Forest é particularmente eficaz em lidar com grandes conjuntos de dados e características de alta dimensionalidade. Elas podem ser computacionalmente intensivas devido ao número de árvores que precisam ser treinadas. Além disso, modelos baseados em árvores de decisão apresentam uma interpretabilidade aprimorada se comparado com outros modelos, como pode ser observado na Figura 2.1.

2.1.5 Máquina de Vetores de Suporte

A Máquina de Vetores de Suporte (do inglês, *Support Vector Machine* - SVM) é um algoritmo de aprendizado supervisionado utilizado tanto para classificação [42] quanto para regressão, reconhecido por sua eficácia em problemas de alta dimensionalidade. Desenvolvido por Vapnik *et al.* [15], a SVM busca encontrar um hiperplano que separa as classes de dados de forma ótima, maximizando a margem entre elas.

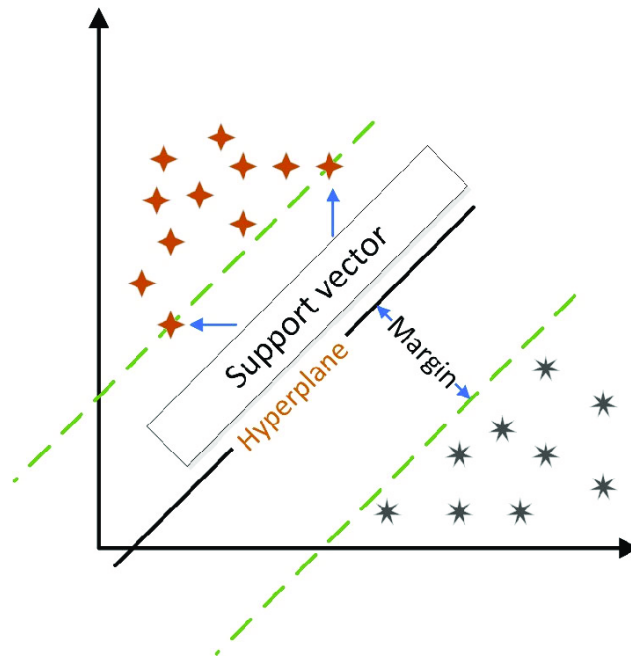


Figura 2.2: Exemplo de duas classes linearmente separáveis em um espaço de entrada bidimensional [1].

Essa margem é definida como a distância entre o hiperplano e os pontos de dados mais próximos, conhecidos como vetores de suporte. O objetivo da SVM é maximizar essa margem para melhorar a generalização do modelo, solucionando um problema de otimização. Para dados que não são linearmente separáveis, a SVM utiliza técnicas de *kernel* [39], como o *kernel* linear, polinomial e *Radial Basis Function* (RBF), para transformar os dados em um espaço de maior dimensão onde um hiperplano linear pode ser utilizado para a separação. A robustez e a precisão da SVM tornam-na uma escolha popular para diversas aplicações, incluindo reconhecimento de padrões, bioinformática e análise de imagens [28].

2.1.6 Redes Neurais Recorrentes

Redes Neurais Recorrentes (do inglês, *Recurrent Neural Networks* - RNNs) são uma classe de redes neurais projetadas para processar dados sequenciais, mantendo informações ao longo do tempo através de ciclos internos. Comportamento que possibilita que a saída dos neurônios influencie na sua entrada subsequente, permitindo que a rede exiba um comportamento dinâmico temporal. No entanto, as RNNs tradicionais enfrentam dificuldades com dependências de longo prazo, principalmente devido ao problema da fuga do gradiente, que afeta o aprendizado eficaz em sequências mais longas.

Para superar essas limitações, foram desenvolvidas variantes como as *Long Short-Term Memory* (LSTM) [21] e as *Gated Recurrent Unit* (GRU) [13]. As LSTMs introduzem uma arquitetura mais complexa com células de memória e três tipos de portas (entrada, esquecimento e saída) que regulam o fluxo de informações, permitindo que a rede mantenha e acesse informações ao decorrer de longos períodos.

Já as GRUs são uma forma mais avançada de RNNs, projetadas para superar o problema do gradiente de fuga, que se refere à incapacidade de propagar gradientes úteis das camadas de saída de volta para as camadas próximas à entrada. Esse problema é solucionado nas GRUs através do uso de *gates* de atualização e de redefinição. O *gate* de atualização permite que o modelo controle a quantidade de informação das etapas de tempo anteriores que deve ser transferida para etapas futuras, garantindo que informações relevantes sejam preservadas e utilizadas de forma eficaz ao longo do tempo.

Pesquisas recentes desenvolveram um novo tipo de LSTM, o modelo *Extended Long Short-Term Memory* (xLSTM). Seu objetivo é superar as três principais limitações das LSTMs, que seriam a incapacidade de revisar decisões de armazenamento, as capacidades de armazenamento limitadas e a falta de paralelização devido à mistura de memória [6]. Essas limitações abriram o caminho para o surgimento dos *Transformers* [45]. Assim, os modelos xLSTMs introduziram duas principais modificações na ideia original das LSTMs: o escalonamento exponencial e as novas estruturas de memória. Isso resulta em dois novos modelos, o sLSTM, com memória escalar, atualização escalar e mistura de memória, e o mLSTM, com memória matricial e uma regra de atualização por covariância, totalmente paralelizável. Tanto o sLSTM quanto o mLSTM aprimoram a LSTM através do escalonamento exponencial [6].

2.2 Trabalhos Relacionados

Nesta seção, serão apresentados trabalhos que buscam detectar distúrbios do sono. As abordagens presentes na literatura normalmente fazem a detecção somente de um único tipo de distúrbio do sono. Outras abordagens também serão apresentadas para mostrar métodos que lidam com o mesmo tipo de dados a ser utilizado neste trabalho, entretanto, com aplicações em problemas diferentes.

2.2.1 Detecção de Apneia

A apneia é o distúrbio mais analisado em estudos sobre o sono [46]. Diversos sensores são utilizados para a detecção da apneia, dentre eles, se destacam o Eletrocardiograma (ECG) e a PSG, porém, também há abordagens que utilizam a análise sonora.

O estudo de *Chen et al.* [12] avalia vinte indivíduos (oito homens e doze mulheres). A faixa etária varia entre 36 e 72 anos, com média de 59,3 anos. Além disso, os pacientes apresentam certa diversidade em termos da gravidade da apneia. O estudo sincroniza os dados dos acelerômetros de *smartwatches* com os dados de equipamentos de polissonografia (PSG), que são o padrão-ouro para a detecção de apneia. A sincronização permite a coleta de dados correspondentes a eventos de apneia identificados por médicos do sono, proporcionando uma base sólida para validação do sistema.

