

Proceeding Series of the Brazilian Society of Computational and Applied Mathematics

Classificação de estágios de sono através da aplicação de DWT sobre um único canal de EEG

Thiago L. T. da Silveira¹

Programa de Pós-Graduação em Informática, UFSM, Santa Maria, RS

Alice J. Kozakevicius

Departamento de Matemática, UFSM, Santa Maria, RS

Cesar R. Rodrigues

Departamento de Eletrônica e Computação, UFSM, Santa Maria, RS

Resumo. Este trabalho apresenta uma nova metodologia de apoio à decisão para a classificação de estágios de sono. No método proposto, uma transformada *wavelet* discreta (DWT) é aplicada a um único canal de eletroencefalograma (EEG) e são extraídas, dos coeficientes da DWT, características estatísticas de ritmos cerebrais relacionados ao sono que, posteriormente, alimentam um classificador. Diversos algoritmos para classificação, incluindo florestas aleatórias, são avaliados em um conjunto de mais de 100.000 instâncias disponíveis em uma base de dados pública. Obtém-se acurácias superiores a 90% e coeficientes *kappa* maiores que 0.8 para as classificações de 2 a 6 estados de estágios de sono. O resultados obtidos são comparáveis aos de trabalhos no estado da arte.

Palavras-chave. Transformada *wavelet* discreta (DWT), Classificação do sono, Sinais de eletroencefalograma (EEG)

1 Introdução

Gastamos quase um terço de nossas vidas dormindo. Lamentavelmente, estima-se que 45% da população mundial sofra de algum tipo de desordem relacionada ao sono [6]. Para que especialistas possam intervir, faz-se necessário o entendimento dos padrões das atividades cerebrais (ritmos) durante o sono. Com isso, é possível classificar diferentes estágios de sono, permitindo que médicos possam diagnosticar e tratar distúrbios como apneia, narcolepsia e insônia [4,12]. Esta análise, que pode tomar de 2 a 4h para cada noite de gravação [9], é classicamente feita por uma dupla de especialistas por meio da inspeção visual de sinais fisiológicos – como eletroencefalograma (EEG), eletromiograma (EMG) e eletrooculograma (EOG) [11]. Sob o prisma fisiológico, sinais de EEG são cruciais na análise do sono [11], pois permitem a identificação de estados cognitivos.

Para rotulagem dos estágios de sono, classicamente seguem-se ou as recomendações de Rechtschaffen e Kales (R&K) ou do guia desenvolvido pela Academia Americana de Medicina do Sono (AASM) [4]. Ambos padrões apresentam regras para classificação, que

¹thiago@inf.ufsm.br

são aplicadas trecho a trecho (épocas de 30s) dos sinais captados: EMG, EOG e sobretudo EEG. Como discutido em [12], R&K organiza os estágios de sono em cinco grupos. O grupo mais completo com 6 estágios é composto por: acordado (W), movimento rápido dos olhos (REM), e quatro estágios intermediários chamados S1–S4. Na classificação de 5 estágios, S3 e S4 são unidos em apenas um estágio de sono, chamado de ondas lentas (SWS). O grupo com 4 estágios contém W, SWS, REM e S1/S2, que agrupa S1 e S2. A classificação em 3 estágios combina S1/S2 e SWS em um novo estágio chamado movimento não-rápido dos olhos (NREM). Por fim, no grupo com 2 estágios, têm-se apenas W e o estado de sono (SLP) que engloba NREM e REM.

Visando assistir a classificação de sono e aumentar o âmbito das comparações com trabalhos que têm o mesmo cenário de análise, é proposta uma metodologia de apoio à decisão para sinais mono-canal, seguindo R&K. Segundo [12], métodos baseados em um único canal de EEG são mais simples e consomem menos recursos computacionais, inclusive na aquisição do sinal. Dentre os estudos com propostas similares, destacam-se [2], [9] e [12], seguindo R&K e [4], guiado pela AASM. Uma comparação mais ampla pode ser vista em [10].

