

Representações Visuais para Classificação dos Estágios do Sono

Rebeca Padovani Ederli

Orientador: Prof. Dr. Zanoni Dias
Coorientador: Prof. Dr. Anderson Rocha

IC – Unicamp

02 de maio de 2024

Sumário

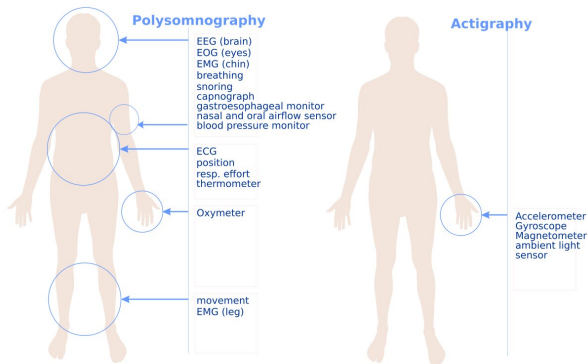
- 1 Introdução
- 2 Fundamentação Teórica
- 3 Materiais e Métodos
- 4 Experimentos e Resultados
- 5 Conclusões e Trabalhos Futuros

Contexto

- As mudanças no estilo de vida contribuem para a redução da duração do sono;
- O sono insuficiente está ligado a problemas de saúde como doenças cardiovasculares e declínio cognitivo [7];
- Pesquisa médica: interesse em diagnósticos mais rápidos e precisos de distúrbios do sono.

Monitoramento do Sono

- A polissonografia (PSG) é o padrão-ouro clínico;
- Actígrafos são dispositivos parecidos com relógios.



Tecnologias Vestíveis

- *Smartwatches* oferecem automação na detecção de padrões de sono, preenchendo a lacuna entre actigrafia e PSG;
- Possibilitam o ajuste de hábitos e melhorarias na saúde do usuário.

Justificativa

- Classificação dos estágios do sono é a **primeira etapa** para a classificação de distúrbios do sono.
- **Abordagem promissora:** imagens para representar dados de sensores de *smartwatches*
 - técnica explorada para outros tipos de problemas [1, 20];
 - ainda não investigada na classificação dos estágios do sono;
 - essa representação é utilizada para superar ruídos.

Explorar a representação de dados do sono (*smartwatches*) em imagens e empregar algoritmos DL para classificar os estágios do sono.

Questões de Pesquisa

- Como combinar as informações dos dados de diferentes sensores de *smartwatches* para obter um método competitivo de classificação dos estágios do sono?
- Quais são as representações de imagens mais adequadas para classificar estágios do sono?
- Quais técnicas de aprendizado de máquina podem tornar a classificação dos estágios do sono mais precisa?

Objetivos

Objetivo Geral

Investigar técnicas de DL para melhorar a classificação dos estágios do sono, representando os dados de *smartwatch* visualmente.

Objetivos Específicos

- Comparar as diferentes representações geradas;
- Explorar a combinação de informações dos diversos sensores;
- Aplicar técnicas de ML para melhorar os resultados originais.

Contribuições

- Desenvolvimento de uma metodologia para classificação de estágios do sono, visando criar um modelo de tomada de decisão automática com dados disponíveis, e limitados, para esse tipo de problema.

Estágios do Sono

Estágios do sono, segundo a AASM [13]:

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.
	S4		As ondas delta ocorrem no EEG.
	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.	

Trabalhos relacionados simplificam o problema em:

5 estágios do sono (AASM)	4 estágios do sono	3 estágios do sono	2 estágios do sono
Vigília	Vigília	Vigília	Vigília
N1	Sono leve	NREM	Sono
N2			
N3	Sono profundo		
REM	REM	REM	

Fundamentação Teórica: Trabalhos Relacionados

Trabalho	Estágios	Representação	Principais Características
Paquet <i>et al.</i> [23] (2007)	2	<i>Features</i>	- Avaliação da actigrafia para detectar vigília/sono; - Indivíduos consumidores moderados de caféina.
Sano e Picard [27] (2014)	2	<i>Features</i>	- Temperatura da pele (ST) desempenhou um papel importante na classificação de vigília/sono.
Haghighyegh <i>et al.</i> [12] (2020)	2	<i>Features</i>	- Comparação de diferentes comprimentos de janela para o cálculo da Variabilidade de Frequência Cardíaca (VFC); - <i>DeepConvLSTM</i> .
Walch <i>et al.</i> [30] (2019)	3	<i>Features</i>	- Base de dados <i>Sleep Accel</i> ; - <i>Feature proxy</i> de relógio, que representa o relógio circadiano; - MESA <i>Sleep</i> para verificar generalização.
Fonseca <i>et al.</i> [11] (2017)	3	<i>Features</i>	- O treinamento foi feito com dados da base SIESTA [16].
Beattie <i>et al.</i> [4] (2017)	4	<i>Features</i>	- Pós-processamento que penaliza padrões fisiológicos improváveis.
Altini e Kinnunen [2] (2021)	4	<i>Features</i>	- Funções cosseno [30], exponencial e linear para modelar características circadianas.
Radha <i>et al.</i> [25] (2021)	4	<i>Features</i>	- Transferência de aprendizado; - Treinamento com dados SIESTA [16].
Korkalainen <i>et al.</i> [17] (2020)	5	Dados brutos	- Não realiza a extração e seleção prévia de características; - Arquitetura CNN e GRU.

Tabela: Resumo dos trabalhos relacionados que classificam os estágios do sono.