Com base em um estudo clínico, os autores definiram o tamanho da janela temporal como 60 segundos e coletaram 1018 eventos de apneia obstrutiva do sono (OSA), 125 eventos de apneia central do sono (CSA), 818 eventos de hipopneia, em que ocorre uma interrupção parcial da respiração, e 3000 eventos de sono normal, amostrados aleatoriamente de todos os vinte sujeitos. Os eventos foram divididos em conjunto de treinamento, que inclui os eventos de dez sujeitos, e conjunto de teste, que inclui os eventos dos pacientes restantes. Foi utilizado um esquema de validação cruzada baseado em grupos, onde os dados amostrados de um sujeito são isolados exclusivamente para o conjunto de treinamento ou para o conjunto de teste. Ou seja, os dados amostrados de um sujeito não aparecem em ambos os conjuntos. Além disso, esta validação cruzada foi realizada com 10 partições (*10-fold cross-validation*) no conjunto de treinamento para determinar o melhor classificador para a solução.

Foi selecionado o classificador com o melhor desempenho entre os diferentes algoritmos de classificação utilizados, como a Árvore de Decisão (DT), *Naive Bayes* (NB), Floresta Aleatória (RF), Máquina de Vetores de Suporte (SVM) e *Adaptive Boost* (ABT). Como pode ser observado na Figura 2.3, o melhor modelo utilizou a técnica de *Adaptive Boost*.

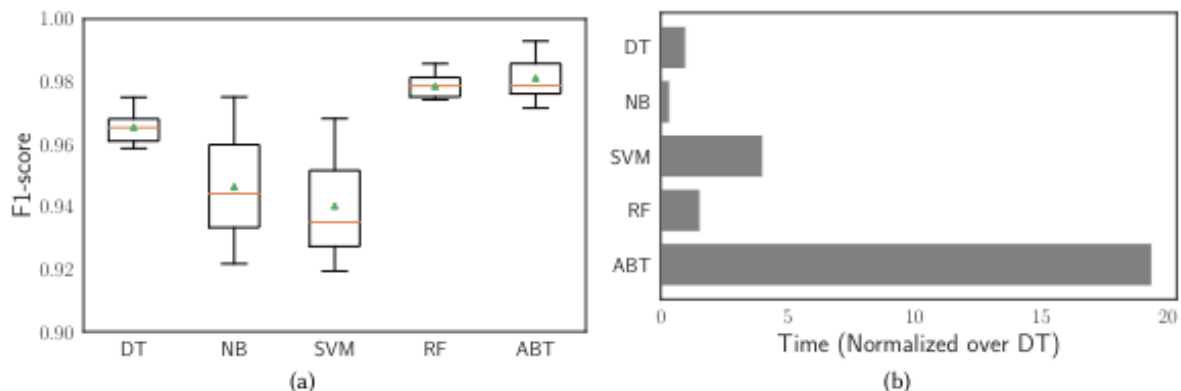


Figura 2.3: Comparação de performance dos diferentes classificadores no trabalho de *Chen et al.* [12]: (a) F_1 -score (b) Tempo.

Segundo os autores, as métricas de detecção da apneia foram 96,7% de precisão, 96,2%

de *recall* e 96,4% de F_1 -score. Já para a detecção de sono normal, 97,5% de precisão, 97,7% de *recall* e 97,6% de F_1 -score.

2.2.2 Detecção de Insônia

A insônia, como a apneia, é um dos distúrbios mais pesquisados e avaliados atualmente. Os sensores comumente utilizados para avaliar esse distúrbio são o Eletroencefalograma (EEG) e o Eletrocardiograma (EGC) [46]. Porém, não há a presença destes tipos de sensores em dispositivos *wearables*. Apesar disso, há pesquisas que relacionam a atividade dos acelerômetros e dos actígrafos para a detecção da insônia, se assemelhando aos *smartwatches*.

A pesquisa de *Angelova et al.* [4] avalia 45 adultos jovens, incluindo 24 assintomáticos e 21 sujeitos com insônia aguda. O estudo utiliza o *Philips Actiwatch* para monitorar os indivíduos ao decorrer de um período de 7 noites, em que, foram orientados a dormir das 22 horas até as 8 da manhã. As conclusões foram baseadas inteiramente nos resultados da actigrafia, sem o uso de diários de sono, de Índice de Gravidade da Insônia ou de outras métricas subjetivas para a avaliação de problemas de sono. Foram extraídas características lineares e não lineares do sinal de actigrafia noturna usando operadores estatísticos tradicionais (Média e Desvio Padrão (SD)), plotagem de Poincaré (SD1, SD2, Razão, Área, CCM), e medida de entropia (entropia amostral SampEn). Além disso, Tempo Total de Sono (TST), Tempo Acordado após o Início do Sono (WASO) e Razão Sono-Vigília (SWR) foram extraídos automaticamente do sinal de actigrafia, como observado pela Figura 2.4.

| Index | Feature Name |
|-------|------------------------------------|
| 1 | Mean (Arithmetic) |
| 2 | SD (Standard Deviation) |
| 3 | SD1 (Poincaré Map) |
| 4 | SD2 (Poincaré Map) |
| 5 | Ratio (SD1/SD2 Poincaré Map) |
| 6 | CCM (Complex Correlation Measure) |
| 7 | SampEn (Sample Entropy) |
| 8 | TST (Total Sleep Time) |
| 9 | WASO (Wake time After Sleep Onset) |
| 10 | SWR (Sleep Wake Ratio) |

Figura 2.4: Lista das características extraídas da actigrafia por *Angelova et al.* [4].

Neste estudo, foi proposto um modelo em duas camadas para detecção de insônia aguda, conforme mostrado na Figura 2.5. Na primeira camada, um modelo de aprendizado de máquina supervisionado é desenvolvido com a técnica de validação cruzada *k-fold* para prever rótulos noturnos de todos os sujeitos. Dois modelos de aprendizado de máquina supervisionados, SVM e RF, foram usados para construir o modelo de previsão de nível noturno.

O RF apresentou melhor desempenho (precisão de 84%) do que a SVM, (73%) na classificação de indivíduos com insônia em relação aos voluntários saudáveis se configurado um *threshold* de um número n de noites mal dormidas. Se avaliado noites isoladas os modelos

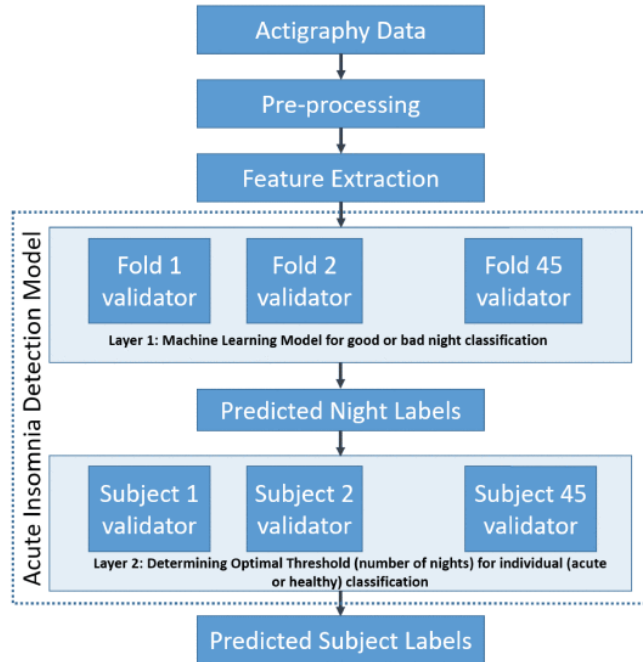


Figura 2.5: Fluxo de trabalho do modelo de aprendizado de máquina proposto por *Angelova et al.* [4] para classificação de indivíduos com insônia aguda.

tem uma acurácia de 69% para RF e 63% para SVM, tendo resultados com pouco potencial para aplicações clínicas.

