

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE INFORMÁTICA
CURSO DE CIÊNCIA DA COMPUTAÇÃO

LUCCA MILANO

**CNNs multi-entrada para detecção de
sonolência via sinais de EEG**

Monografia apresentada como requisito parcial
para a obtenção do grau de Bacharel em Ciência
da Computação

Orientador: Prof. Dr. Thiago Lopes Trugillo da
Silveira

Porto Alegre
2023

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

Reitor: Prof. Carlos André Bulhões Mendes

Vice-Reitora: Prof^a. Patricia Helena Lucas Pranke

Pró-Reitora de Graduação: Prof^a. Cíntia Inês Boll

Diretora do Instituto de Informática: Prof^a. Carla Maria Dal Sasso Freitas

Coordenador do Curso de Ciência de Computação: Prof. Marcelo Walter

Bibliotecário-chefe do Instituto de Informática: Alexsander Borges Ribeiro

RESUMO

Com o aumento drástico do número de veículos conduzidos diariamente, também há o aumento no total de acidentes de trânsito, sendo uma parcela desses causados pela falta de atenção ou sonolência ao volante. Visando remediar essa situação, diferentes trabalhos da literatura propõem identificar o nível de sonolência do condutor, permitindo tomar a devida providência de forma antecipada, alertando-o. Sinais de eletroencefalograma (EEG) capturam a atividade elétrica do escalpo de indivíduos de forma não-invasiva. Analisando a intensidade, duração e algumas outras características desses sinais, incluindo as frequências dominantes, é possível associá-los a estados cognitivos, atividades mentais ou motoras e patologias. Informações desses sinais são usualmente extraídas de dois domínios: temporal e espectral. Ainda há discussões sobre qual domínio oferece maior capacidade de reconhecimento quando utilizado por algoritmos de aprendizado de máquina. Este trabalho investiga a adoção de uma rede neural convolucional (*convolutional neural network*, CNN) com diversas entradas (*multi-branch*) para o problema de detecção de sonolência. As várias entradas da CNN processam diferentes versões do sinal de EEG, filtradas pela transformada *wavelet* discreta de Haar, que se relacionam a ritmos cerebrais associados aos estados de sonolência e alerta. São consideradas diferentes combinações de entradas (ritmos utilizados). Nossa metodologia é avaliada em uma base de dados pública e comparada a um trabalho do estado da arte. Os resultados indicam que a modelagem com filtragem dos sinais em ritmos cerebrais atinge 81.6% de acurácia e supera outras que trabalham sobre sinais não filtrados.

Palavras-chave: Detecção de sonolência. eletroencefalograma (EEG). aprendizado de máquina profundo. análise espectral.

Multi-branch CNNs for drowsiness detection using EEG signals

ABSTRACT

With the drastic increase in the number of vehicles driven daily, there is also an increase in the total number of traffic accidents, some of which are caused by lack of attention or drowsiness at the wheel. To remedy this situation, different works in the literature propose identifying the driver's sleepiness level, allowing them to take the appropriate action in advance, alerting him. Electroencephalogram (EEG) signals non-invasively capture electrical activity from the scalp of individuals. Analyzing the intensity, duration, and some other characteristics of these signals, including the dominant frequencies, it is possible to associate them with cognitive states, mental or motor activities, and pathologies. Information from these signals is usually extracted from two domains: temporal and spectral. There are still discussions about which domain offers greater recognition capacity when used by machine learning algorithms. This work investigates the adoption of a convolutional neural network (CNN) with multiple inputs (multi-branch) for the sleepiness detection problem. The various CNN inputs process different versions of the EEG signal, filtered by the discrete Haar wavelet transform, which relates to brain rhythms associated with sleepiness and alertness. Different combinations of inputs are considered (rhythms used). Our methodology is evaluated in a public database and compared to a state-of-the-art work. The results indicate that the modeling with filtering of the signals in rhythms reaches 81.6% accuracy and surpasses approaches that work on raw signals.

Keywords: Drowsiness detection, electroencephalogram (EEG), spectral analysis, deep learning.

