

# Detecção e Classificação de Distúrbios do Sono

---

Candidato: Eduardo Carvalheira Teixeira de Aguiar

Orientador: Prof. Dr. Zanoni Dias

Coorientador: Prof. Dr. Hélio Pedrini

Outubro 2024

Instituto de Computação – Unicamp

# Agenda

Introdução

Objetivos

Fundamentação Teórica

Metodologia

Plano de Trabalho

# Introdução

---

- Distúrbios do sono
- Consequências da privação de sono
- Polissonografia e actigrafia
- *Smartwatches* e conforto
- Diversidade e complexidade dos distúrbios
- Integração com Inteligência Artificial

# Definição do Problema

- Resultados promissores com o uso de tecnologia avançada
  - Fotopleletismografia (PPG)
  - Redes Neurais (NN)
  - Variabilidade da Frequência Cardíaca (HRV)
- Limitações destes resultados
  - Precisão insuficiente para diagnóstico clínico
  - Falta de dados sobre distúrbios como a síndrome das pernas inquietas e distúrbios circadianos
- Sensores PPG e acelerômetros disponíveis em dispositivos vestíveis
- Abordagens *online* e *offline*

- 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 o tipo de abordagem (*online* ou *offline*) é mais adequada para a detecção e classificação de distúrbios do sono?

# Objetivos

---

## Objetivo Geral

- Desenvolver uma metodologia capaz de prever distúrbios do sono

## Objetivos Específicos

- 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
- Publicação dos resultados



## Contribuições Esperadas

- Melhoria na precisão de detecção de distúrbios do sono
- Melhoria na precisão de classificação de distúrbios do sono
- Uso otimizado de sensores vestíveis
- Ampliação de estudos para distúrbios pouco explorados
- Gerar uma solução que utiliza sensores disponíveis em *smartwatches*

# Fundamentação Teórica

---

# Estágios do Sono

- Vigília
- NREM N1
- NREM N2
- NREM N3
- REM

# Distúrbios do Sono

- Insônia
- Apneia do Sono
  - Apneia Obstrutiva do Sono (OSA)
  - Apneia Central do Sono (CSA)
  - Apneia Mista ou Complexa
- Síndrome das Pernas Inquietas (RLS)
- Narcolepsia

- Sequência de observações
- Taxa de amostragem
- Dados organizados cronologicamente

## Árvore de Decisão (DT)

- Nós internos (decisões) e folhas (resultados)
- Processo de divisão dos dados até atingir uma condição de parada


## Floresta Aleatória (RF)

- *Ensemble learning* que combina várias árvores de decisão
- Usa o princípio de *bagging* e seleção aleatória de características
- Eficaz para grandes conjuntos de dados e alta dimensionalidade
- Melhor interpretabilidade comparada a outros modelos

# Máquina de Vetores de Suporte (SVM)

- Encontrar um hiperplano que separa as classes de dados maximizando a margem
- Vetores de suporte: pontos mais próximos do hiperplano que definem a margem
- Amplamente utilizada em reconhecimento de padrões, bioinformática e análise de imagens
- Eficácia em problemas de alta dimensionalidade

# Redes Neurais (NN)



**Figura 1:** Exemplo de rede neural.



# Redes Neurais Recorrentes (RNN)

- Análise de dados temporais ou espaciais
- Redes unidirecionais ou bidirecionais
- RNNs, *Long short-term memory* (LSTM), *Extended Long short-term memory* (xLSTM) e *Gated Recurrent Unit* (GRU)

## Detecção de Apneia

- Chen et al. (2021) [1]
  - Modelos Utilizados
    - Adaptive Boost (melhor desempenho)
    - Árvore de Decisão
    - Naive Bayes
    - Floresta Aleatória
    - Máquina de Vetores de Suporte
  - Base de Dados
    - 20 indivíduos (8 homens, 12 mulheres)
    - Eventos normais de sono e com apneias obstrutivas, centrais e hipopneias
    - Sincroniza dados dos acelerômetros com os de polissonografia
  - Métricas de Desempenho (melhor modelo):
    - Apneia: 96,7% precisão
    - Sono normal: 97,5% precisão

## Detecção de Insônia

- Angelova et al. (2020) [2]
  - Modelos de Máquina de Vetores de Suporte e Floresta aleatória
  - Base de Dados
    - 45 adultos jovens (24 sem sintomas, 21 com insônia aguda).
    - Monitoramento com *Philips Actiwatch* por 7 noites
  - Métricas de Desempenho:
    - RF: 84% precisão considerando  $n$  noites mal dormidas
    - SVM: 73% precisão considerando  $n$  noites mal dormidas
- Kusmakar et al. (2021) [3]
  - Modelos de Máquina de Vetores de Suporte e Floresta Aleatória
  - Base de Dados
    - 80 adultos (40 saudáveis, 40 com insônia crônica)
    - Monitoramento com *Philips Actiwatch* por 7 noites
  - Métricas de Desempenho:
    - RF: 80% precisão, 76% sensibilidade, 82% especificidade
    - Superior à SVM

## Outros Problemas

- Christensen et al. (2015) [4]
  - Detectar os pacientes com narcolepsia utilizando EEG
  - Regressão Logística com regularização Lasso (LASSO)
  - Não utiliza dispositivos vestíveis
  - Estágios do sono são relevantes para a detecção deste distúrbio do sono.
- Korkalainen et al. (2020) [5]
  - Identificar os estágios do sono a partir do sinal de Fotopletismografia (PPG)
  - Pacientes com Apneia Obstrutiva do Sono
  - Modelos de Redes Neurais Convolucionais (CNNs) para aprender as características dos estágios do sono
  - Modelos de RNNs para considerar a distribuição temporal dos estágios