Já o artigo de *Kusmakar et al.* [26] avaliou 80 adultos, sendo 40 deles saudáveis e 40 indivíduos com insônia crônica. O estudo utilizou, também, a actigrafia de pulso nos sujeitos recrutados e os dados foram coletados por uma semana utilizando o modelo de actígrafo *Respironics Actiwatch Spectrum Pro* da *Philips* e os dados brutos foram processados com o *software Actiware*. Os movimentos foram amostrados em intervalos de 60 segundos. Todos os sujeitos recrutados usaram os dispositivos o tempo todo, durante o dia e a noite e estavam livres para se mover e não foram proibidos de realizar quaisquer atividades cotidianas. A coleta de dados para cada participante incluiu cinco dias úteis e um fim de semana.

Como na pesquisa anterior, extraiu-se as características lineares e não lineares do sinal do actígrafo, usando operadores estatísticos tradicionais (Média e Desvio Padrão (SD)), plotagem de Poincaré (SD1, SD2, Razão, Área, CCM), medida de entropia (entropia amostral SampEn), Tempo Total de Sono (TST), Tempo Acordado após o Início do Sono (WASO) e da Razão Sono-Vigília (SWR), além de incluir a Eficiência do Sono (SE). Este estudo apresentou uma estrutura semelhante ao supracitado, com duas camadas, realizando treinamentos com modelos de Floresta Aleatória e Máquinas de Vetores de Suporte.

O desempenho de classificação do modelo proposto apresentou uma precisão de 80%, sensibilidade de 76% e especificidade de 82% utilizando RF, mostrando um desempenho superior em comparação com a SVM.

A pesquisa apresentada, em comparação com as referências apresentadas acima, que limitam-se a estudar apenas um distúrbio em específico, pode trazer um avanço significativo no campo da detecção e classificação de distúrbios do sono ao adotar uma abordagem ampla

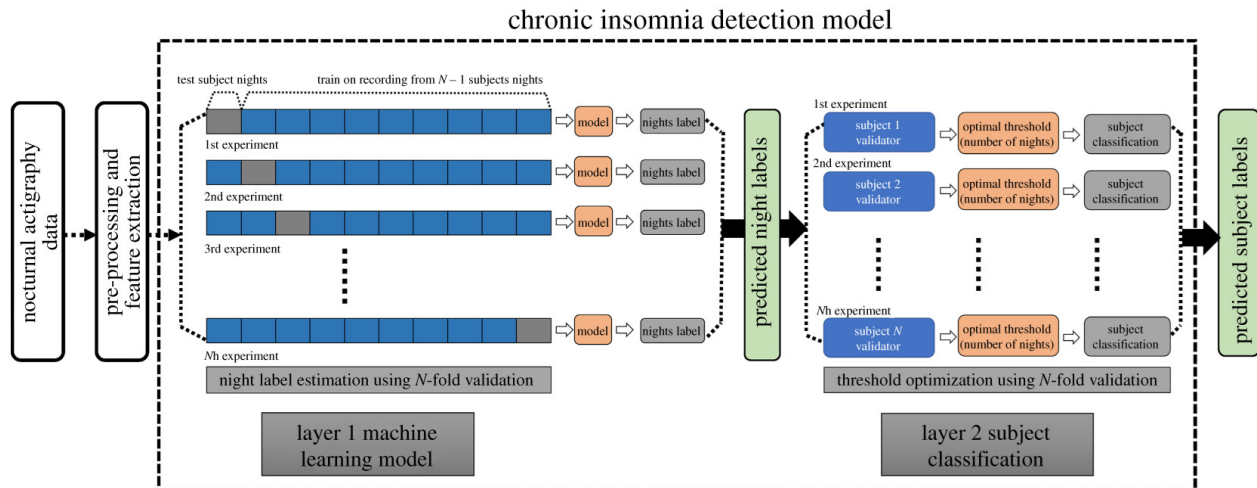


Figura 2.6: O fluxo de trabalho do modelo de detecção de insônia crônica proposto por Kusmakar *et al.* [26]

que abrange múltiplos distúrbios simultaneamente. Este diferencial permite uma análise mais robusta e abrangente das relações entre os diversos distúrbios, abrindo novas possibilidades para a detecção de um sono anormal.

Além de adotar uma abordagem holística na detecção e classificação de múltiplos distúrbios do sono, o trabalho considera a possibilidade de integrar essa tecnologia a dispositivos vestíveis. Essa característica oferece um diferencial importante ao tornar a detecção de diversos distúrbios mais acessível, prática e contínua para o usuário, permitindo monitoramento em tempo real sem a necessidade de equipamentos complexos, facilitando a identificação precoce de distúrbios.

2.2.3 Outros Problemas

Em relação a aplicações em dispositivos vestíveis, somente aplicações de detecção de apneia e de insônia são encontradas na literatura. Algumas implementações, utilizando dados que não estão presentes neste dispositivos, fazem a detecção de distúrbios do sono como a narcolepsia [14]. Além disso, outros problemas envolvendo dados de sensores de *smartwatches* são abordados na literatura. Dentre eles, o problema do Reconhecimento de Atividades Humana (HAR) e detecção dos estágios do sono, que são normalmente abordados utilizando redes neurais com os dados provenientes dos acelerômetros e giroscópios destes dispositivos vestíveis.

Na pesquisa de Christensen *et al.* [14] busca detectar os pacientes com narcolepsia utilizando EEG. Segundo o artigo, estudos em animais e humanos demonstraram que transições rápidas da vigília para o sono REM são uma característica diagnóstica da narcolepsia. Assim, se essa transição se realizar em períodos menores que 15 minutos durante o PSG e durante o sono diurno, é considerado que o paciente apresenta o distúrbio. O estudo utilizou dados de um total de 1218 pacientes, com 155 sujeitos apresentando narcolepsia catapléxica. Do total, somente 510 foram utilizados para o treinamento do modelo, em que 136 apresentavam

a doença.

Foi aplicada uma abordagem combinada de seleção de características e classificação utilizando Regressão Logística com regularização Lasso (LASSO). O conjunto de dados de treinamento foi usado para otimizar o modelo LASSO aplicando uma validação cruzada de 10-*fold*, onde os valores das características foram padronizados antes de serem fornecidos como entrada. Dez modelos LASSO foram construídos usando este procedimento, e o modelo final foi selecionado como aquele que apresentou o maior valor de área sob a curva ROC (AUC).