Outros Problemas

Trabalho	Problema	Representação	Principais Características
Sharen <i>et al.</i> [28] (2022)	HAR	Dados brutos	- Conjunto WISDM [18]; - CNN 1D.
Imran [14] (2022)	HAR	Dados brutos	- Conjunto WISDM [18]; - <i>UltraNet</i> [14] com BiGRU [5].
Lu e Tong [20] (2019)	HAR	Imagens (RP)	- <i>ResNet</i> com imagens RGB; - Eixos x , y e z como canais RGB.
Qin <i>et al.</i> [24] (2020)	HAR	Imagens (GAF)	- Conjuntos de dados: HHAR [29] e MHEALTH [3]; - <i>ResNet</i> de fusão.
Ortega <i>et al.</i> [22] (2021)	Reconhecimento de ingestão de alimentos e bebidas	Imagens (GAF, MTF, espectrogramas)	- Redes <i>multi-input</i> e CNNs.

Limitações dos Trabalhos Relacionados

- Poucos trabalhos para classificar estágios do sono com dados de *smartwatches*;
- Uso de imagens para classificar estágios do sono ainda não foi explorado.

Lacuna de pesquisa: transformar séries temporais em imagens para classificar estágios do sono.

Materiais e Métodos: Metodologia

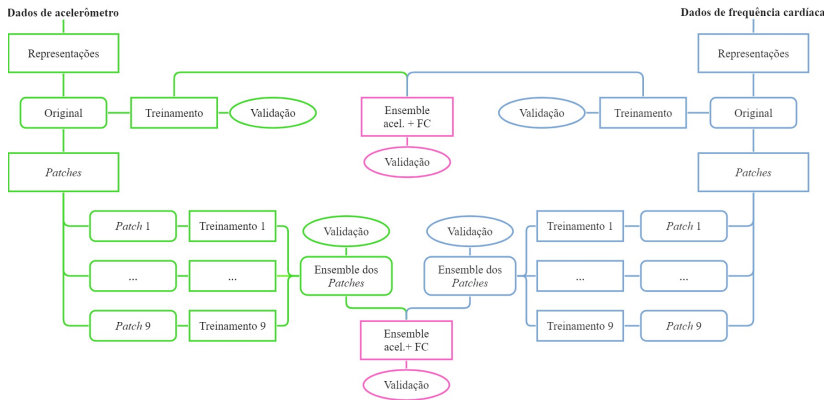


Figura: Esquema da metodologia.

Preparação dos Dados

Dados brutos de acelerômetro e frequência cardíaca:

- Interpolação para 600 medições [30];
- Imagens de dimensão 600×600 (exceto Espectrogramas);
- Imagens redimensionadas para 224×224 ;
- Imagem RGB da composição dos eixos x , y e z do acelerômetro.




Figura: Classificação binária dos dados de acelerômetro de um indivíduo.

Representações

Dada uma série temporal $X = \{x_1, x_2, \dots, x_N\}$:

Gráficos de Recorrência (RP)

- Eckmann *et al.* [8];

$$R[i, j] = \begin{cases} 1 & \text{se } d(x[i], x[j]) \leq \varepsilon \\ 0 & \text{caso contrário} \end{cases}$$

- Diversas alternativas para o limiar de recorrência ε [9];
- *Unthresholded* RP [15]: distâncias em escala de cinza.

Markov Transition Field (MTF) [31]

- Probabilidade de transição entre estados;
- A série temporal X é discretizada em Q quantis (\tilde{X});
- Matriz de Transição de Markov: cada elemento é a frequência de transição de q_i para q_j .

Representações

Dada uma série temporal $X = \{x_1, x_2, \dots, x_N\}$:

Gramian Angular Field (GAF) [31]

- Conversão para ângulos da série X normalizada (\tilde{X});

$$\phi_i = \arccos(\tilde{x}_i)$$

$$G_{i,j}^{(\text{GASF})} = \cos(\phi_i + \phi_j)$$

$$G_{i,j}^{(\text{GADF})} = \sin(\phi_i - \phi_j)$$

- GADF enfatiza as diferenças angulares entre pontos de tempo consecutivos [24].

Espectrogramas

- Aplicação da *Short-Time Fourier Transform* (STFT);

$$E(x(n)) = |STFT\{x(n)\}(m, k)|^2$$

- Permite visualizar como o espectro de frequência do sinal varia com o tempo [32].

Representações




Tabela: Diferentes representações dos dados de **acelerômetro**.

Representações






Tabela: Diferentes representações dos dados de **frequência cardíaca**.

Patches



(a) Imagem original
(600×600).



(b) Patches
(224×224 cada).

Figura: Imagens de “vigília” geradas com GAF e dados de acelerômetro.

- Aplicações de visualização de imagens e ML [19, 26];
- Principal objetivo: melhorar o foco em detalhes locais da imagem;
- Combinação das previsões dos *patches* para a imagem inteira.

Ensembles

- **Média Simples:** média aritmética das predições;
- **Média Ponderada:** cada predição possui um peso diferente. 1000 conjuntos aleatórios de n pesos para encontrar a melhor combinação em cada caso;
- **Rede Simples:** as predições são entradas para uma rede neural simples;
- **Deep Features:** vetores de características são extraídos das camadas profundas e são entradas para um modelo final.

Ensembles

Configurações de dados:

- a) imagens originais dos dados de acelerômetro + imagens originais dos dados de frequência cardíaca;
- b) *patches* dos dados de acelerômetro;
- c) *patches* dos dados de frequência cardíaca; e
- d) *patches* dos dados de acelerômetro + *patches* dos dados de frequência cardíaca.