Em [2] é apresentado um método baseado em lógica nebulosa para classificação de atributos obtidos via transformada de Fourier (FT), cujos resultados foram de 95,4%, 88,3%, 74,5% e 71,2% de acurácia para os problemas de 2 a 5 estados, considerando 8 indivíduos da base de dados *Sleep EDF*. Em [9] é proposta uma série de arquiteturas de redes neurais artificiais (ANNs) alimentadas pela energia de diferentes ritmos cerebrais, obtidos via FT. Para cada ANN, são obtidos diversos resultados para 2, 3, 4 e 6 estados de estágios de sono. Três extratores de características – distribuição de Choi-Williams e as transformadas *wavelet* contínua (CWT) e de Hilbert-Huang – são, em [4], aplicados sobre épocas de 30s, das quais é obtida a entropia de Renyi. Após, um algoritmo do tipo floresta aleatória é considerado, obtendo 83% de acurácia na classificação de 5 estágios. Em [12], máquinas de vetores de suporte (SVM) são construídas com características extraídas via grafos de diferença de visibilidade (DVG) e de visibilidade horizontais (HVG), permitindo atingir 97,9%, 92,6%, 89,3%, 88,9% e 87,5% de acertos nos problemas de 2 a 6 estados.

Inspirado em [2,9] que usam atributos baseados em faixas de frequência extraídos via FT, neste trabalho este conceito é revisitado e explorado através das transformadas *wavelet* discretas (DWTs) da família de Daubechies. Além disso, são utilizados momentos estatísticos como forma de se obter características significativas dos dados transformados em cada nível da DWT, relacionando-os a ritmos cerebrais. É utilizada a ferramenta *Waikato Environment for Knowledge Analysis* (WEKA) [13] – que oferece implementações de diversos algoritmos de aprendizagem de máquina. Os resultados apontam o classificador do tipo floresta aleatória como a melhor opção para o problema em questão. Diferentemente de trabalhos da literatura, aqui, as rotulagens de todos os 2 a 6 estados de estágios de sono são realizadas via uma única metodologia – ou seja, únicos pré-processamento, conjunto de características e algoritmo de classificação.

O restante do texto está organizado como segue. A Seção 2 apresenta os materiais e métodos necessários para o desenvolvimento deste trabalho. A Seção 3 reporta e discute os resultados deste estudo. Por fim, as conclusões desse trabalho são expostas na Seção 4.

2 Materiais e Métodos

2.1 Sinais cerebrais, base de dados e pré-processamento

EEGs são adequados para capturar ondas cerebrais em uma grande variedade de frequências [8], associando-as a diferentes estados funcionais do cérebro. As ondas delta (1 – 4Hz) surgem no sono profundo [1]. O ritmo teta (4 – 8Hz) ocorre tanto no estado de vigília quanto durante o sono [1], podendo ser um indicativo de sonolência [8]. O ritmo alfa (8 – 13Hz) está relacionado a estados nos quais o indivíduo está tranquilo, mas acordado [8]. A atividade beta (13 – 30Hz) é dominante durante o estado de vigília [11] e o baixo-gama (30 – 50Hz) está associado à memória recente [1] e à atenção [8].

Para análise de sinais de EEG, o presente trabalho considera a base pública *Sleep EDF[Expanded]* [7] por permitir a reprodutibilidade dos resultados. Todos os seus 39 registros de 20 indivíduos saudáveis são utilizados. Cada registro contém sinais de dois canais de EEG (FPz-Cz e Pz-Oz) amostrados a 100Hz. Com os sinais, são providas anotações feitas por especialistas para cada época (intervalo de 30s), indicando sua classificação de acordo com R&K em 6 estágios ou “tempo de movimento” ou “não classificado”. Épocas com as duas últimas opções são excluídas da análise para possibilitar a construção e avaliação dos algoritmos de classificação. Opta-se pelo canal Pz-Oz, pois segundo [9, 12], através deste, melhores resultados podem ser atingidos em problemas de análise do sono.

2.2 Extração de características

2.2.1 Transformada *wavelet* discreta de Daubechies

Assim como senos e cossenos da FT, as *wavelets* servem como base para representação de outras funções [3]. Em especial, as transformadas *wavelet* (WTs) são mais eficientes do que a FT quando os sinais analisados são não-periódicos [8], como é o caso de EEGs. Um problema inerente às WTs, exceto para a base de Haar, é a necessidade de extrapolação para permitir o cálculo da DWT nas fronteiras do sinal. O aumento na quantidade de momentos nulos M da *wavelet* exige um maior número de valores extrapolados. Por conta disso, opta-se pela família de Daubechies com $M = 2$ (Db2) [3]. Uma possibilidade de extrapolação é considerar que o sinal é periódico. Entretanto, isso não é razoável para sinais não-estacionários. Outra opção é extrapolar assumindo todos os valores nulos. O problema é que, desta forma, o sinal se degrada à medida que é decomposto em vários níveis. Mesmo considerando uma função polinomial para se extrapolar, este processo afeta a qualidade dos coeficientes nas proximidades das fronteiras do sinal.