O modelo final LASSO, incluindo as 13 características, apresentou uma precisão de 89,2%, uma AUC de 94,0%, uma sensibilidade de 53,7% e uma especificidade de 98,6% no conjunto de dados de treinamento, e uma precisão de 70,3%, uma AUC de 48,0%, uma sensibilidade de 26,3% e uma especificidade de 71,5% no conjunto de dados de validação. Apesar de não utilizar dispositivos vestíveis, com este estudo é possível perceber que os estágios do sono são relevantes para a detecção deste distúrbio do sono.

Já na pesquisa de Korkalainen *et al.* [25], realizada com 894 indivíduos com suspeita de Apneia Obstrutiva do Sono (OSA), foi desenvolvido um método baseado em CNN e RNN para identificar os estágios do sono a partir do sinal de Fotopletismografia (PPG). Este sinal foi obtido utilizando um oxímetro de dedo (Nonin Xpod 3011). O modelo desenvolvido utiliza CNN para aprender as características de cada estágio do sono, enquanto a RNN foi utilizada para considerar a distribuição temporal dos estágios durante a noite. Foram considerados três cenários diferentes, a classificação em três, quatro e cinco estágios do sono, todos com a mesma arquitetura, que pode ser observada na Figura 2.7.

Os resultados gerais obtidos foram acurácias de 80,1%, 68,5%, e 64,1% para a classificação de três, quatro e cinco estágios, respectivamente.

Ainda em aspectos da classificação de estágios do sono, que pode auxiliar na detecção dos distúrbios do sono, temos a pesquisa de Ederli *et al.* [17], que utilizou dados de acelerômetro de *smartwatches* para a classificação de estágios de sono e a vigília, com o uso de diferentes representações de dados, como séries temporais brutas e técnicas de extração de características. Nesse contexto, foi proposto um método baseado em Gráficos de Recorrência gerados a partir de dados de acelerômetro de *smartwatches*, como observado na Figura 2.8, utilizando as redes neurais como a *RensNet* e *EfficientNet* para classificar os estágios de sono e vigília.

Ederli *et al.* [17] obtiveram resultados que alcançaram uma acurácia balanceada de 79,3%, um ganho de quase três pontos percentuais em comparação com a extração de características do trabalho de referência. Além disso, eles exploraram técnicas de extração de características para comparar diferentes representações utilizando os classificadores Floresta Aleatória e Regressão Logística. Com essas técnicas, obtiveram até 85,0% de acurácia balanceada, superando o trabalho de referência e demonstrando que essas técnicas também têm o potencial de aprimorar os modelos baseados em Gráficos de Recorrência.

Outro estudo que aborda a classificação dos estágios do sono, porém com a presença de uma população que contém indivíduos com apneia do sono, é a pesquisa de Silva *et al.* [40]. Eles utilizaram um grande conjunto de dados de 1522 gravações noturnas coletadas de uma população altamente heterogênea e utilizando diferentes versões do *Galaxy Watch* da *Samsung*, e usaram um modelo baseado em rede neural recorrente com 23 características de entrada extraídas de dados de acelerômetro e sensores de fotopletismografia para populações

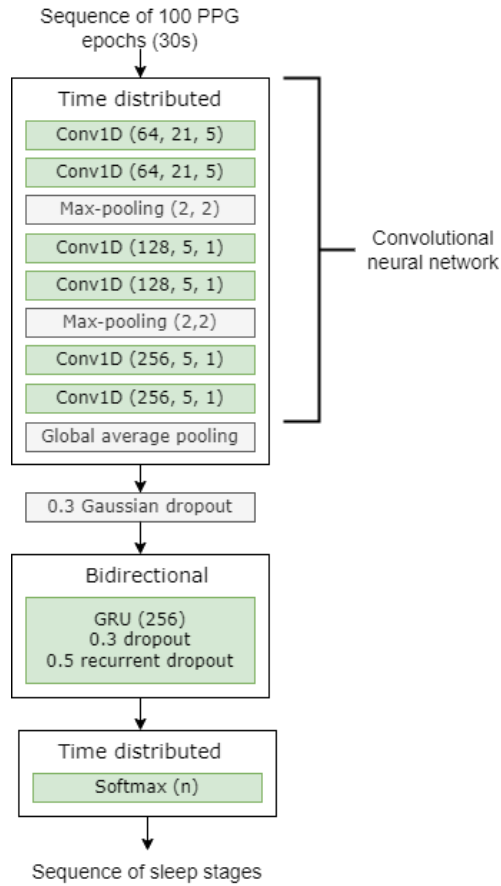


Figura 2.7: Arquitetura de rede CNN e RNN utilizada por Korkalainen *et al.* [25] para detecção de estágios do sono.

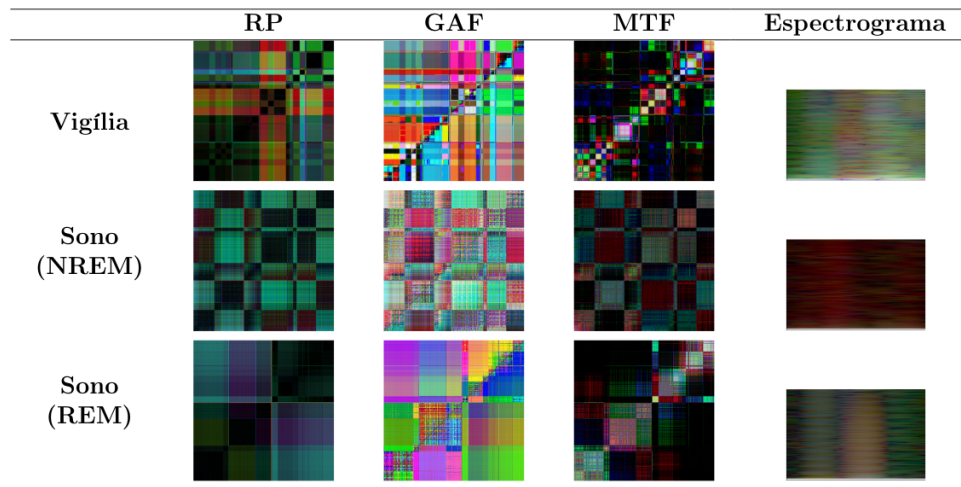


Figura 2.8: Exemplos de imagens geradas na pesquisa de Ederli *et al.* [17] com dados de acelerômetro, com cada tipo de representação.

saudáveis e com apneia do sono, permitindo a previsão dos estágios do sono em intervalos de

30 segundos. O fluxo de execução pode ser observado pela Figura 2.9.