Ensemble aplicado e respectivos tipos de dados

- **Média Simples:** a, b, c, d;
- **Média Ponderada:** a ($n = 2$), b ($n = \text{número de } patches = 9$), c ($n = \text{número de } patches = 9$), d ($n = 9 \times 2 = \text{número de } patches \times \text{número de tipos de dados}$);
- **Rede Simples:** b, c;
- **Deep Features:** a.

Métricas de Avaliação

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

$$\text{sensibilidade}_n = \frac{VP_n}{VP_n + FN_n}$$

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


Coeficiente κ (kappa) de Cohen [6]:

$$\kappa = \frac{\% \text{concordância observada} - \% \text{concordância por acaso}}{1 - \% \text{concordância por acaso}}$$


- $\kappa \leq 0,00$: 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.

Conjunto de Dados: *Sleep Accel (Apple Inc.)* [30]


● 31 indivíduos.



(a) Dados de acelerômetro.



(b) Dados de frequência cardíaca.

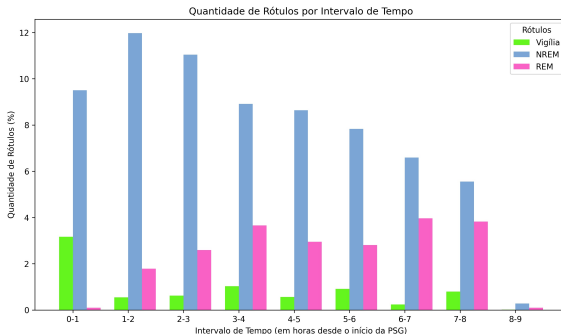


(c) Rótulos dos estágios do sono (PSG).

Conjunto de Dados

Desbalanceamento na *Sleep Accel*:

- **Dois estágios** (12 “sono” / 1 “vigília”) e
- **Três estágios** (9 “NREM” / 3 “REM” / 1 “vigília”).



Conjunto de Dados

Alguns problemas com o artigo de referência:

- *Feature* “tempo” baseada no tempo desde o início da PSG;
- Modelos com *overfitting* e ausência de um conjunto de validação;
- A acurácia balanceada é mais adequada para esse tipo de base.

Experimentos

- *EfficientNet* pré-treinada na *ImageNet*;
 - 90% das primeiras camadas congeladas;
 - *Fine tuning*: uma camada densa de tamanho 512 com 50% de *dropout* e uma camada densa de tamanho 256 com 20% de *dropout*;
- *k-fold* com $k = 5$;
- **Dados de um mesmo indivíduo não foram utilizados para treinamento e validação simultaneamente;**
- Atribuição de pesos às classes.

Comparação com Outras Representações

- Extração de *features*;
- Dados brutos.

Descrição dos Experimentos

Dois cenários:

- 1 Classificação de sono/vigília e
- 2 Classificação dos estágios do sono (vigília / NREM / REM);

Os experimentos permitem comparar:

- Diferentes representações visuais;
- Acelerômetro (AC) *versus* frequência cardíaca (FC);
- Configurações dos dados: original; *patches*; e diferentes *ensembles*:
 - *Ensembles* AC + FC;
 - *Ensembles* dos *patches* dos dados de acelerômetro;
 - *Ensembles* dos *patches* dos dados de frequência cardíaca;
 - *Ensembles patches* AC + *patches* FC.

Resultados e Discussões: Classificação de Sono/Vigília

		RP		GAF		MTF		Espectrogramas	
Rede	Config.	AC	FC	AC	FC	AC	FC	AC	FC
Eff.Net	Original	76.620	69.910	79.630	69.318	77.436	64.882	78.340	61.216
Ensembles AC + FC	M. Simples	71.382		69.038		71.269		75.937	
	M. Ponderada	76.541		77.569		74.946		78.190	
	Deep Features	75.592		77.610		75.430		77.124	
Eff.Net	Patch 1	76.796	66.364	76.790	65.686	74.298	63.212	72.044	51.074
	Patch 2	77.916	68.840	77.734	67.934	75.794	64.664	76.564	51.235
	Patch 3	73.486	64.176	73.166	64.736	71.452	61.166	71.658	51.250
	Patch 4	79.970	69.010	79.568	68.068	78.572	64.990	76.686	54.830
	Patch 5	76.852	66.056	78.704	69.044	76.818	65.122	76.432	52.832
	Patch 6	78.206	67.444	77.738	68.506	75.482	65.874	71.900	52.376
	Patch 7	74.058	62.856	72.366	62.610	72.376	60.772	77.718	53.138
	Patch 8	80.302	69.396	79.828	67.680	78.078	66.412	76.360	51.440
	Patch 9	76.320	64.990	77.736	63.938	74.792	63.210	71.938	53.070
Ensembles dos Patches	M. Simples	80.388	71.393	82.358	73.712	80.034	70.209	79.105	54.903
	M. Ponderada	80.382	71.282	82.035	72.148	80.203	68.777	79.007	54.907
	Rede Simples	80.259	70.812	81.544	72.874	79.853	69.410	79.032	53.302
Ensembles P. AC + P. FC	M. Simples	76.144		77.245		78.283		77.778	
	M. Ponderada	79.276		81.444		80.327		78.641	

Tabela: Acurácias balanceadas para a classificação de sono/vigília.

Classificação de Sono/Vigília

- Utilizar *Ensemble* dos *Patches* apresenta um ganho significativo, comparando com dados Originais;
 - RP: até 3,7 pontos percentuais;
 - GAF: até 2,7 pontos percentuais;
 - MTF: até 2,9 pontos percentuais;
 - Espectrogramas: até 0,7 pontos percentuais.

