

# Detecção e Classificação de Estágios do Sono

Exame de Qualificação de Mestrado

Candidata: Rebeca Padovani Ederli

Orientador: Prof. Dr. Zanoni Dias

Coorientador: Prof. Dr. Anderson Rocha

Instituto de Computação  
Unicamp

17 de outubro de 2022

# Agenda

1. Introdução
2. Fundamentação Teórica
3. Materiais
4. Métodos
5. Plano de Trabalho
6. Resultados Preliminares

- O sono é um mecanismo de recuperação: a frequência cardíaca e a respiração desaceleram enquanto o cérebro processa as experiências do dia.
- “Estamos cada vez mais convencidos de que os distúrbios do sono são novos fatores de risco cardiovascular” [5].
- Pesquisa médica: interesse em diagnósticos mais rápidos e adiantados de distúrbios do sono.

- Utilização de tecnologias vestíveis que são confortáveis como os actígrafos e precisos como a polissonografia (PSG).
- *Smartwatches*: desempenho, precisão e percepção do usuário.




Figura: Métodos de diagnóstico.

# Descrição do Problema

- Existem as notações de Rechtschaffen e Kales (R&K) e da Academia Americana de Medicina do Sono (AASM) para definir cada estágio.
- Alguns autores simplificam o problema:

<b>5 estágios do sono (AASM)</b>	<b>4 estágios do sono</b>	<b>3 estágios do sono</b>	<b>2 estágios do sono</b>
Vigília	Vigília	Vigília	Vigília
N1	Sono leve	NREM	Sono
N2			
N3			
REM	REM	REM	

## Principais desafios

- Classificação dos estágios mais complexos;
- Desequilíbrio das classes no conjunto de dados.

# Descrição do Problema

- Principalmente dados de movimento (acelerômetro) e batimentos cardíacos (fotopletismografia) ao longo do tempo.

Duas formas de utilizar os dados são encontradas na literatura:

- *Online*: apenas os dados conhecidos até o momento atual são analisados;
- *Offline*: dados em torno do momento atual e aplicação de pós-processamentos.




Figura: Exemplo de abordagem *offline* [7].

## Questões de Pesquisa

- Como combinar as informações dos dados de diferentes sensores de *smartwatches* para obter um método competitivo de detecção de sono/vigília?
- Como combinar as informações dos dados de diferentes sensores de *smartwatches* para obter um método competitivo de classificação dos estágios do sono?
- Qual o tipo de abordagem (*online* ou *offline*) é mais adequada para a detecção e classificação dos estágios do sono?

# Introdução

## Objetivo Geral

Investigar técnicas de Inteligência Artificial para melhorar a precisão da detecção e classificação de distúrbios do sono.

## Objetivos Específicos

- Explorar a combinação de dados dos diferentes sensores presentes em *smartwatches*;
- Desenvolver um detector e classificador de estágios do sono.

## Contribuições

Desenvolvimento de uma metodologia aplicando Inteligência Artificial ligada aos desafios presentes na classificação de estágios do sono, a fim de obter um modelo para a tomada de decisão automática com dados disponíveis, e limitados, para esse tipo de problema.



# Fundamentação Teórica: Conceitos e Técnicas

Os estágios do sono e respectiva descrição, segundo a notação da AASM:


R&K (1968)	AASM (2007)	Descrição
	Vigília	Alerta de vigília para sonolência, sentir-se relaxado, adormecer rapidamente.
NREM	S1	N1 Início do sono, transição rápida e superficial. Ao ouvir um ruído não sentir vontade de responder a ele.
	S2	N2 Menor frequência cardíaca e temperatura corporal. Sinais de eletroencefalograma (EEG) continuam a diminuir em frequência enquanto aumentam em amplitude.
	S3	N3 Sono profundo, o tônus muscular, o pulso e a frequência respiratória diminuem. As ondas delta ocorrem no EEG.
	S4	
	REM	Paralisia temporária dos músculos, exceto dos olhos e os músculos que controlam a respiração. "Sono dos sonhos". A atividade cerebral se aproxima dos níveis observados durante a vigília.