Aqui, como os sinais são, apenas por convenção, divididos em épocas, extrapolam-se valores assumindo-se amostras da época seguinte. Essa abordagem é preferível, pois nenhum valor é obtido artificialmente, diferindo de soluções apresentadas na literatura estudada até o momento. Além desse tratamento especial nas regiões de fronteira, outra contribuição deste estudo é um ajuste feito no algoritmo clássico da DWT para permitir a análise de funções discretas que não têm tamanho $L = 2^J$, mas sim $L = R \cdot 2^K$, R e $K \in \mathbb{N}$. Isto significa que um vetor com $L = R \cdot 2^K$ pode ser decomposto K vezes e, no nível mais grosseiro, os vetores de coeficientes de escala e *wavelet* ambos teriam R valores.

Tabela 1: Faixas de frequência associadas a conjuntos de coeficientes obtidos após cinco níveis de decomposição com DWT Db2 em um sinal com taxa de amostragem de 100Hz

Conjunto de coeficientes	Faixa de frequências (Hz)	Ritmo cerebral associado
Coefficientes <i>wavelet</i> do 1º nível	25–50	baixo gama
Coefficientes <i>wavelet</i> do 2º nível	12.5–25	beta
Coefficientes <i>wavelet</i> do 3º nível	6.25–12.5	alfa
Coefficientes <i>wavelet</i> do 4º nível	3.125–6.25	teta
Coefficientes <i>wavelet</i> do 5º nível	1.5625–3.125	delta
Coefficientes de escala do 5º nível	0–1.5625	delta

Com esse ajuste, as épocas de 3000 amostras ($30s \times 100Hz$) poderiam ser decompostas apenas duas vezes. Para permitir seis níveis de decomposição, cada época passa a ter 3008 pontos, 8 obtidos da época seguinte, sem deslocar seu início. Como em [4], aqui explora-se o fato de que a decomposição *wavelet* pode ser vista como um conjunto de filtros passa-baixa (funções escala) e passa-alta (funções *wavelet*) [3]. Neste caso, associam-se as noções de escala e frequências, permitindo que ritmos cerebrais sejam resolvidos via DWT. Pelo teorema de Nyquist [3], a relação entre os coeficientes de escala e *wavelet* e os ritmos cerebrais é dada na Tabela 1, mostrando que cinco níveis de decomposição são suficientes.

2.2.2 Redução de dimensionalidade

A escolha das características que melhor representem cada classe de um problema de aprendizado de máquina é a tarefa *mais importante e difícil* de ser realizada [12]. Neste trabalho, a DWT aponta importantes variações nos padrões de comportamento dos sinais. Visando destacá-las e ainda reduzir drasticamente o conjunto de características necessárias para classificação, são extraídos os segundo, terceiro e quarto momentos estatísticos [5,9], mensurando, respectivamente, a dispersão e os graus de compressão e simetria de uma distribuição de dados restrita a faixas de frequência específicas.

De acordo com [9], vários estimadores estatísticos foram utilizados para análise de sinais fisiológicos no domínio de tempo. Além disso, em [5], a FT é aplicada às épocas, permitindo a extração de atributos estatísticos correspondentes ao espectro completo de frequências. Aqui, os três momentos estatísticos são obtidos para cada um dos seis conjuntos de coeficientes da DWT. Consideram-se todas as 106.377 épocas válidas de 30s da base dados. Depois de extraídas, todas essas características são agrupadas em um único conjunto no qual são mantidas as anotações dos especialistas, permitindo a construção e teste de um modelo de classificação [4,12]. Destaca-se que este conjunto de 18 características é o mesmo utilizado para identificar quaisquer estágios de sono, *independentemente do cenário de classificação* (2, 3, 4, 5 e 6 estágios de estados de sono).

2.3 Classificação

Neste estudo, a ferramenta WEKA [13] é utilizada. Todos os algoritmos de classificação disponíveis são testados para explorar o potencial do WEKA no contexto de processamento