LISTA DE FIGURAS

Figura 4.1	Visão geral da metodologia proposta.....	22
Figura 4.2	Épocas de EEG do canal Pz-Oz rotuladas com os estados de (a) “alerta” e (b) “sonolência”. Em laranja, uma (sub)época de 1s. Em azul, o restante da época de 30s.....	23
Figura 4.3	Coefficientes da DWT de Haar associados a diferentes ritmos cerebrais. Amostras da época original são destacadas em azul. Os coeficientes destacados em cor estão, em ordem, associados aos ritmos gama, beta, alfa, teta e delta.....	25
Figura 4.4	Sinal de EEG não processado e versões desse sinal associadas aos diferentes ritmos cerebrais (gama, beta, alfa, teta e delta, em ordem).....	26
Figura 4.5	Arquitetura da CNN multi-entrada proposta.....	27
Figura 5.1	Curvas de aprendizado para o modelo com dados não-processados e uma unidade de processamento linear.....	30
Figura 5.2	Curva de aprendizado para o modelo com cinco ritmos cerebrais/unidades de processamento linear.....	30

LISTA DE TABELAS

Tabela 3.1	Comparação entre os trabalhos que realizam DD no domínio temporal.....	16
Tabela 3.2	Comparação entre os trabalhos que realizam DD no domínio temporal.....	18
Tabela 4.1	Frequências associadas aos níveis de decomposição da DWT e ritmos cerebrais relacionados.....	25
Tabela 5.1	Matriz de confusão para modelo com cinco ritmos cerebrais/unidades de processamento linear.....	30
Tabela 5.2	Matriz de confusão para modelo com dados não-processados e duas unidades de processamento linear (Balam, Sameer and Chinara (2021)).	31
Tabela 5.3	Matriz de confusão para modelo com dados não-processados e uma unidade de processamento linear.....	31
Tabela 5.4	Frequências associadas aos ritmos cerebrais.....	31
Tabela 5.5	Resultados de acurácia para cada configuração do modelo para validações <i>5-fold CV</i> e <i>splits</i> fixos (70%-15%-15%).....	32
Tabela 5.6	Matriz de confusão para modelo com Configuração 2, referente a Tabela 5.4.....	33
Tabela 5.7	Matriz de confusão para modelo com Configuração 3, referente a Tabela 5.4.....	33
Tabela 5.8	Matriz de confusão para modelo com Configuração 4, referente a Tabela 5.4.....	33
Tabela 5.9	Matriz de confusão para modelo com Configuração 5, referente a Tabela 5.4.....	33
Tabela 5.10	Matriz de confusão para modelo com Configuração 6, referente a Tabela 5.4.....	33
Tabela 5.11	Matriz de confusão para modelo com Configuração 7, referente a Tabela 5.4.....	34
Tabela 5.12	Matriz de confusão para modelo com Configuração 8, referente a Tabela 5.4.....	34
Tabela 5.13	Matriz de confusão para modelo com Configuração 9, referente a Tabela 5.4.....	34
Tabela 5.14	Matriz de confusão para modelo com Configuração 10, referente a Tabela 5.4.....	34
Tabela 5.15	Matriz de confusão para modelo com Configuração 11, referente a Tabela 5.4.....	34
Tabela 5.16	Matriz de confusão para modelo com Configuração 12, referente a Tabela 5.4.....	34
Tabela 5.17	Matriz de confusão para modelo com Configuração 13, referente a Tabela 5.4.....	34

LISTA DE ABREVIATURAS E SIGLAS

AASM	Academia Americana de Medicina do Sono
ANN	Rede Neural Artificial
CNN	Rede Neural Convolucional
CV	Validação cruzada
DD	Detecção de Sonolência
DL	Aprendizado de Máquina Profundo (<i>Deep Learning</i>)
DWT	Transformada <i>Wavelet</i> Discreta
EEG	Electroencefalograma
ELM	Máquina de aprendizado extremo
EMG	Eletromiograma
EOG	Eletrooculograma
FFT	Transformada Rápida de Fourier
STFT	Transformada Rápida de Fourier de curto termo
LSTM	Rede Memória Longa de Curto Prazo
ML	Aprendizado de Máquina (<i>Machine Learning</i>)
R&K	Rechtschaffen & Kales
REM	Movimento rápido dos olhos
NREM	Não REM
SVM	Máquina de Vetores de Suporte
STFT	Transformada de Fourier de curto termo
GCN	Rede neural convolucional em grafos

LISTA DE SÍMBOLOS

\mathbf{Q}_j	Matriz de transformação da DWT de Haar para o nível j
\mathbf{C}_j	Submatriz de transformação da DWT de Haar para o nível j (informações médias)
\mathbf{D}_j	Submatriz de transformação da DWT de Haar para o nível j (detalhes)
\mathbf{v}	Vetor no domínio de tempo
\mathbf{w}	Vetor transformado pela DWT de Haar
\mathbf{Q}_j^\top	Matriz transposta/inversa de \mathbf{Q}_j
\mathbf{I}_k	Matriz de identidade de dimensão k