Tabela: Descrição resumida dos estágios do sono.

- **Séries temporais:**
  - Observações coletadas de forma sequencial conforme uma determinada taxa de amostragem;
  - Gravações de PSG: épocas de 30s e cada uma delas possui uma *label* correspondente a um estágio do sono.
- **Redes Neurais Convolucionias (CNNs):** As CNNs 1D são comumente aplicadas a séries temporais para capturar características espaciais dos sinais de sensores [9].

# Conceitos e Técnicas: Redes Neurais Recorrentes (RNNs)

- As redes LSTM podem aprender dependências de longo prazo;
- As GRUs evitam o problema do gradiente de fuga.



# Fundamentação Teórica: Trabalhos Relacionados

Trabalho	Estágios	Abordagem	Principais contribuições
Paquet <i>et al.</i> [13] (2007)	2	<i>Offline</i>	<ul style="list-style-type: none"><li>- Avaliação da actigrafia para detectar vigília/sono;</li><li>- Indivíduos consumidores moderados de cafeína.</li></ul>
Sano e Picard [15] (2014)	2	<i>Online</i>	<ul style="list-style-type: none"><li>- Temperatura da pele (ST) desempenhou um papel importante na classificação de vigília/sono.</li></ul>
Haghighyegh <i>et al.</i> [7] (2020)	2	<i>Offline</i>	<ul style="list-style-type: none"><li>- Comparação de diferentes comprimentos de janela para o cálculo da Variabilidade de Frequência Cardíaca (VFC);</li><li>- DeepConvLSTM.</li></ul>
Walch <i>et al.</i> [18] (2019)	3	<i>Online</i>	<ul style="list-style-type: none"><li>- Base de dados <i>Sleep Accel</i>;</li><li>- <i>Feature proxy</i> de relógio, que representa o relógio circadiano;</li><li>- MESA <i>Sleep</i> para verificar generalização.</li></ul>
Fonseca <i>et al.</i> [6] (2017)	3	<i>Offline</i>	<ul style="list-style-type: none"><li>- O treinamento foi feito com dados da base SIESTA [10].</li></ul>

# Fundamentação Teórica: Trabalhos Relacionados

<b>Trabalho</b>	<b>Estágios</b>	<b>Abordagem</b>	<b>Principais contribuições</b>
Beattie <i>et al.</i> [2] (2017)	4	<i>Offline</i>	- Pós-processamento que penaliza padrões fisiológicos improváveis.
Altini e Kinnunen [1] (2021)	4	<i>Offline</i>	- Funções cosseno Walch <i>et al.</i> [18], exponencial e linear para modelar características circadianas.
Radha <i>et al.</i> [14] (2021)	4	<i>Offline</i>	- Transferência de aprendizado; - Treinamento com dados SIESTA [10].
Korkalainen <i>et al.</i> [11] (2020)	5	<i>Online</i>	- Não realiza a extração e seleção prévia de características; - Arquitetura CNN e GRU.

# Trabalhos Relacionados: Outros Problemas

- Acelerômetro e giroscópio de *smartwatches*;
- Reconhecimento e classificação da atividade humana (HAR).
  1. Rede neural residual profunda unidimensional (1D-ResNet) [12];
  2. Rede *WISNet* [16];
  3. Rede *UltraNet* [8].
- Unidade recorrente fechada bidirecional (BiGRU).







Figura: Estrutura do modelo *WISNet* [16].

# Materiais: Bases de Dados

- **Sleep Accel** [18]: 31 indivíduos;
- **MESA Sleep** [3]: 2159 indivíduos.
  - Contagem de atividades e gravações de PSG.



# Materiais: Ferramentas e Recursos Computacionais

## Bibliotecas

NumPy, pandas, Matplotlib, scikit-learn, TensorFlow.