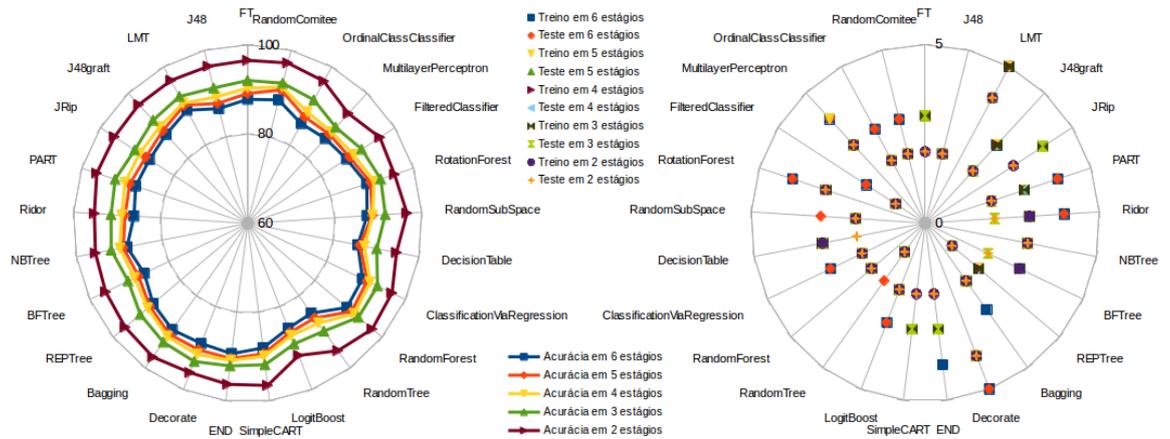


Figura 1: Acurácias (%) e tempos máximos ($\log_{10}s$) de treino e teste² para os 25 algoritmos com melhor desempenho na classificação do sono. Codinomes conforme o WEKA [13].

Tabela 2: Acurácias e κ para classificações de 2 a 6 estados de estágios de sono

Metodologia	Quantidade de estados de estágios de sono				
	2	3	4	5	6
Método [2]	95,4% / 0,83	88,3% / 0,76	74,5% / 0,63	71,2% / 0,61	- / -
Método [9]	96,9% / -	90,3% / -	81,4% / -	- / -	76,7% / -
Método [12]	97,9% / 0,96	92,6% / 0,87	89,3% / 0,83	88,9% / 0,83	87,5% / 0,81
Proposto	97,3% / 0,94	93,9% / 0,87	92,3% / 0,84	91,5% / 0,83	90,5% / 0,80

de sinais. Uma relação do desempenho e tempo de execução de alguns desses classificadores é dada na Figura 1. O algoritmo de floresta aleatória foi escolhido como classificador desta metodologia por apresentar o melhor desempenho dentre todas as opções testadas.

O algoritmo de florestas aleatórias é rápido, robusto a ruídos e livre de superajuste [13]. Seu objetivo é combinar as classificações individuais de N (aqui $N = 64$) árvores aleatórias, cada uma construída com F atributos, em uma só rotulagem. O parâmetro F é definido por $F = \lfloor \log_2 P + 1 \rfloor$, em que P é a quantidade total de características do conjunto de dados [4]. Como $P = 18$, cada árvore cresce com $F = 5$ atributos escolhidos aleatoriamente.

3 Resultados e Discussões

O desempenho geral de um método de classificação pode ser medido pela acurácia [13] e pelo coeficiente κ de Cohen [9]. Figuras de mérito como precisão e revocação [13] são importantes indicadores no reconhecimento de cada classe separadamente. Esses resultados podem ser encontrados em [10]. Com o intuito de aumentar a confiabilidade dos resultados obtidos pela aplicação da metodologia proposta, a técnica de k -fold cross validation [13] (k -fold CV), com $k = 10$, é empregada. A Tabela 2 compara os valores de

²Valores de tempo obtidos em uma máquina Core i7 com quatro núcleos a 2.0GHz e 8Gb de RAM.

acurácia e coeficiente *kappa* obtidos pelo método proposto e [2, 9, 12] que utilizam registros da mesma base de dados, o mesmo canal de EEG para análise e o mesmo guia para classificação do sono. Ao melhor de nosso conhecimento, estes são os únicos trabalhos que propõem métodos para resolver as classificações de 2 a 6 estados de estágios de sono. Nota-se que o método aqui proposto apresenta acurácias maiores do que os demais para 3 a 6 estados. Os valores de *kappa* apresentam-se comparáveis àqueles obtidos em [12] e superiores aos dos demais estudos. Metodologias cujos valores de *kappa* são superiores a 0.8 são consideradas *excelentes* [9].

Destacam-se: (i) é adotado um *único conjunto de características* para representar as épocas, independentemente do número de estágios de sono avaliados (diferindo dos demais trabalhos - que atribuem seus bons resultados à escolha de características dependentemente do cenário de classificação); e (ii) é utilizado um robusto conjunto de treino e teste contendo mais de 100.000 épocas de 30 segundos referentes à 39 registros.