Matrizes de Confusão: RP

Verdadeiro	Vigília	0.70	0.30
	Sono	0.17	0.83
		Vigília	Sono
		Predito	

(a) Originais AC.

Verdadeiro	Vigília	0.69	0.31
	Sono	0.29	0.71
		Vigília	Sono
		Predito	

(b) Originais FC.

Verdadeiro	Vigília	0.69	0.31
	Sono	0.16	0.84
		Vigília	Sono
		Predito	

(c) E. AC + FC.

Verdadeiro	Vigília	0.82	0.18
	Sono	0.22	0.78
		Vigília	Sono
		Predito	

(d) Patches AC.

Verdadeiro	Vigília	0.73	0.27
	Sono	0.30	0.70
		Vigília	Sono
		Predito	

(e) Patches FC.

Verdadeiro	Vigília	0.79	0.20
	Sono	0.21	0.79
		Vigília	Sono
		Predito	

(f) E. P. AC + FC.

- Maior sensibilidade: *ensemble* dos dados originais;
- Acertos de “vigília” aumentaram com o uso de *patches*.

Matrizes de Confusão: GAF

Verdadeiro	Vigília	0.76	0.24
	Sono	0.17	0.83
		Vigília	Sono
		Predito	

(a) Originais AC.

Verdadeiro	Vigília	0.70	0.30
	Sono	0.31	0.69
		Vigília	Sono
		Predito	

(b) Originais FC.

Verdadeiro	Vigília	0.74	0.26
	Sono	0.19	0.81
		Vigília	Sono
		Predito	

(c) E. AC + FC.

Verdadeiro	Vigília	0.82	0.18
	Sono	0.18	0.82
		Vigília	Sono
		Predito	

(d) Patches AC.

Verdadeiro	Vigília	0.69	0.31
	Sono	0.21	0.79
		Vigília	Sono
		Predito	


(e) Patches FC.

Verdadeiro	Vigília	0.78	0.22
	Sono	0.15	0.85
		Vigília	Sono
		Predito	


(f) E. P. AC + FC.

- Maior sensibilidade: *ensemble* dos *patches* de AC + *patches* de FC;
- A classificação com dados de AC é balanceada ao usar *patches*.

Matrizes de Confusão: MTF



(a) Originais AC. (b) Originais FC. (c) E. AC + FC.



(d) Patches AC. (e) Patches FC. (f) E. P. AC + FC.

- Maior sensibilidade: *ensemble* dos dados originais;
- A classificação com dados de AC é balanceada ao usar *patches*.

Matrizes de Confusão: Espectrogramas

Verdadeiro	Vigília	0.78	0.22
	Sono	0.21	0.79
		Vigília	Sono
		Predito	

(a) Originais AC.

Verdadeiro	Vigília	0.62	0.38
	Sono	0.39	0.61
		Vigília	Sono
		Predito	

(b) Originais FC.

Verdadeiro	Vigília	0.76	0.24
	Sono	0.20	0.80
		Vigília	Sono
		Predito	

(c) E. AC + FC.

Verdadeiro	Vigília	0.83	0.17
	Sono	0.24	0.76
		Vigília	Sono
		Predito	

(d) Patches AC.

Verdadeiro	Vigília	0.92	0.08
	Sono	0.81	0.19
		Vigília	Sono
		Predito	


(e) Patches FC.

Verdadeiro	Vigília	0.77	0.23
	Sono	0.20	0.80
		Vigília	Sono
		Predito	


(f) E. P. AC + FC.

- Maior sensibilidade: ambos os *ensembles*;
- Acertos de “vigília” aumentam com o uso de *patches* e dados de AC.

Classificação de Sono/Vigília: Noite de Sono



(a) Dados originais de acelerômetro.



(b) *Ensemble dos patches* dos dados de acelerômetro.

- Dados Originais: mais erros de “sono” para “vigília” no início da noite;
- *Ensemble dos Patches*: redução de erros “sono” para “vigília”;
- *Ensemble dos Patches*: erros “vigília” para “sono” com maior frequência por volta das 2 e 6 horas.

Classificação dos Estágios do Sono

		RP		GAF		MTF		Espectrogramas	
Rede	Config.	AC	FC	AC	FC	AC	FC	AC	FC
Eff.Net	Original	55.734	57.854	57.684	57.092	55.004	53.354	55.956	40.326
Ensembles AC + FC	M. Simples	46.009		46.135		46.354		52.410	
	M. Ponderada	50.244		50.104		50.366		56.002	
	Deep Features	53.598		53.392		54.818		51.006	
Eff.Net	Patch 1	53.676	54.080	54.956	53.926	51.584	51.476	52.722	35.330
	Patch 2	55.288	55.508	56.224	55.602	53.636	51.652	52.122	35.344
	Patch 3	44.114	45.854	52.060	51.468	45.788	47.920	43.610	35.628
	Patch 4	56.896	55.276	55.504	55.228	55.006	52.792	52.052	34.506
	Patch 5	54.624	54.364	56.178	54.722	53.544	50.616	52.038	36.252
	Patch 6	55.476	55.188	56.452	55.914	52.222	52.048	40.672	35.420
	Patch 7	49.712	50.064	51.236	50.284	46.450	48.034	53.518	35.342
	Patch 8	57.438	56.036	57.878	54.782	55.322	51.646	50.524	35.632
	Patch 9	54.212	53.930	55.880	53.246	52.538	50.924	48.286	35.330
Ensembles dos Patches	M. Simples	59.191	61.866	60.661	62.180	58.375	57.814	55.534	39.501
	M. Ponderada	59.405	61.459	60.164	61.568	58.300	57.340	57.362	39.277
	Rede Simples	49.960	52.435	51.186	51.247	48.293	51.293	48.689	39.331
Ensembles P. AC + P. FC	M. Simples	49.849		49.984		50.953		53.089	
	M. Ponderada	61.481		61.172		60.974		55.346	

Tabela: Acurácias balanceadas para a classificação dos estágios do sono.