## Ambientes

- Laboratório de Inteligência Artificial (Recod.ai) do Instituto de Computação (IC – Unicamp);
- Google Colab
  - CPU, GPU, TPU, memória RAM e armazenamento.



# Métodos: Metodologia

- Explorar métodos que consideram as informações espaciais e temporais dos dados;
- Combinar os diferentes dados dos sensores de *smartwatches*;
- Aprendizado profundo e abordagem direcionada a dados sem seleção prévia de características.

## Detalhamento

- Características espaciais de cada estágio do sono:
  - CNNs 1D, como a *WaveNet* [17].
- Distribuição temporal dos estágios do sono:
  - RNNs, como as arquiteturas LSTM e GRU [7, 11].
- Realização de experimentos que possam mitigar o desequilíbrio de classes;
- Comparação entre as abordagens *online* e *offline*.

# Métodos: Metodologia

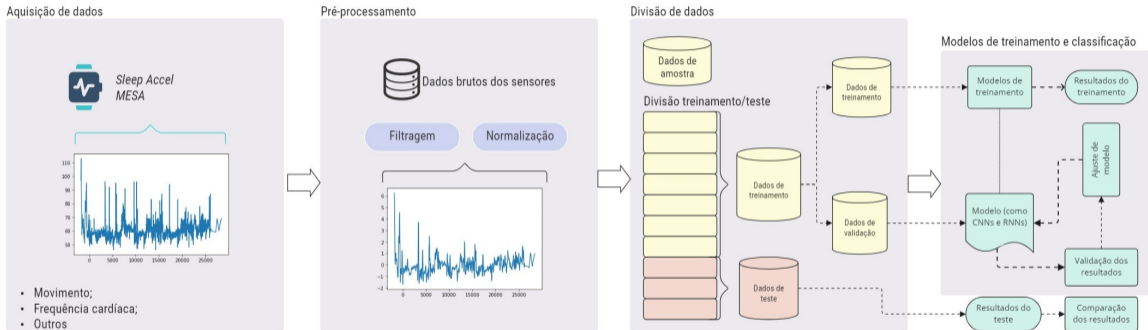


Figura: Esquema de metodologia a ser utilizada.

# Métodos: Métricas de Avaliação

- $c$ : total de classes;
- $n$ : classe atual.

$$\text{sensibilidade}_n = \frac{VP_n}{VP_n + FN_n} \quad (1)$$

$$\text{acurácia balanceada} = \frac{\sum_{n=1}^{n=c} \text{sensibilidade}_n}{c} \quad (2)$$

$$\text{precisão} = \frac{\sum_{n=1}^{n=c} VP_n}{\sum_{n=1}^{n=c} (VP_n + FP_n)} \quad (3)$$

$$F_{1_n} = 2 \times \frac{\text{precisão}_n \times \text{sensibilidade}_n}{\text{precisão}_n + \text{sensibilidade}_n} \quad (4)$$

# Métodos: Métricas de Avaliação

Coeficiente  $\kappa$  (kappa) de Cohen [4]:

$$\kappa = \frac{\% \text{Concordância observada} - \% \text{Concordância por acaso}}{1 - \% \text{Concordância por acaso}} \quad (5)$$

Os valores de  $\kappa$  são interpretados como:

- $\kappa \leq 0,00$ : nenhuma concordância;
- $0,00 < \kappa \leq 0,20$ : concordância leve;
- $0,20 < \kappa \leq 0,40$ : concordância regular;
- $0,40 < \kappa \leq 0,60$ : concordância moderada;
- $0,60 < \kappa \leq 0,80$ : concordância substancial; e
- $0,80 < \kappa \leq 1,00$ : concordância quase perfeita.

# Plano de Trabalho e Cronograma de Execução

- Cronograma das atividades propostas dividido em meses.