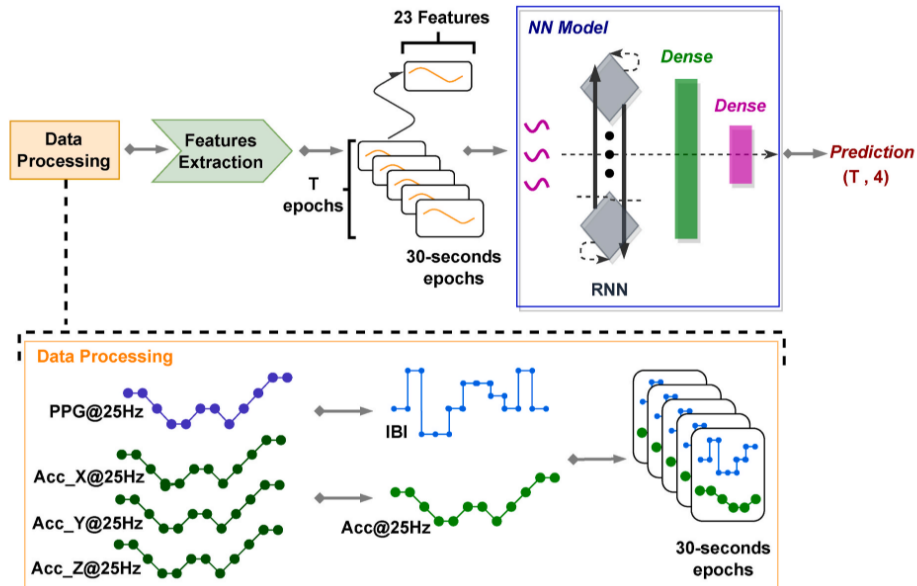


Figura 2.9: *Pipeline* proposto por *Silva et al.* [40] para a classificação dos estágios do sono.

O resultado desse modelo, em uma classificação de quatro estágios do sono (vigília, sono leve, sono profundo e sono REM), alcançou 71,6% de acurácia balanceada e um coeficiente kappa de Cohen de 0,56 em um conjunto de testes com 586 gravações. Os resultados apresentados nesse estudo validaram a proposta como uma solução competitiva e utilizável em dispositivos vestíveis para a classificação dos estágios do sono. Além disso, demonstrou que o desempenho do algoritmo tem baixa correlação com variáveis demográficas, já que se utilizou dados de populações saudáveis e com apneia do sono.

Capítulo 3

Material e Métodos

Este capítulo descreve o método, a base de dados, as métricas de avaliação e os recursos computacionais que serão utilizados no desenvolvimento do projeto.

3.1 Método

O método empregado para detectar e classificar distúrbios do sono baseia-se na exploração de métodos que levam em conta tanto as informações espaciais quanto as temporais dos dados, além da combinação de diferentes dados obtidos de sensores de *smartwatches*, como acelerômetro e PPG.

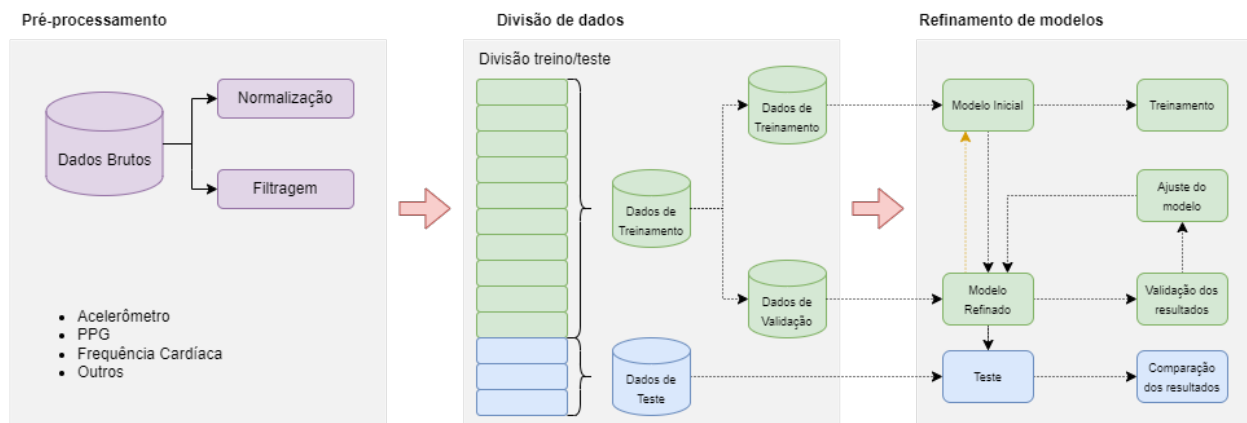


Figura 3.1: Esquema de método a ser desenvolvido.

Ao utilizar uma abordagem orientada a dados, que envolve a exploração direta dos dados brutos sem a extração prévia de características, permite-se que um modelo aprenda propriedades distintas dos dados e resolva tarefas específicas [24]. O aprendizado profundo, em particular, extrai automaticamente características dos dados de entrada sem a necessidade de intervenção humana, permitindo que o modelo capture aspectos que podem ser negligenciados na seleção manual de características [29]. Considerando que os dados utilizados neste estudo estão relacionados a diversas variáveis fisiológicas, especialmente os dados de PPG [25], optamos por adotar o método de aprendizado profundo e a abordagem orientada a

dados para analisar os sinais dos sensores de *smartwatches*, sem a seleção prévia de características, uma vez que padrões sutis obtidos diretamente dos dados podem não ser identificados manualmente.

O método consiste primeiramente na detecção dos distúrbios e posteriormente na classificação deles. A detecção de anomalias foca em identificar eventos ou padrões incomuns que se desviam do comportamento típico, indicando irregularidades. Como o sono normal apresenta uma estrutura uniforme e previsível, com padrões nos dados que seguem ciclos conhecidos [36] e, em contraste, as anomalias no sono, introduzem irregularidades únicas que rompem essa uniformidade, elas possibilitam a detecção destes intervalos anômalos.

Por outro lado, a classificação categoriza esses eventos detectados em classes específicas de distúrbios do sono, como insônia, apneia, narcolepsia, entre outros. Nesta abordagem, o modelo é treinado para reconhecer padrões associados a cada tipo de distúrbio, o que permite não só detectar uma anomalia, mas também especificar qual distúrbio está presente.

Como ilustrado na Figura 3.1, o processo começa com o pré-processamento dos dados, que inclui filtragem e normalização dos dados brutos. As amostras serão então divididas em conjuntos de treino, validação e teste. Para analisar a distribuição temporal dos distúrbios do sono e identificar possíveis janelas de anomalias, serão utilizadas RNNs, como as arquiteturas LSTM e GRU. Para classificar esses intervalos anômalos em distúrbios específicos do sono, serão empregados modelos de classificação como SVM e RF, que têm mostrado resultados promissores em estudos relacionados [4, 12, 26].