Classificação dos Estágios do Sono

- Utilizar *Ensemble* dos *Patches* apresenta um ganho significativo, comparando com dados Originais:
 - RP: até 4,0 pontos percentuais;
 - GAF: até 4,5 pontos percentuais;
 - MTF: até 6,0 pontos percentuais;
 - Espectrogramas: até 1,4 pontos percentuais.

Matrizes de Confusão: RP

Verdadeiro	REM	0.65	0.11	0.24
	NREM	0.14	0.40	0.46
	Vigília	0.14	0.24	0.62
		Vigília	NREM Predito	REM

(a) Originais AC.

Verdadeiro	REM	0.50	0.23	0.27
	NREM	0.15	0.65	0.20
	Vigília	0.17	0.24	0.59
		Vigília	NREM Predito	REM

(b) Originais FC.

Verdadeiro	REM	0.60	0.12	0.28
	NREM	0.10	0.48	0.42
	Vigília	0.15	0.35	0.50
		Vigília	NREM Predito	REM

(c) E. AC + FC.

Verdadeiro	REM	0.80	0.05	0.15
	NREM	0.19	0.46	0.35
	Vigília	0.18	0.29	0.52
		Vigília	NREM Predito	REM

(d) Patches AC.

Verdadeiro	REM	0.52	0.17	0.31
	NREM	0.15	0.65	0.20
	Vigília	0.15	0.16	0.69
		Vigília	NREM Predito	REM

(e) Patches FC.

Verdadeiro	REM	0.74	0.13	0.13
	NREM	0.16	0.63	0.21
	Vigília	0.14	0.39	0.47
		Vigília	NREM Predito	REM

(f) E. P. AC + FC.

- Mais “vigílias” corretas com dados de AC (incluindo *ensembles*);
- Mais “NREM” e “REM” corretas com dados de FC.

Matrizes de Confusão: GAF

Verdadeiro	Vigília	0.63	0.14	0.23
	NREM	0.09	0.60	0.31
	REM	0.11	0.39	0.50
		Vigília	NREM Predito	REM

(a) Originais AC.

Verdadeiro	Vigília	0.46	0.20	0.34
	NREM	0.14	0.65	0.21
	REM	0.19	0.21	0.60
		Vigília	NREM Predito	REM

(b) Originais FC.

Verdadeiro	Vigília	0.62	0.14	0.24
	NREM	0.60	0.44	0.40
	REM	0.17	0.29	0.54
		Vigília	NREM Predito	REM

(c) E. AC + FC.

Verdadeiro	Vigília	0.77	0.05	0.18
	NREM	0.14	0.47	0.39
	REM	0.14	0.28	0.58
		Vigília	NREM Predito	REM

(d) Patches AC.

Verdadeiro	Vigília	0.46	0.24	0.30
	NREM	0.08	0.72	0.19
	REM	0.12	0.20	0.68
		Vigília	NREM Predito	REM

(e) Patches FC.

Verdadeiro	Vigília	0.71	0.15	0.14
	NREM	0.10	0.64	0.26
	REM	0.09	0.43	0.48
		Vigília	NREM Predito	REM

(f) E. P. AC + FC.

- Dados originais de AC: “vigílias” mais corretamente classificadas e “REM”, a menos;
- FC: “NREM” mais corretamente classificadas e “vigília”, a menos.

Matrizes de Confusão: MTF

Verdadeiro REM	Vigília	0.72	0.10	0.18
	NREM	0.16	0.57	0.27
	REM	0.21	0.43	0.36
		Vigília	NREM Predito	REM

(a) Originais AC.

Verdadeiro REM	Vigília	0.36	0.21	0.42
	NREM	0.13	0.58	0.29
	REM	0.18	0.15	0.66
		Vigília	NREM Predito	REM

(b) Originais FC.

Verdadeiro REM	Vigília	0.62	0.13	0.25
	NREM	0.16	0.54	0.30
	REM	0.17	0.35	0.48
		Vigília	NREM Predito	REM

(c) E. AC + FC.

Verdadeiro REM	Vigília	0.77	0.07	0.15
	NREM	0.16	0.51	0.33
	REM	0.21	0.33	0.47
		Vigília	NREM Predito	REM

(d) Patches AC.

Verdadeiro REM	Vigília	0.48	0.23	0.29
	NREM	0.14	0.65	0.21
	REM	0.22	0.18	0.60
		Vigília	NREM Predito	REM

(e) Patches FC.

Verdadeiro REM	Vigília	0.70	0.15	0.15
	NREM	0.13	0.63	0.25
	REM	0.15	0.35	0.50
		Vigília	NREM Predito	REM

(f) E. P. AC + FC.

- Mais “vigílias” corretas com dados de AC (incluindo *ensembles*);
- *Patches* com FC diminui a confusão de “vigília” como “REM”.

Matrizes de Confusão: Espectrogramas

Verdadeiro REM NREM Vigília	Vigília	0.71	0.15	0.14
	NREM Predito	0.14	0.64	0.23
	REM	0.16	0.51	0.33

(a) Originais AC.

Verdadeiro REM NREM Vigília	Vigília	0.85	0.07	0.08
	NREM Predito	0.72	0.21	0.07
	REM	0.80	0.06	0.15

(b) Originais FC.