	2022												2023												2024	
	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 análise dos resultados.																										
10. PED.																										
11. Documentar e publicar os resultados.																										
12. Escrita do documento da dissertação.																										
13. Defesa da Dissertação de Mestrado.																										■

# Resultados Preliminares: Artigo de Referência

## Artigo de referência para os experimentos

- Walch, Y. Huang, D. Forger, and C. Goldstein. Sleep stage prediction with raw acceleration and photoplethysmography heart rate data derived from a consumer wearable device. *Sleep*, 42(12):zsz180, 2019;
- Disponibilizam a base de dados *Sleep Accel*;
- Detecção de vigília/sono e classificação em três estágios do sono.

## Principais objetivos dos experimentos

- Estudar a base de dados e entender as dificuldades que podem ser encontradas;
- Estudar a **modelagem** do problema.

# Resultados Preliminares: Base de Dados

## *Sleep Accel* [18]

- *Apple Watch*: dados de acelerômetro e frequência cardíaca;
- Dados de PSG para validação.
- Desbalanceada: proporção de 12 (sono) para 1 (vigília).




Figura: Quantidade de dados de vigília e sono a cada hora após o início das gravações de PSG.

# Resultados Preliminares: Descrição dos Experimentos

## Observações

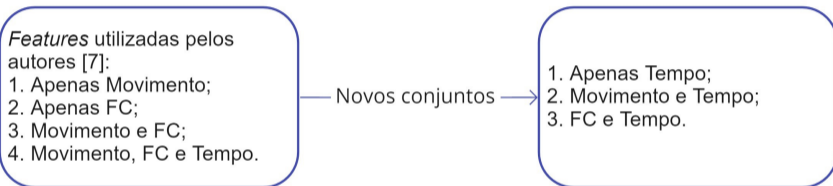
- Épocas de 30 segundos;
- Conjunto de treinamento: 70% dos dados;
- Conjunto de teste: 30% dos dados;
- A divisão de dados foi feita aleatoriamente 20 vezes;
- Não há um conjunto de validação;
- Acurácia e acurácia balanceada;
- Abordagem *online*.





# Resultados Preliminares: Descrição dos Experimentos

1. **Novos conjuntos de features:** totalizando 7 combinações diferentes;



2. **Aumentação de dados:** considerar que 10 horas antes do início das gravações de PSG, os indivíduos estavam acordados (vigília).
  - Proporção de 12 (sono) para 1 (vigília) foi para 7 (sono) para 1 (vigília).

# Resultados Preliminares: Descrição dos Experimentos

## 3. Inclusão de features de períodos passados:

- As *features* de cada período  $c$  são compostas pelas *features* de  $n$  períodos passados.
- Caso não exista uma  $Feature_x$  ( $x < 0$ ), a  $Feature_0$  é utilizada no seu lugar.

### Exemplo com $n = 2$ (movimento)

Período	<i>features</i>
0	31.640606
1	22.570999
2	19.341522
3	21.960207

Tabela: Sem considerar períodos passados.

Período	<i>features</i>		
0	31.640606	31.640606	<b>31.640606</b>
1	31.640606	31.640606	<b>22.570999</b>
2	31.640606	22.570999	<b>19.341522</b>
3	22.570999	19.341522	<b>21.960207</b>

Tabela: Considerando  $n = 2$  períodos passados.

# Resultados Preliminares: Aumentação de Dados

Conjunto de <i>features</i>	Dados originais		Com aumento de dados	
	Acurácia	Ac. balanceada	Acurácia	Ac. balanceada
Apenas movimento	0.84	0.73	<b>0.88</b>	<b>0.79</b>
Apenas FC	0.67	0.64	0.68	0.67
Apenas tempo	0.80	0.65	0.45	0.54
Movimento e FC	0.85	0.74	<b>0.88</b>	<b>0.79</b>
Movimento e tempo	<b>0.87</b>	0.74	<b>0.88</b>	<b>0.79</b>
FC e tempo	0.77	0.74	0.68	0.66
Movimento, FC e tempo	<b>0.87</b>	<b>0.77</b>	<b>0.88</b>	<b>0.79</b>

Tabela: Classificador Regressão Logística.

- O resultado de 79% de acurácia balanceada é obtido com a aumento de dados utilizando apenas o movimento.