Além do mais, outros testes foram feitos e comparados com [4], no qual *wavelets* contínuas e florestas aleatórias são utilizadas. Também foram feitas comparações com o recente trabalho [12], cujos resultados são muito competitivos. Com o objetivo de diminuir as diferenças nos contextos de avaliação, dois pontos foram ajustados. Seleciona-se aleatoriamente a mesma quantidade de épocas por classe que ambos utilizam, bem como método de avaliação (separação em conjuntos de treino e teste ou *10-fold CV*). Experimentos repetidos 10 vezes confirmaram a superioridade do método proposto, ainda que no cenário desses dois trabalhos relacionados. Detalhes podem ser encontrados em [10].

4 Conclusões

Este estudo apresenta uma metodologia para classificação de 2 a 6 estados de estágios de sono de acordo com R&K através de um único canal de EEG (Pz-Oz). O método é composto de etapas de pré-processamento, extração de características e classificação. Na primeira, o sinal é dividido em épocas de 30 segundos e aquelas inválidas são removidas. A extração de características é realizada através da DWT. Visto que um sinal de EEG é dividido em épocas por convenção, contorna-se o problema de tratamento de bordas da DWT obtendo pontos exatos da época seguinte. A decomposição em cinco níveis permite a separação em faixas de frequência próximas a de ritmos cerebrais relacionados ao sono. Um conjunto de três atributos por nível é extraído e, posteriormente, alimenta um classificador do tipo floresta aleatória. Obtém-se acurácias superiores a 90% e coeficientes *kappa* maiores que 0.8 para as classificações de 2 a 6 estados de estágios de sono. Em comparações com trabalhos recentes, a metodologia proposta apresenta os melhores resultados em termos de acurácia para os casos de 3 a 6 classes. Os valores de *kappa* sugerem que o método proposto é *excelente*.

Agradecimentos

O primeiro autor agradece à CAPES por sua bolsa de Mestrado. Os demais autores agradecem à FAPERGS, PG n° 1873-25.51/13-0.

Referências

- [1] M. F. Bear, B. W. Connors, and M. A. Paradiso. *Neuroscience: Exploring the Brain*. Wolters Kluwer, United Kingdom, 2015.
- [2] C. Berthomier, X. Drouot, M. Herman-Stoica, P. Berthomier, J. Prado, D. Bokar-Thire, O. Benoit, J. Mattout, and M. P. d’Ortho. Automatic analysis of single-channel sleep EEG: Validation in healthy individuals. *Sleep*, 30:1587–1595, 2007.
- [3] I. Daubechies. *Ten Lectures on Wavelets*. Society for Industrial and Applied Mathematics, Philadelphia, 1992.
- [4] L. Fraiwan, K. Lweesy, N. Khasawneh, H. Wenz, and H. Dickhaus. Automated sleep stage identification system based on time-frequency analysis of a single EEG channel and random forest classifier. *Computer Methods and Programs in Biomedicine*, 108(1):10–19, 2012.
- [5] B. Koley and D. Dey. An ensemble system for automatic sleep stage classification using single channel EEG signal. *Computers in Biology and Medicine*, 42(12):1186–1195, 2012.
- [6] Z. M. Noor, A. Smith, S. Smith, and L. Nissen. A study protocol: a community pharmacy-based intervention for improving the management of sleep disorders in the community settings. *BMC Health Services Research*, 14(1):74, 2014.
- [7] Physionet. The Sleep-EDF-X database. <http://www.physionet.org>, 2013. Online; Acessado em 12/05/2015.
- [8] R. P. N. Rao. *Brain Computer Interface - An Introduction*. Cambridge University Press, New York, 2013.
- [9] M. Ronzhina, Janousek. O, J. Kolarova, M. Novakova, P. Honzik, and I. Provaznik. Sleep scoring using artificial neural networks. *Sleep Medicine Reviews*, 16:251–263, 2012.
- [10] T. L. T. Silveira. Classificação de estágios de sono através da aplicação de transformada wavelet discreta sobre um único canal de eletroencefalograma. Dissertação de Mestrado, UFSM, 2016.
- [11] M. Teplan. Fundamentals of EEG measurement. In *Measurement Science Review*, Walter de Gruyter GmbH 2:1–11, 2002, ISSN: 1335-8871.
- [12] G. Zhu, Y. Li, and P. Wen. Analysis and classification of sleep stages based on difference visibility graphs from a single-channel EEG signal. *IEEE Journal of Biomedical and Health Informatics*, 18(6):1813–1821, 2014.
- [13] I. H. Witten, E. Frank, and M. A. Hall. *Data Mining: Practical Machine Learning Tools and Techniques*. Morgan Kaufmann/Elsevier, Burlington, 2011.