Verdadeiro REM NREM Vigília	Vigília	0.72	0.15	0.13
	NREM Predito	0.15	0.64	0.21
	REM	0.17	0.51	0.32

(c) E. AC + FC.

Verdadeiro REM NREM Vigília	Vigília	0.72	0.10	0.18
	NREM Predito	0.13	0.56	0.31
	REM	0.15	0.41	0.44

(d) Patches AC.

Verdadeiro REM NREM Vigília	Vigília	0.87	0.12	0.01
	NREM Predito	0.75	0.24	0.01
	REM	0.79	0.13	0.08


(e) Patches FC.

Verdadeiro REM NREM Vigília	Vigília	0.75	0.12	0.13
	NREM Predito	0.15	0.65	0.20
	REM	0.18	0.55	0.27


(f) E. P. AC + FC.

- Poucas classificações para “NREM” e “REM” com dados de FC;
- *Ensembles* apresentam melhor classificação de "vigília".

Classificação dos Estágios do Sono: Noite de Sono



(a) Dados originais de frequência cardíaca.



(b) *Ensemble* dos *patches* dos dados de frequência cardíaca.

- Dados Originais: erros mais frequentes são “vigília” para “NREM” e “REM” para “NREM”;
- Redução de “vigília” para “NREM” e de “NREM” para “REM”;
- Erros “REM” para “vigília”, no início, permaneceram.

Outras Representações: Dados Brutos

- Arquitetura descrita para HAR [21].

Config.		CNN		LSTM		GRU	
		AC	FC	AC	FC	AC	FC
Original		71.596	52.000	71.554	56.290	72.542	63.884
Ensembles AC + FC	M. Simples	71.300		72.784		75.620	
	M. Ponderada	71.940		72.835		74.959	
	Deep Features	70.052		71.910		61.985	

Tabela: Classificação de sono/vigília.

Config.		CNN		LSTM		GRU	
		AC	FC	AC	FC	AC	FC
Original		46.656	46.700	47.874	57.546	46.844	56.030
Ensembles AC + FC	M. Simples	45.660		48.715		45.078	
	M. Ponderada	46.267		48.419		45.040	
	Deep Features	45.521		51.754		36.770	

Tabela: Classificação dos estágios do sono.

Outras Representações: Extração de *Features*

- Extração de *features* realizada no trabalho de referência da base de dados [30];
- Contadores de atividade (acelerômetro) e desvios padrão locais (frequência cardíaca);
- *Ensemble*: *feature* dos dados de acelerômetro + *feature* dos dados de frequência cardíaca.

	Classificação de Sono/Vigília				Classificação dos Estágios do Sono			
	Random Forest		Regressão Logística		Random Forest		Regressão Logística	
Config.	AC	FC	AC	FC	AC	FC	AC	FC
Original	76.553	64.807	73.854	63.592	51.550	48.732	44.501	40.502
Ensembles AC + FC	76.654		73.982		58.510		46.510	

Tabela: Acurácias balanceadas obtidas com extração de *features* para as classificações de sono/vigília e de estágios do sono.

Classificação de Sono/Vigília

	AC			FC			Ensemble AC + FC		
	Imagens	D. Brutos	Features	Imagens	D. Brutos	Features	Imagens	D. Brutos	Features
Ac. bal.	82.358	72.542	76.553	73.712	63.884	64.807	81.444	75.620	76.654
Config.	GAF Patches	GRU	RF	GAF Patches	GRU	RF	GAF Patches	GRU	RF

- Representação visual tem vantagem de até:
 - 5,8 pontos percentuais com dados de acelerômetro;
 - 8,9 pontos percentuais com dados de frequência cardíaca;
 - 4,8 pontos percentuais com *ensemble*.

Classificação dos Estágios do Sono

	AC			FC			Ensemble AC + FC		
	Imagens	D. Brutos	Features	Imagens	D. Brutos	Features	Imagens	D. Brutos	Features
Ac. bal.	60.661	47.874	51.550	62.180	57.546	48.732	61.481	51.754	58.510
Config.	GAF Patches	LSTM	RF	GAF Patches	LSTM	RF	RP Patches	LSTM	RF

- Representação visual tem vantagem de até:
 - 9,1 pontos percentuais com dados de acelerômetro;
 - 4,6 pontos percentuais com dados de frequência cardíaca;
 - 3,0 pontos percentuais com *ensemble*.

Conclusões e Trabalhos Futuros

Ambos os cenários

- Importância dos dados de acelerômetro, para classificar sono/vigília, e os de frequência cardíaca, para classificar estágios do sono, foi observada em trabalhos relacionados [10, 30];
- *Patches* melhoraram as acurácias balanceadas;
- Coeficiente κ reforçam a superioridade dos dados de AC e de FC para o respectivo cenário;
- Comportamento diferente com Espectrogramas em alguns casos.

Conclusões e Trabalhos Futuros

Artigo que explora classificação de sono/vigília com RP

- “*Sleep-Wake Classification using Recurrence Plots from Smartwatch Accelerometer Data*” (Rebeca Padovani Ederli, Didier Vega-Oliveros, Aurea Soriano-Vargas, Anderson Rocha e Zanoni Dias), *IEEE LA – CCI*, Recife (PE) [9].

Comparação com outras representações

- Maior eficácia utilizando representação visual;
- Menor eficiência em termos de recursos computacionais e tempo.

Questões de Pesquisa

Como combinar as informações dos dados de diferentes sensores de *smartwatches* para obter um método competitivo de classificação dos estágios do sono?