Diferentemente de abordagens hierárquicas, a classificação será multirrótulo, permitindo que um mesmo intervalo seja rotulado com múltiplos distúrbios simultaneamente, inclusive diferenciando tipos específicos de apneia (como apneia obstrutiva e apneia central), que serão tratados como distúrbios distintos. Essa abordagem reflete a complexidade dos distúrbios do sono, onde diferentes condições podem coexistir em um mesmo episódio, exigindo uma classificação mais flexível e detalhada. A utilização dos dados de saída do primeiro modelo no segundo está representado pela seta laranja na Figura 3.1. Além da exploração de métodos e da combinação de dados de diferentes sensores, o método também inclui:

- Aquisição e preparação das bases de dados disponíveis publicamente;
- Combinar e comparar a utilização de dados dos diferentes sensores de *smartwatches* (como acelerômetro e PPG);
- Estudo de geração de novas *features* a partir dos dados disponibilizados;
- Realização de experimentos que possam mitigar o desequilíbrio de classes;
- Exploração de soluções baseadas nas técnicas do estado da arte e nos resultados das investigações realizadas;
- Comparação entre as abordagens *online* e *offline*;
- Comparação do método proposto com resultados obtidos em trabalhos relacionados.

3.2 Métricas de Avaliação

O desempenho do método proposta será avaliado utilizando as métricas quantitativas citadas a seguir.

A precisão é representada pela Equação 3.1, onde VP é o número de verdadeiros positivos e FP é o número de falsos positivos. Pela Equação 3.1, é possível perceber que a precisão é a capacidade de classificar como positivo um dado que realmente é positivo.

$$\text{Precisão} = \frac{\text{VP}}{\text{VP} + \text{FP}} \quad (3.1)$$

A taxa de revocação é dada pela Equação 3.2, onde VP é o número de verdadeiros positivos e FN é o número de falsos negativos. Essa medida verifica a capacidade do classificador de classificar corretamente dados positivos.

$$\text{Revocação} = \frac{\text{VP}}{\text{VP} + \text{FN}} \quad (3.2)$$

A taxa F_1 é mostrada na Equação 3.3. A taxa F_1 corresponde à média harmônica da precisão e da revocação.

$$F_1 = 2 \times \frac{\text{Precisão} \times \text{Revocação}}{\text{Precisão} + \text{Revocação}} \quad (3.3)$$

A acurácia é representada na Equação 3.4, onde VP é o número de verdadeiros positivos, FP é o número de falsos positivos, P é o número de casos positivos e N é o número de casos negativos. Essa métrica calcula a porcentagem de decisões corretas atingidas pelo classificador.

$$\text{Acurácia} = \frac{\text{VP} + \text{VN}}{\text{P} + \text{N}} \quad (3.4)$$

No caso de dados desbalanceados, deve-se utilizar as métricas de avaliação de forma balanceada. A Equação 3.5 representa a forma balanceada das métricas de avaliação utilizadas (precisão, revocação, taxa F_1 e acurácia), onde y_i é a métrica avaliada da i -ésima classe e n é a quantidade de classes.

$$\text{Métrica Balanceada} = \frac{\sum_i^n y_i}{n} \quad (3.5)$$

A maioria dos trabalhos e pesquisas apresentados anteriormente apresenta um conjunto limitado de métricas para avaliação dos modelos. Em geral, esses estudos carecem de métricas balanceadas, que são essenciais para uma avaliação justa em cenários de classes desbalanceadas, comuns nos dados de distúrbios do sono, que pode levar a uma superestimação da performance do modelo. Por isso, utilizar e balancear todas as métricas supracitadas é de extrema importância.

3.3 Conjunto de Dados

Este estudo utilizará o conjunto de dados MESA¹ (*Multi-Ethnic Study of Atherosclerosis*) para analisar distúrbios do sono, que contém dados de actigrafia de pulso provenientes do *Actiwatch Spectrum* (Philips) [9].

O conjunto de dados MESA oferece uma riqueza de dados detalhados sobre sono e saúde cardiovascular, coletados de uma população multiétnica diversa, recrutando cerca de 2237 participantes de diferentes regiões dos Estados Unidos para usarem o *Actiwatch Spectrum* entre 2010 e 2013. Ele inclui dados detalhados de monitoramento do sono, juntamente com uma vasta gama de informações demográficas, clínicas e laboratoriais. A coleta de dados do sono foi realizada utilizando dispositivos de polissonografia domiciliar, de actigrafia e do uso de questionários padronizados de acordo com as diretrizes da AASM, proporcionando medições precisas e contínuas dos padrões de sono dos participantes. As gravações de PSG incluem uma noite completa de sono de cada participante e a actigrafia de pulso foi utilizada por 7 dias.

Também contém dados relacionados a distúrbios do sono, como:

- Apneia do Sono: Dados de polissonografia que registram a frequência e a gravidade dos eventos de apneia e hipopneia durante o sono. Isso inclui medidas do índice de apneia-hipopneia (AHI), saturação de oxigênio e outras métricas respiratórias.
- Insônia: Informações derivadas de questionários e actigrafia que podem identificar padrões de sono interrompido e dificuldades para iniciar ou manter o sono.
- Síndrome das Pernas Inquietas (SPI): Dados coletados por meio de questionários específicos que avaliam a presença e a gravidade dos sintomas de SPI.
- Sonolência Diurna Excessiva: Podendo estar ligado à narcolepsia [11]. Avaliação através de questionários como a Escala de Sonolência de Epworth, que mede a propensão ao sono durante atividades diárias.

3.4 Recursos Computacionais

A implementação deste projeto será feita em linguagem de programação Python, devido ao grande número de bibliotecas disponíveis e com boa documentação. O projeto utilizará bibliotecas de aprendizado de máquina, aprendizado profundo, funções científicas e numéricas e apresentação de gráficos. Algumas bibliotecas que podem ser destacadas são: NumPy², scikit-learn³, TensorFlow⁴, Keras⁵ e Matplotlib⁶.

¹<https://sleepdata.org/datasets/mesa>

²<https://www.numpy.org>

³<https://scikit-learn.org>

⁴<https://www.tensorflow.org>

⁵<https://keras.io>

⁶<https://matplotlib.org>

Os experimentos deste projeto serão realizados em dois ambientes, em uma máquina equipada com processador i5-13600K com 3.50 GHz e uma GPU GeForce RTX 4060, com 3072 núcleos CUDA, memória padrão DDR5 de 16 GB e e na plataforma **Google Colab**⁷, que fornece recursos de computação em nuvem gratuitos, tais como CPU, GPU, TPU, memória RAM e armazenamento.

⁷<https://colab.research.google.com/>

Capítulo 4

Plano de Trabalho e Cronograma de Execução

O plano de trabalho é composto pelas seguintes atividades:

1. Obtenção dos créditos obrigatórios em disciplinas do programa de mestrado.
2. Revisão bibliográfica.
3. Estudo e seleção de bases de dados.
4. Exame de Qualificação do Mestrado (EQM).
5. Preparação das bases de dados.
6. Seleção de modelos como ponto de partida.
7. Definição de um novo modelo.
8. Avaliação e aprimoramento do modelo.
9. Realização de testes e análise dos resultados.
10. Documentação e publicação dos resultados.
11. Escrita do documento da dissertação.
12. Defesa da dissertação de mestrado.