# Resultados Preliminares: Aumentação de Dados

Conjunto de <i>features</i>	Dados originais		Com aumento de dados	
	Acurácia	Ac. balanceada	Acurácia	Ac. balanceada
Apenas movimento	0.76	0.77	0.81	0.81
Apenas FC	0.54	0.65	0.67	0.68
Apenas tempo	<b>0.87</b>	0.64	0.73	0.70
Movimento e FC	0.75	0.77	0.82	0.82
Movimento e tempo	0.80	0.80	0.82	0.82
FC e tempo	0.82	0.74	0.76	0.71
Movimento, FC e tempo	0.81	<b>0.81</b>	<b>0.83</b>	<b>0.83</b>

Tabela: Classificador Random Forest.

- Com a aumento de dados, as acurácias balanceadas de quase todos os conjuntos são maiores.

# Resultados Preliminares: $n = 80$ Períodos Passados

- Testes com  $n$  entre 0 e 128 (saltos de potência de 2) e  $n$  entre 10 e 100 (saltos de 10).

Regressão Logística			
	Conjunto de <i>features</i>	Acurácia	Ac. balanceada
Sem períodos passados	Apenas movimento	0.84	0.73
	Apenas FC	0.67	0.64
	Apenas tempo	0.80	0.65
	Movimento e FC	0.85	0.74
	Movimento e tempo	<b>0.87</b>	0.74
	FC e tempo	0.77	0.74
	Movimento, FC e tempo	<b>0.87</b>	0.77
	Com 80 períodos passados	Apenas movimento	0.85

# Resultados Preliminares: $n = 80$ Períodos Passados

- O melhor resultado obtido foi com  $n = 80$  para ambos os classificadores.

Random Forest			
	Conjunto de <i>features</i>	Acurácia	Ac. balanceada
Sem períodos passados	Apenas movimento	0.76	0.77
	Apenas FC	0.54	0.65
	Apenas tempo	<b>0.87</b>	0.64
	Movimento e FC	0.75	0.77
	Movimento e tempo	0.80	0.80
	FC e tempo	0.82	0.74
	Movimento, FC e tempo	0.81	<b>0.81</b>
Com 80 períodos passados	Apenas movimento	0.77	<b>0.81</b>

# Resultados Preliminares: Aumentação de Dados e Períodos Passados

Configuração	Acurácia		Ac. balanceada	
	Média	Desvio	Média	Desvio
Original	0.87	0.019	0.73	0.025
Com dados passados	0.87	0.023	0.78	0.034
Com aumento de dados	0.89	0.013	0.78	0.018
Com dados passados e aumento de dados	<b>0.91</b>	0.009	<b>0.85</b>	0.023

Tabela: Regressão Logística e apenas movimento (3 eixos do acelerômetro), com  $n = 30$  dados passados (quando aplicável).

# Resultados Preliminares: Aumentação de Dados e Períodos Passados

Configuração	Acurácia		Ac. balanceada	
	Média	Desvio	Média	Desvio
Original	0.75	0.042	0.77	0.025
Com dados passados	0.80	0.031	0.80	0.022
Com aumento de dados	0.85	0.018	0.80	0.015
Com dados passados e aumento de dados	<b>0.86</b>	0.028	<b>0.86</b>	0.015

Tabela: Random Forest e apenas movimento (3 eixos do acelerômetro), com  $n = 30$  dados passados (quando aplicável).



# Resultados Preliminares: Conclusões

- *Feature* de movimento é importante na detecção de vigília/sono;
- A aumento de dados e a utilização de dados passados, em conjunto, melhoram significativamente os resultados;
- A acurácia encontra valores otimistas para determinar o desempenho dos modelos, sendo apenas adequada em conjuntos balanceados (o que não é o caso deste problema).