- *Ensemble patches* AC + FC obteve melhores acurácias balanceadas.

Questões de Pesquisa

Quais são as representações de imagens mais adequadas para classificar estágios do sono?

- Sono/vigília: representações visuais superam as não-visuais;
- Estágios do sono: Espectrogramas não superam as acurácias balanceadas das representações não-visuais.

Quais técnicas de aprendizado de máquina podem tornar a classificação dos estágios do sono mais precisa?

- O uso de *ensembles* de *patches* individuais e de *ensembles* de *patches* AC + FC.

Trabalhos Futuros

- Explorar redes baseadas em *Transformers*;
- Investigar métodos de normalização;
- Explorar técnicas de filtragem;
- Investigar técnicas de pós-processamento;
- Investigar métodos que otimizam e reduzam o custo computacional de representações visuais;
- Empregar técnicas de explicabilidade.

Referências I

- [1] L. C. S. Afonso, G. Rosa, C. R. Pereira, S. Weber, C. Hook, V. H. C. Albuquerque, and J. P. Papa. A recurrence plot-based approach for Parkinson's disease identification. *Future Generation Computer Systems*, 94:282–292, 2019.
- [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] O. Banos, R. Garcia, J. A. Holgado-Terriza, M. Damas, H. Pomares, I. Rojas, A. Saez, and C. Villalonga. mHealthDroid: a novel framework for agile development of mobile health applications. In *Ambient Assisted Living and Daily Activities*, pages 91–98. Springer, 2014.
- [4] 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.
- [5] A. Chakrabarty, O. A. Pandit, and U. Garain. Context sensitive lemmatization using two successive bidirectional gated recurrent networks. In *Annual Meeting of the Association for Computational Linguistics*, pages 1481–1491, 2017.
- [6] J. Cohen. A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, 20(1):37–46, 1960.
- [7] 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.
- [8] J.-P. Eckmann, S. O. Kamphorst, and D. Ruelle. Recurrence plots of dynamical systems. *World Scientific Series on Nonlinear Science Series A*, 16:441–446, 1995.
- [9] 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.

Referências II

- [10] S. Fallmann and L. Chen. Computational sleep behavior analysis: A survey. *IEEE Access*, 7:142421–142440, 2019.
- [11] P. Fonseca, T. Weysen, M. S. Goelema, E. I. Møst, M. Radha, C. Lunsingh 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.
- [12] 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.
- [13] C. Iber. The AASM manual for the scoring of sleep and associated events: Rules. *Terminology and Technical Specification*, 2007.
- [14] H. A. Imran. Ultanet: An antithesis neural network for recognizing human activity using inertial sensors signals. *IEEE Sensors Letters*, 6, 1 2022.
- [15] J. S. Iwanski and E. Bradley. Recurrence plots of experimental data: To embed or not to embed? *Chaos: An Interdisciplinary Journal of Nonlinear Science*, 8(4):861–871, 1998.
- [16] G. Klosh, 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 (EMBC)*, 20(3):51–57, 2001.
- [17] 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.
- [18] J. R. Kwapisz, G. M. Weiss, and S. A. Moore. Activity recognition using cell phone accelerometers. *ACM SIGKDD Explorations Newsletter*, 12:74–82, 3 2011.
- [19] C. Lam, C. Yu, L. Huang, and D. Rubin. Retinal lesion detection with deep learning using image patches. *Investigative Ophthalmology & Visual Science*, 59(1):590–596, 2018.
- [20] J. Lu and K.-Y. Tong. Robust single accelerometer-based activity recognition using modified recurrence plot. *IEEE Sensors Journal*, 19(15):6317–6324, 2019.

Referências III

- [21] S. Mekruksavanich and A. Jitpattanakul. Biometric user identification based on human activity recognition using wearable sensors: An experiment using deep learning models. *Electronics*, 10(3):308, 2021.
- [22] D. Ortega Anderez, A. Lotfi, and A. Pourabdollah. A deep learning based wearable system for food and drink intake recognition. *Journal of Ambient Intelligence and Humanized Computing*, 12:9435–9447, 2021.
- [23] J. Paquet, A. Kawinska, and J. Carrier. Wake detection capacity of actigraphy during sleep. *Sleep*, 30(10):1362–1369, 2007.
- [24] Z. Qin, Y. Zhang, S. Meng, Z. Qin, and K.-K. R. Choo. Imaging and fusing time series for wearable sensor-based human activity recognition. *Information Fusion*, 53:80–87, 2020.
- [25] 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.
- [26] K. Roy, D. Banik, D. Bhattacharjee, and M. Nasipuri. Patch-based system for classification of breast histology images using deep learning. *Computerized Medical Imaging and Graphics*, 71:90–103, 2019.
- [27] A. Sano and R. W. Picard. Comparison of sleep-wake classification using electroencephalogram and wrist-worn multi-modal sensor data. In *International Conference of the IEEE Engineering in Medicine and Biology Society*, pages 930–933. IEEE, 2014.
- [28] 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.
- [29] A. Stisen, H. Blunck, S. Bhattacharya, T. S. Prentow, M. B. Kjærgaard, A. Dey, T. Sonne, and M. M. Jensen. Smart devices are different: Assessing and mitigating mobile sensing heterogeneities for activity recognition. In *ACM Conference on Embedded Networked Sensor Systems (SenSys)*, pages 127–140, 2015.
- [30] 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.
- [31] Z. Wang and T. Oates. Imaging time-series to improve classification and imputation. *arXiv preprint arXiv:1506.00327*, 2015.
- [32] Z. Zeng, M. G. Amin, and T. Shan. Arm motion classification using time-series analysis of the spectrogram frequency envelopes. *Remote Sensing*, 12(3):454, 2020.