SUMÁRIO

1 INTRODUÇÃO	10
1.1 Motivação.....	10
1.2 Objetivos	11
1.3 Organização dos Capítulos.....	12
2 FUNDAMENTAÇÃO TEÓRICA	13
2.1 Sinais de EEG	13
2.2 Ritmos Cerebrais em Sinais de EEG.....	14
3 TRABALHOS RELACIONADOS	16
3.1 Detecção de Sonolência no Domínio Temporal	16
3.2 Detecção de Sonolência no Domínio Espectral.....	17
3.3 CNNs Multi-entrada para Análise do Sono.....	19
3.4 Semelhanças com o Método Proposto	20
4 MÉTODO PROPOSTO.....	21
4.1 Visão Geral	21
4.2 Base de Dados.....	21
4.3 Pré-processamento	22
4.4 Filtragem Espectral	22
4.5 CNN Multi-entrada.....	26
5 RESULTADOS	28
5.1 Recursos Computacionais	28
5.2 Comparações com uma CNN Multi-entrada do Estado da Arte.....	28
5.3 Estudos de Ablação	30
6 CONCLUSÃO	35
REFERÊNCIAS	36

1 INTRODUÇÃO

Este capítulo motiva a proposta de sistemas para detecção de sonolência utilizando sinais de eletroencefalograma. Também pontua os objetivos do presente trabalho e apresenta a organização do restante do texto.

1.1 Motivação

A sonolência é um estado de baixa atenção que ocorre entre estar acordado (alerta) e entrar em um estágio de sono (CORSI-CABRERA et al., 1996). O estado de sonolência aumenta as chances de um sujeito causar acidentes associados a tarefas que exigem foco, como a condução de veículos (MORADI; NAZARI; RAHMANI, 2019; SALEEM, 2022; AREFNEZHAD et al., 2022). Portanto, para reduzir tais riscos, a detecção e alerta do estado de sonolência é essencial. A fim de realizar essa detecção, diversos métodos computacionais podem ser usados, sendo que os que utilizam sinais fisiológicos são considerados os mais eficientes (LAL; CRAIG, 2001). Um tipo de sinal de destaque é o de eletroencefalograma (EEG), utilizado amplamente na pesquisa relacionada ao sono devido ao seu baixo custo, facilidade de medição e acurácia (HAL et al., 2014).

Sinais de EEG medem a atividade cerebral e podem ser utilizados como fonte para sistemas de detecção de sonolência (*drowsiness detection*, DD) (AMARASINGHE; WIJAYASEKARA; MANIC, 2014). Um par de eletrodos que captura ondas cerebrais é chamado de canal de EEG (ALYASSERI et al., 2022). Os sistemas típicos de captura de EEG podem ter desde um único canal até centenas de canais (TEPLAN et al., 2002). Além disso, a captura das ondas cerebrais via EEG é feita de forma não-invasiva (YUAN et al., 2021). Para DD, pode-se usar um ou vários canais (SRIRAAM; SHRI; MAHESHWARI, 2016). Sistemas para DD que utilizam único canal de EEG são mais portáteis e têm reduzido custo computacional se comparados com aqueles que dependem de múltiplos canais (OGINO et al., 2019; LAROCCO; LE; PAENG, 2020).

O domínio temporal é o domínio natural dos sinais de EEG. Por outro lado, no domínio espectral, pode-se enxergar faixas de frequência características (ritmos) associadas ao estado cognitivo de um sujeito (SABY; MARSHALL, 2012). As atividades de ritmos cerebrais (como o alfa, beta, gama, delta e teta, discutidos em mais detalhes no Capítulo 2) podem ser relacionados a eventos como os estados de alerta e sonolência (DKHIL; WALI; ALIMI, 2015). A utilização de dados espectrais extraídos de sinais de EEG para

DD foi ampla nas últimas décadas (RAMZAN et al., 2019). Mais recentemente, métodos de aprendizado profundo (*deep learning*, DL) retomaram investigações em DD com sinais de EEG no domínio temporal (BALAM; SAMEER; CHINARA, 2021; FOUAD, 2023). Ainda há discussão sobre qual dos domínios permite identificar sonolência mais eficientemente (STANCIN; CIFREK; JOVIC, 2021; LUO, 2023).