# Resultados Preliminares: Classificação em Três Estágios

Conjunto de <i>features</i>	Original		Com dados passados e aumento de dados	
	Acurácia	Ac. balanceada	Acurácia	Ac. balanceada
Apenas movimento	<b>0.70</b>	0.45	<b>0.72</b>	0.54
Apenas FC	0.67	0.41	0.66	0.46
Apenas tempo	<b>0.70</b>	0.34	0.66	0.44
Movimento e FC	0.68	0.47	0.71	0.59
Movimento e tempo	<b>0.70</b>	0.45	<b>0.72</b>	0.55
FC e tempo	0.67	0.45	0.66	0.49
Movimento, FC e tempo	0.68	<b>0.50</b>	0.71	<b>0.61</b>

**Tabela:** Comparação dos resultados obtidos pela Regressão Logística com a configuração original e com a utilização de aumento de dados e  $n = 30$  dados passados.

# Resultados Preliminares: Classificação em Três Estágios

Conjunto de <i>features</i>	Original		Com dados passados e aumento de dados	
	Acurácia	Ac. balanceada	Acurácia	Ac. balanceada
Apenas movimento	0.55	0.52	<b>0.56</b>	0.58
Apenas FC	0.53	0.49	0.51	0.56
Apenas tempo	0.44	0.47	0.48	0.50
Movimento e FC	0.55	0.59	0.55	<b>0.67</b>
Movimento e tempo	0.47	0.55	0.53	0.56
FC e tempo	0.56	0.57	0.53	0.59
Movimento, FC e tempo	<b>0.59</b>	<b>0.63</b>	0.55	<b>0.67</b>

**Tabela:** Comparação dos resultados obtidos pelo Random Forest com a configuração original e com a utilização de aumento de dados e  $n = 30$  dados passados.

# Resultados Preliminares: Conclusões e Considerações Finais

- Para a classificação em três estágios, não houve resultados satisfatórios em nenhum dos cenários;
- A aumento de dados pode ter causado a melhoria da classificação de vigílias;
- A FC desempenhou papel importante (Walch *et al.* [18] também destacam esse ponto).

## Considerações Finais

- É possível observar algumas dificuldades e possibilidades de soluções;
- Visão geral do problema e das bases de dados;
- Direcionamento à investigação de novas metodologias.

# Referências I

- [1] 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.
- [2] Z. Beattie, Y. Oyang, A. Statan, A. Ghoreyshi, A. Pantelopoulos, A. Russell, and C. Heneghan.  
Estimation of sleep stages in a healthy adult population from optical plethysmography and accelerometer signals.  
*Physiological Measurement*, 38(11):1968–1979, 2017.
- [3] X. Chen, R. Wang, P. Zee, P. L. Lutsey, S. Javaheri, C. Alcántara, C. L. Jackson, M. A. Williams, and S. Redline.  
Racial/ethnic differences in sleep disturbances: the Multi-Ethnic Study of Atherosclerosis (MESA).  
*Sleep*, 38(6):877–888, 2015.
- [4] J. Cohen.  
A coefficient of agreement for nominal scales.  
*Educational and Psychological Measurement*, 20(1):37–46, 1960.
- [5] 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. Maki-Nunes, 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.  
1º 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.
- [6] P. Fonseca, T. Weysen, M. S. Goelema, E. I. Møst, M. Radha, C. Lusingh Scheurleer, L. van den Heuvel, and R. M. Aarts.  
Validation of photoplethysmography-based sleep staging compared with polysomnography in healthy middle-aged adults.  
*Sleep*, 40(7), 2017.