O cronograma de execução das atividades propostas, divididas em 12 atividades, em um prazo de 24 meses, é apresentado na Tabela 4.1.

| Atividades | 2024 | | | | | | | | | | | | 2025 | | | | | | | | | | | | 2026 | |
|---|------|----|----|----|----|----|----|----|----|----|----|----|------|----|----|----|----|----|----|----|----|----|----|----|------|--|
| | 03 | 04 | 05 | 06 | 07 | 08 | 09 | 10 | 11 | 12 | 01 | 02 | 03 | 04 | 05 | 06 | 07 | 08 | 09 | 10 | 11 | 12 | 01 | 02 | | |
| 1. Créditos obrigatórios em disciplinas | • | • | • | • | • | • | • | • | • | • | | | | | | | | | | | | | | | | |
| 2. Revisão bibliográfica | | • | • | • | • | • | • | | | | | • | | | | | • | | | | • | | | | | |
| 3. Estudo e seleção de bases de dados | | | • | • | • | • | • | | | | | | | | | | | | | | | | | | | |
| 4. EQM | | | | | | | | | | | | | | | | | | | | | | | | | | |
| 5. Preparação das bases de dados | | | | | | | • | • | • | • | | | | | | | | | | | | | | | | |
| 6. Seleção de modelos | | | | | | | | | • | • | • | • | • | | | | | | | | | | | | | |
| 7. Definição de um novo modelo | | | | | | | | | | • | • | • | • | • | | | | | | | | | | | | |
| 8. Avaliar e aprimorar o modelo | | | | | | | | | | | • | • | • | • | • | • | • | • | • | • | • | • | • | • | • | |
| 9. Testes e análises dos resultados | | | | | | | | | | | • | • | • | • | • | • | • | • | • | • | • | • | • | • | • | |
| 10. Documentar e publicar os resultados | | | | | | | | | | | | | | | • | • | • | • | • | • | • | • | • | • | • | |
| 11. Escrita da dissertação | | | | | | | | | | | | | | | | | | | | | | • | • | • | • | |
| 12. Defesa da dissertação | | | | | | | | | | | | | | | | | | | | | | | | | • | |

Tabela 4.1: Cronograma de atividades dividido em meses.

Bibliografia

- [1] M. Aghaabbasi, M. Ali, M. Jasiński, Z. Leonowicz, and T. Novak. On hyperparameter optimization of machine learning methods using a bayesian optimization algorithm to predict work travel mode choice. *IEEE Access*, 11, 01 2023.
- [2] M. Altini and H. Kinnunen. The promise of sleep: A multi-sensor approach for accurate sleep stage detection using the oura ring. *Sensors*, 21(13):4302, 2021.
- [3] American Academy of Sleep Medicine. *International Classification of Sleep Disorders, 3rd edition, text revision*. American Academy of Sleep Medicine, 2023.
- [4] M. Angelova, C. Karmakar, Y. Zhu, S. P. Drummond, and J. Ellis. Automated method for detecting acute insomnia using multi-night actigraphy data. *IEEE Access*, 8:74413–74422, 2020.
- [5] G. Atluri, A. Karpatne, and V. Kumar. Spatio-temporal data mining: A survey of problems and methods. *ACM Computing Surveys*, 51(4):1–41, 2018.
- [6] M. Beck, K. Pöppel, M. Spanring, A. Auer, O. Prudnikova, M. Kopp, G. Klambauer, J. Brandstetter, and S. Hochreiter. xLSTM: Extended Long Short-Term Memory. *arXiv preprint arXiv: 2405.04517*, 2024.
- [7] R. B. Berry, R. Brooks, C. E. Gamaldo, S. M. Harding, C. Marcus, and B. V. Vaughn. The AASM manual for the scoring of sleep and associated events: rules, terminology and technical specifications. *American Academy of Sleep Medicine*, 176(2012):7, 2012.
- [8] M. T. Bianchi, S. S. Cash, J. Mietus, C.-K. Peng, and R. Thomas. Obstructive sleep apnea alters sleep stage transition dynamics. *PLOS One*, 5(6):e11356, 2010.
- [9] D. E. Bild, D. A. Bluemke, G. L. Burke, R. Detrano, A. V. Diez Roux, A. R. Folsom, P. Greenland, D. R. JacobsJr, R. Kronmal, K. Liu, et al. Multi-ethnic study of atherosclerosis: objectives and design. *American Journal of Epidemiology*, 156(9):871–881, 2002.
- [10] V. K. Chattu, M. D. Manzar, S. Kumary, D. Burman, D. W. Spence, and S. R. Pandi-Perumal. The global problem of insufficient sleep and its serious public health implications. *Healthcare*, 7:1–16, 2019.
- [11] V. Chavda, B. Chaurasia, G. E. Umana, S. O. Tomasi, B. Lu, and N. Montemurro. Narcolepsy—a neuropathological obscure sleep disorder: A narrative review of current literature. *Brain Sciences*, 12(11):1473, 2022.

- [12] X. Chen, Y. Xiao, Y. Tang, J. Fernandez-Mendoza, and G. Cao. Apneadetector: Detecting sleep apnea with smartwatches. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 5(2):1–22, 2021.
- [13] K. Cho, B. Van Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk, and Y. Bengio. Learning phrase representations using rnn encoder-decoder for statistical machine translation. *arXiv preprint arXiv:1406.1078*, 2014.
- [14] J. A. E. Christensen, E. G. S. Munk, P. E. Peppard, T. Young, E. Mignot, H. B. D. Sorensen, and P. Jennum. The diagnostic value of power spectra analysis of the sleep electroencephalography in narcoleptic patients. *Sleep Medicine*, 16(12):1516–1527, 2015.
- [15] C. Cortes and V. Vapnik. Support-vector networks. *Machine Learning*, 20:273–297, 1995.
- [16] M. de Zambotti, L. Rosas, I. M. Colrain, and F. C. Baker. The sleep of the ring: comparison of the URA sleep tracker against polysomnography. *Behavioral Sleep Medicine*, 17(2):124–136, 2019.
- [17] R. P. Ederli, D. Vega-Oliveros, A. Soriano-Vargas, A. Rocha, and Z. Dias. Sleep-wake classification using recurrence plots from smartwatch accelerometer data. In *IEEE Latin American Conference on Computational Intelligence (LA-CCI)*, pages 1–6. IEEE, 2023.
- [18] U. Erdenebayar, Y. J. Kim, J.-U. Park, E. Y. Joo, and K.-J. Lee. Deep learning approaches for automatic detection of sleep apnea events from an electrocardiogram. *Computer Methods and Programs in Biomedicine*, 180:105001, 2019.
- [19] S. Fallmann and L. Chen. Computational sleep behavior analysis: A survey. *IEEE Access*, 7:142421–142440, 2019.
- [20] M. Hafner, M. Stepanek, J. Taylor, W. M. Troxel, and C. Van Stolk. Why sleep matters — the economic costs of insufficient sleep: a cross-country comparative analysis. *RAND Health Quarterly*, 6(4), 2017.
- [21] S. Hochreiter and J. Schmidhuber. Long short-term memory. *Neural Computation*, 9(8):1735–1780, 1997.
- [22] V. Ibáñez, J. Silva, and O. Cauli. A survey on sleep assessment methods. *PeerJ*, 6:e4849, 2018.
- [23] M. R. Irwin. Why sleep is important for health: a psychoneuroimmunology perspective. *Annual Review of Psychology*, 66:143–172, 2015.
- [24] K. Konyushkova, R. Sznitman, and P. Fua. Learning active learning from data. *Advances in Neural Information Processing Systems*, 30, 2017.
- [25] H. Korkalainen, J. Aakko, B. Duce, S. Kainulainen, A. Leino, S. Nikkonen, I. O. Afara, S. Myllymaa, J. Töyräs, and T. Leppänen. Deep learning enables sleep staging from photoplethysmogram for patients with suspected sleep apnea. *Sleep*, 43(11):zsaa098, 2020.