Classicamente, métodos de aprendizado de máquina (*machine learning*, ML) são utilizados como peça-chave na construção de sistemas para DD (MEDA; GANESH; SAHANI, 2021). Alguns métodos de ML requerem a extração manual de características (*hand-crafted features*) do sinal, sendo necessária orientação especializada (NANNI; GHIDONI; BRAHNAM, 2017). Atualmente há uma tendência de extração automática de características (*learning-based*), o que se prova útil na descoberta de conhecimento (ZHU et al., 2014; BALAM; SAMEER; CHINARA, 2021). Nesse contexto, redes neurais convolucionais (CNNs) têm mostrado excelente desempenho em problemas associados ao processamento e classificação de sinais biomédicos (ALASKAR, 2018).

O presente trabalho usa uma CNN multi-entrada para DD utilizando um único canal de EEG. Os sinais de EEG são filtrados em domínio espectral utilizando análise e síntese multi-nível via transformada discreta *wavelet* (*discrete wavelet transform*, DWT) de Haar (HAAR, 1910). Esse processo gera versões filtradas do sinal associadas aos ritmos alfa, beta, gama, delta e teta. Cada versão do sinal é passado a uma entrada da CNN que as processa independentemente e então as combina para uma classificação final. Essa abordagem de extração de características híbrida permite identificar componentes do sinal que contribuem para DD.

1.2 Objetivos

O objetivo geral desse trabalho é endereçar o problema dos acidentes causados pela sonolência na condução de veículos, propondo uma CNN multi-entrada para DD através de um único canal de EEG. As várias entradas da CNN processam versões do sinal de EEG, filtradas pela DWT de Haar (HAAR, 1910), que se relacionam a ritmos cerebrais associados aos estados de sonolência e alerta. Assim como Balam, Sameer and Chinara (2021), Arif, Munawar and Ali (2023), Tarafder et al. (2022), endereçamos essa tarefa como um problema de classificação binária.

Os objetivos específicos deste trabalho incluem:

1. Identificação de bases de dados públicas para classificação/detecção dos estágios de alerta e sonolência;
2. Identificação de métodos para análise espectral dos sinais de EEG;
3. Estudo do estado da arte em DD e implementação de abordagens computacionais para comparação com a técnica proposta;
4. Treinamento e avaliação de CNNs com diferentes arquiteturas e hiperparâmetros.

1.3 Organização dos Capítulos

O restante do documento está organizado como segue. O Capítulo 2 apresenta os fundamentos necessários para a compreensão do trabalho, incluindo uma breve descrição dos ritmos cerebrais alfa, beta, gama, delta e teta e como eles auxiliam a DD. O Capítulo 3 revisa trabalhos relacionados que exploram informações extraídas dos sinais de EEG nos domínios temporal e espectral, bem como trabalhos que se utilizam de *multi-branch* CNNs. O Capítulo 4 mostra a metodologia proposta. Mais precisamente, a Seção 4.1 dá a visão geral do método proposto e a Seção 4.2 descreve a base de dados adotada. As Seções 4.3 e 4.4 descrevem, respectivamente, o pré-processamento aplicado aos dados e os procedimentos de análise e síntese via DWT de Haar. O Capítulo 5 apresenta resultados e comparações do método proposto com abordagens concorrentes. O Capítulo 6 conclui o trabalho e oferece uma visão do que pode ser explorado no futuro.

2 FUNDAMENTAÇÃO TEÓRICA

Esse capítulo oferece uma breve revisão de metodologias para DD, de uma forma abrangente, através de sinais de EEG (Seção 2.1) e o papel de ritmos cerebrais nessa tarefa (Seção 2.2).

2.1 Sinais de EEG

A utilização de sinais de EEG para DD é um campo da biomedicina que ganhou atenção significativa devido ao seu potencial para melhorar a segurança e o desempenho em vários setores, como da locomoção automotiva e aviação (MARDI; ASHTIANI; MIKAILI, 2011; ZHU et al., 2021; MA et al., 2019). Acidentes relacionados à sonolência, particularmente no âmbito automotivo, destacaram a necessidade de métodos confiáveis para sua detecção. Os sinais de EEG fornecem uma medida direta da atividade cerebral, oferecendo informações sobre o estado cognitivo de um indivíduo (KUMAR; BHUVANESWARI, 2012). A análise de sinais de EEG envolve a identificação de padrões de frequência específicos associados aos estados de alerta e sonolência (BELAKHDAR et al., 2018). Ao monitorar esses padrões, é possível desenvolver algoritmos e modelos preditivos para detecção automática de sonolência (RUNDO et al., 2019).