## Outros Problemas

- Ederli et al. (2023) [6]
  - Classificação de estágios de sono e a vigília
  - Utilizou dados de acelerômetro de *smartwatches*
  - Método baseado em Gráficos de Recorrência
  - Utilizando as redes neurais como a *RenNet* e *EfficientNet*
- Silva et al. (2024) [7]
  - Classificação dos estágios do sono
  - População que contém indivíduos com apneia do sono
  - Utilizando diferentes versões do *Galaxy Watch* da *Samsung*
  - Modelo baseado em rede neural recorrente

# Metodologia

---

# Metodologia

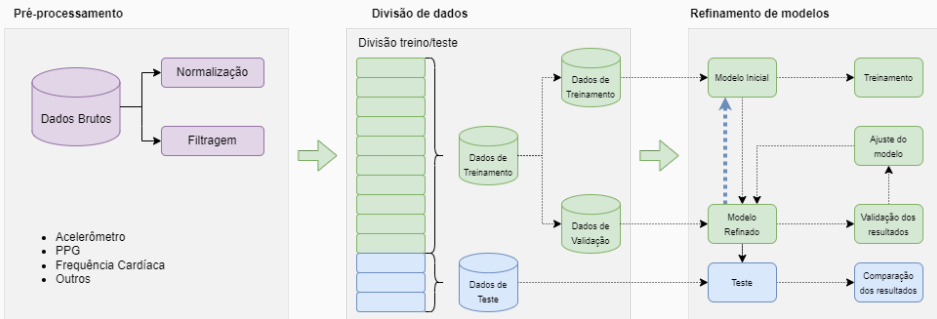


Figura 2: Esquema da metodologia a ser desenvolvida.

- Abordagem orientada a dados, explorando diretamente os dados brutos
- Pré-processamento dos dados com filtragem e normalização
- Utilização de RNNs para analisar a distribuição temporal dos distúrbios do sono
- Modelos de classificação para classificar os intervalos anômalos de sono



# Exemplo de Sinais de Apneia




Figura 3: Fluxo de ar durante diferentes eventos de apneia do sono [1].




Figura 4: Dados de acelerômetro durante a apneia do sono [1].

# Multi-Ethnic Study of Atherosclerosis (MESA)

- Conjunto de dados detalhados sobre sono e saúde cardiovascular
- 2237 participantes usando o *Actiwatch Spectrum* da *Philips* entre 2010 e 2013
- Utiliza dispositivos de polissonografia domiciliar, de actigrafia e do uso de questionários padronizados pela Academia Americana de Medicina do Sono (AASM)
- Dados relacionados à Apneia Obstrutiva do Sono, Insônia, Síndrome das Pernas Inquietas e Sonolência Diurna Excessiva

- Acurácia
- Precisão
- Revocação
- Taxa F1
- Métricas balanceadas

# Plano de Trabalho

---

# Plano de Trabalho

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												○●

- Análise e processamento dos dados do conjunto de dados MESA:
  - Dados de actigrafia pré-processados
  - Dados de Apneia do Sono
- Reprodução de resultados da literatura de Chen et al. (2021) [1]:
  - Replicação dos experimentos realizados com os dados do conjunto de dados MESA
  - Detecção de Apneia Obstrutiva do Sono (OSA)
  - Detecção Apneia Central do Sono (CSA)
  - Utilização de dados de acelerômetro

- [1] Xianda Chen, Yifei Xiao, Yeming Tang, Julio Fernandez-Mendoza, and Guohong Cao.

**ApneaDetector: Detecting sleep apnea with smartwatches.**

*Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 5(2):1–22, 2021.

- [2] Maia Angelova, Chandan Karmakar, Ye Zhu, Sean PA Drummond, and Jason Ellis.

**Automated method for detecting acute insomnia using multi-night actigraphy data.**

*IEEE Access*, 8:74413–74422, 2020.

- [3] Shitanshu Kusmakar, Chandan Karmakar, Ye Zhu, Sergiy Shelyag, Sean PA Drummond, Jason G Ellis, and Maia 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.
- [4] Julie Anja Engelhard Christensen, Emil Gammelmark Schreiner Munk, Paul E Peppard, Terry Young, Emmanuel Mignot, Helge Bjarrup Dissing Sorensen, and Poul Jennum.  
**The diagnostic value of power spectra analysis of the sleep electroencephalography in narcoleptic patients.**  
*Sleep Medicine*, 16(12):1516–1527, 2015.



- [5] Henri Korkalainen, Juhani Aakko, Brett Duce, Samu Kainulainen, Akseli Leino, Sami Nikkonen, Isaac O Afara, Sami Myllymaa, Juha Töyräs, and Timo Leppänen.  
**Deep learning enables sleep staging from photoplethysmogram for patients with suspected sleep apnea.**  
*Sleep*, 43(11):98, 2020.
- [6] Rebeca Padovani Ederli, Didier Vega-Oliveros, Aurea Soriano-Vargas, Anderson Rocha, and Zanoni 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.

- [7] Fernanda B Silva, Luisa FS Uribe, Felipe X Cepeda, Vitor SA Alquati, João PS Guimarães, Yuri GA Silva, Orlem L dos Santos, Alberto A de Oliveira, Gabriel HM de Aguiar, Lin Tzy Li, and Otávio A Penatti. **Sleep staging algorithm based on smartwatch sensors for healthy and sleep apnea populations.** *Sleep Medicine*, 119:535–548, 2024.