- [26] S. Kusmakar, C. Karmakar, Y. Zhu, S. Shelyag, S. P. Drummond, J. G. Ellis, and M. Angelova. A machine learning model for multi-night actigraphic detection of chronic insomnia: development and validation of a pre-screening tool. *Royal Society Open Science*, 8(6):202264, 2021.
- [27] L. F. Drager, G. Lorenzi-Filho, F. D. Cintra, R. P. Pedrosa, L. R. Bittencourt, D. Poyares, C. G. Carvalho, S. M. G. P. T. Moura, R. Santos-Silva, P. F. De Bruin, G. R. Geovanini, F. N. Albuquerque, W. A. A. De Oliveira, G. A. Moreira, L. M. Ueno, F. B. Nerbass, M. U. P. B. Rondon, E. R. F. Barbosa, A. Bertolami, A. A. V. De Paola, B. B. S. Marques, C. F. Rizzi, C. E. Negrão, C. H. G. Uchôa, C. MakiNunes, D. Martinez, E. A. Fernández, F. U. Maroja, F. R. Almeida, I. C. Trombetta, L. J. Storti, L. A. Bortolotto, M. T. de Mello, M. A. Borges, M. L. Andersen, N. d. P. Portilho, P. Macedo, R. Alves, S. Tufik, S. C. Fagundes, and T. T. Risso. 1^o posicionamento brasileiro sobre o impacto dos distúrbios de sono nas doenças cardiovasculares da sociedade brasileira de cardiologia. *Arquivos brasileiros de cardiologia*, 111:290–340, 2018.
- [28] P. Maji and S. K. Pal. *Rough-fuzzy pattern recognition: applications in bioinformatics and medical imaging*, volume 3. John Wiley & Sons, 2012.
- [29] P. Mavaie, L. Holder, and M. K. Skinner. Hybrid deep learning approach to improve classification of low-volume high-dimensional data. *BMC Bioinformatics*, 24(1):419, 2023.
- [30] F. Mendonca, S. S. Mostafa, A. G. Ravelo-Garcia, F. Morgado-Dias, and T. Penzel. A review of obstructive sleep apnea detection approaches. *IEEE Journal of Biomedical and Health Informatics*, 23(2):825–837, 2018.
- [31] J. Newell, O. Mairesse, P. Verbanck, and D. Neu. Is a one-night stay in the lab really enough to conclude? First-night effect and night-to-night variability in polysomnographic recordings among different clinical population samples. *Psychiatry Research*, 200(2-3):795–801, 2012.
- [32] M. Pal. Random forest classifier for remote sensing classification. *International Journal of Remote Sensing*, 26(1):217–222, 2005.
- [33] M. K. Pavlova and V. Latreille. Sleep disorders. *The American Journal of Medicine*, 132(3):292–299, 2019.
- [34] A. Ramachandran and A. Karuppiah. A survey on recent advances in machine learning based sleep apnea detection systems. *Healthcare*, 9(7):914, 2021.
- [35] R. J. Raymann, D. F. Swaab, and E. J. Van Someren. Skin deep: enhanced sleep depth by cutaneous temperature manipulation. *Brain*, 131(2):500–513, 2008.
- [36] A. Rechtschaffen and A. Kales. A manual of standardized terminology, techniques and scoring system for sleep stages of human subjects. *Brain Information Service*, 1968.
- [37] S. R. Safavian and D. Landgrebe. A survey of decision tree classifier methodology. *IEEE Transactions on Systems, Man, and Cybernetics*, 21(3):660–674, 1991.

- [38] N. Salari, A. Hosseinian-Far, M. Mohammadi, H. Ghasemi, H. Khazaie, A. Daneshkhah, and A. Ahmadi. Detection of sleep apnea using machine learning algorithms based on ECG signals: A comprehensive systematic review. *Expert Systems with Applications*, 187:115950, 2022.
- [39] B. Schölkopf and A. J. Smola. *Learning with kernels: support vector machines, regularization, optimization, and beyond*. MIT Press, 2002.
- [40] F. B. Silva, L. F. Uribe, F. X. Cepeda, V. S. Alquati, J. P. Guimarães, Y. G. Silva, O. dos Santos, A. A. de Oliveira, G. H. de Aguiar, L. Li, et al. Sleep staging algorithm based on smartwatch sensors for healthy and sleep apnea populations. *Sleep Medicine*, 119:535–548, 2024.
- [41] E. R. Sung, Z. Hassan, and J. S. Allam. Emerging technologies and wearables for monitoring and managing sleep disorders in patients with cardiovascular disease. *Current Sleep Medicine Reports*, 10:158–168, 2024.
- [42] J. A. Suykens and J. Vandewalle. Least squares support vector machine classifiers. *Neural Processing Letters*, 9:293–300, 1999.
- [43] S. M. G. P. Togeiro and A. K. Smith. Métodos diagnósticos nos distúrbios do sono. *Brazilian Journal of Psychiatry*, 27:8–15, 2005.
- [44] V. T. Van Hees, S. Sabia, K. N. Anderson, S. J. Denton, J. Oliver, M. Catt, J. G. Abell, M. Kivimäki, M. I. Trenell, and A. Singh-Manoux. A novel, open access method to assess sleep duration using a wrist-worn accelerometer. *PLOS One*, 10(11):e0142533, 2015.
- [45] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, L. u. Kaiser, and I. Polosukhin. Attention is all you need. In *Advances in Neural Information Processing Systems (NeurIPS)*, volume 30, pages 5998–6008, 2017.
- [46] S. Xu, O. Faust, S. Seoni, S. Chakraborty, P. D. Barua, H. W. Loh, H. Elphick, F. Molinari, and U. R. Acharya. A review of automated sleep disorder detection. *Computers in Biology and Medicine*, 150:106100, 2022.