# Referências II

- [7] S. Haghayegh, S. Khoshnevis, M. H. Smolensky, K. R. Diller, and R. J. Castriotta. Deep neural network sleep scoring using combined motion and heart rate variability data. *Sensors*, 21(1):25, 2020.
- [8] H. A. Imran. Ultanet: An antithesis neural network for recognizing human activity using inertial sensors signals. *IEEE Sensors Letters*, 6, 1 2022.
- [9] S. Kiranyaz, O. Avci, O. Abdeljaber, T. Ince, M. Gabbouj, and D. J. Inman. 1d convolutional neural networks and applications: A survey. *Mechanical Systems and Signal Processing*, 151:107398, 4 2021.
- [10] G. Klose, B. Kemp, T. Penzel, A. Schlogl, P. Rappelsberger, E. Trenker, G. Gruber, J. Zeithofer, B. Saletu, W. Herrmann, S. Himanen, D. Kunz, M. Barbanoj, J. Roschke, A. Varri, and G. Dorffner. The SIESTA project polygraphic and clinical database. *IEEE Engineering in Medicine and Biology Magazine*, 20(3):51–57, 2001.
- [11] 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.
- [12] S. Mekruksavanich, P. Jantawong, and A. Jitpattanukul. Recognition of complex human activities for wellness management from smartwatch using deep residual neural network. In *International Conference on Digital Arts, Media and Technology with ECTI Northern Section Conference on Electrical, Electronics, Computer and Telecommunications Engineering (ECTI DAMT & NCON)*, pages 350–353. IEEE, 2022.
- [13] J. Paquet, A. Kawinska, and J. Carrier. Wake detection capacity of actigraphy during sleep. *Sleep*, 30(10):1362–1369, 2007.

# Referências III

- [14] M. Radha, P. Fonseca, A. Moreau, M. Ross, A. Cerny, P. Anderer, X. Long, and R. M. Aarts. A deep transfer learning approach for wearable sleep stage classification with photoplethysmography. *npj Digital Medicine*, 4(1):1–11, 2021.
- [15] A. Sano and R. W. Picard. Comparison of sleep-wake classification using electroencephalogram and wrist-worn multi-modal sensor data. In *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pages 930–933. IEEE, 2014.
- [16] H. Sharen, P. Rukmani, L. J. Anbarasi, and A. H. Gandomi. WISNet: A deep neural network based human activity recognition system. *Research Square (preprint)*, 2022.
- [17] A. van den Oord, S. Dieleman, H. Zen, K. Simonyan, O. Vinyals, A. Graves, N. Kalchbrenner, A. Senior, and K. Kavukcuoglu. Wavenet: A generative model for raw audio. 9 2016.
- [18] O. Walch, Y. Huang, D. Forger, and C. Goldstein. Sleep stage prediction with raw acceleration and photoplethysmography heart rate data derived from a consumer wearable device. *Sleep*, 42(12):zsz180, 2019.

Obrigada!



# Descrição de Experimento

## 4. Features de movimento com os eixos x, y e z

- Walch *et al.* [18] converteram o movimento em um contador de atividades (eixo z);
- Três eixos: contador x, contador y e contador z;
- *Features* de valores estatísticos (como média, desvio padrão, entropia, entre outros).

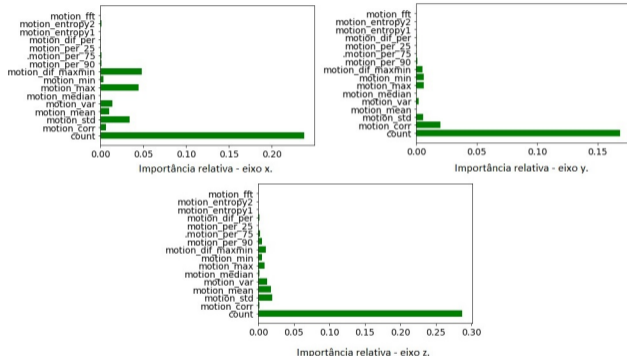


Figura: Importância relativa de cada *feature* com Random Forest.

# Classificação em Três Estágios

## Matriz de Confusão




Figura: Sem e com aumento de dados e adição de dados passados com Regressão Logística (movimento, FC e tempo).

- A classificação do estágio NREM melhorou com as configurações adicionais.

# Classificação em Três Estágios

## Matriz de Confusão




Figura: Sem e com aumento de dados e adição de dados passados com Random Forest (movimento, FC e tempo).

- Ambos os classificadores apresentaram melhorias na classificação das vigílias.