Representações Visuais para Classificação dos Estágios do Sono

Rebeca Padovani Ederli

Orientador: Prof. Dr. Zanoni Dias
Coorientador: Prof. Dr. Anderson Rocha

IC – Unicamp

02 de maio de 2024

Classificação de Sono/Vigília: Coeficientes κ

Rede	Config.	RP		GAF		MTF		Espectrogramas	
		AC	FC	AC	FC	AC	FC	AC	FC
Eff.Net	Original	0.317	0.178	0.353	0.184	0.322	0.152	0.297	0.108
Ensembles AC + FC	M. Simples	0.237		0.213		0.320		0.290	
	M. Ponderada	0.320		0.319		0.334		0.314	
	Deep Features	0.339		0.418		0.351		0.389	
Eff.Net	Patch 1	0.256	0.141	0.267	0.170	0.181	0.125	0.241	0.105
	Patch 2	0.319	0.155	0.324	0.163	0.234	0.120	0.245	0.110
	Patch 3	0.199	0.097	0.225	0.128	0.180	0.114	0.259	0.104
	Patch 4	0.354	0.159	0.348	0.165	0.314	0.129	0.315	0.119
	Patch 5	0.335	0.124	0.328	0.147	0.289	0.099	0.300	0.099
	Patch 6	0.281	0.149	0.294	0.211	0.288	0.123	0.248	0.113
	Patch 7	0.215	0.110	0.269	0.097	0.228	0.082	0.342	0.082
	Patch 8	0.333	0.178	0.368	0.183	0.303	0.113	0.288	0.103
	Patch 9	0.277	0.131	0.286	0.115	0.247	0.099	0.232	0.099
Ensembles dos Patches	M. Simples	0.299	0.195	0.370	0.259	0.300	0.171	0.350	0.141
	M. Ponderada	0.306	0.219	0.372	0.279	0.327	0.187	0.339	0.137
	Rede Simples	0.304	0.183	0.355	0.255	0.303	0.174	0.340	0.124
Ensembles P. AC + P. FC	M. Simples	0.281		0.361		0.297		0.262	
	M. Ponderada	0.303		0.390		0.337		0.310	

Classificação de Sono/Vigília: Coeficientes κ

- Melhores coeficientes κ são do *Ensemble* AC + FC com *deep features* (passando de 0,4);
- Para a maioria das configurações, com dados de AC, indica uma concordância regular (mais de 0,2);
- Novamente é demonstrada a importância dos dados de acelerômetro.

Classificação dos Estágios do Sono: Coeficientes κ

		RP		GAF		MTF		Espectrogramas	
Rede	Config.	AC	FC	AC	FC	AC	FC	AC	FC
Eff.Net	Original	0.171	0.322	0.241	0.326	0.195	0.279	0.203	0.085
Ensembles AC + FC	M. Simples	0.131		0.134		0.151		0.191	
	M. Ponderada	0.172		0.172		0.173		0.189	
	Deep Features	0.216		0.254		0.215		0.112	
Eff.Net	Patch 1	0.150	0.252	0.183	0.277	0.167	0.237	0.153	0.051
	Patch 2	0.166	0.283	0.197	0.269	0.152	0.253	0.184	0.084
	Patch 3	0.087	0.157	0.142	0.232	0.106	0.175	0.103	0.092
	Patch 4	0.189	0.284	0.132	0.322	0.170	0.244	0.142	0.083
	Patch 5	0.175	0.261	0.171	0.272	0.141	0.205	0.162	0.081
	Patch 6	0.190	0.292	0.202	0.308	0.149	0.229	0.071	0.073
	Patch 7	0.149	0.189	0.140	0.252	0.092	0.200	0.138	0.081
	Patch 8	0.205	0.274	0.187	0.300	0.154	0.213	0.154	0.080
	Patch 9	0.167	0.254	0.175	0.272	0.181	0.207	0.154	0.086
Ensembles dos Patches	M. Simples	0.214	0.375	0.225	0.413	0.211	0.331	0.208	0.091
	M. Ponderada	0.207	0.380	0.230	0.414	0.205	0.335	0.211	0.101
	Rede Simples	0.192	0.370	0.209	0.352	0.171	0.347	0.176	0.102
Ensembles P. AC + P. FC	M. Simples	0.165		0.180		0.192		0.199	
	M. Ponderada	0.284		0.272		0.283		0.190	

Classificação dos Estágios do Sono: Coeficientes κ

- κ obtidos com dados de frequência cardíaca ultrapassam 0,2 para maioria dos casos com RP, GAF e MTF;
- κ obtidos com dados de acelerômetro são inferiores a 0,2 para a maioria dos casos;
- Melhores κ foram obtidos com *Ensembles* dos *Patches* de FC:
 - RP: $\kappa = 0,38$ (concordância regular);
 - GAF: $\kappa = 0,41$ (concordância moderada);
 - MTF: $\kappa = 0,35$ (concordância regular).
- Espectrogramas: κ com frequências cardíaca, na maioria, menores que 0,1.

Desvios-Padrão: Classificação de Sono/Vigília

- RP: até 3,0%;
- GAF: até 4,0%;
- MTF: até 6,0%;
- Espectrogramas: até 4,0%.

Desvios-Padrão: Classificação dos Estágios do Sono

- RP: até 6,0%;
- GAF: até 3,0%;
- MTF: até 2,0%;
- Espectrogramas: até 3,0%.