Uma vantagem do uso de sinais de EEG para DD é sua natureza não-invasiva (HE et al., 2014). Os eletrodos de EEG podem ser facilmente colocados no couro cabeludo, o que o torna um método conveniente e confortável para monitoramento à longo prazo, permitindo a avaliação contínua do estado cognitivo de um indivíduo (KEMP et al., 2000). Tsai et al. (2009) sugere, inclusive, o uso de dispositivos portáteis baseados em poucos eletrodos para medição de sinais de EEG e DD. Deve-se destacar que também há outras abordagens para DD que utilizam técnicas de processamento de imagens tanto para detectar movimento ocular quanto de boca (POURSADEGHIYAN et al., 2018; KHURSHID; SCHARCANSKI, 2020). No entanto, métodos baseados em imagens dependem de fatores externos, tais como boa iluminação, contraste e desocclusões (ALBADAWI; ALREDHAEI; TAKRURI, 2023).

Além disso, a detecção de sonolência baseada em EEG é promissora para abordagens personalizadas (SUN; MOU, 2023). Diferentes indivíduos podem exibir padrões distintos de EEG associados à sonolência, dependendo de fatores como padrões de sono, idade e saúde. Analisando dados individualizados, é possível criar modelos personali-

zados para maior precisão (WAN et al., 2021). Essa abordagem tem o potencial de aumentar a confiabilidade dos sistemas de detecção de sonolência e reduzir falsos positivos (BERKA et al., 2005; JAYARATHNE; COHEN; AMARAKEERTHI, 2020).

Os critérios da Academia Americana de Medicina do Sono (*American Academy of Sleep Medicine*, AASM) (IBER et al., 2007) e Rechtschaffen & Kales (R&K) (HOBSON, 1969) são duas estruturas utilizadas para classificar os estágios do sono (NOVELLI; FERRI; BRUNI, 2010). Com base na análise visual dos sinais de EEG, eletrooculograma (EOG) e eletromiograma (EMG), o sistema R&K introduziu o conceito de sono de movimento rápido dos olhos (*rapid eye movement*, REM) (WEHRLE et al., 2007). Em contraste, a AASM, aprimorou a classificação do sono incorporando tecnologias emergentes como a polissonografia (PSG), levando a uma maior precisão e objetividade na classificação (RUEHLAND et al., 2011). O sistema R&K identifica quatro estágios não REM (*non-rapid eye-movement*, NREM) (S1, S2, S3, S4) e sono REM, com estágios NREM diferenciados por padrões específicos de sinais de EEG. Os critérios da AASM, evoluídos dos de R&K, estabeleceram quatro estágios do sono (S1, S2, sono de ondas lentas – SWS, REM) e o estado de alerta (MOSER et al., 2009). Normalmente, trechos dos sinais (épocas) são rotulados de acordo com R&K ou AASM.

2.2 Ritmos Cerebrais em Sinais de EEG

Sinais de EEG são não-estacionários (KLONOWSKI, 2009) e são compostos de vários ritmos – ou padrões de atividade – cerebrais. Esses ritmos apresentam informações relacionadas ao estado do cérebro, incluindo níveis de alerta e sonolência (TARAN; BAJAJ, 2018).

Os principais ritmos atrelados a presença ou ausência de sonolência são:

1. Ritmo *gama*: são ondas de alta frequência (30–50 Hz) e são associadas a um estado de funcionamento cognitivo aumentado, estando completamente alerta e engajado em atividades que demandam atenção (MAJUMDER et al., 2019). Com o aumento da sonolência, a atividade da onda gama diminui (SILVEIRA; KOZAKEVICIUS; RODRIGUES, 2016; RUNDO et al., 2019).
2. Ritmo *beta*: são ondas de alta frequência (13–30 Hz) e baixa amplitude, normalmente observadas quando uma pessoa está acordada e envolvida em atividade mental ativa (RUNDO et al., 2019). À medida que a sonolência se instala, as ondas beta

começam a diminuir (MAJUMDER et al., 2019).

3. Ritmo *alfa*: são ondas que possuem frequência relativamente baixa (8–13 Hz) e têm amplitude maior em comparação às ondas beta. Observadas quando uma pessoa está acordada, mas em um estado de relaxamento (MAJUMDER et al., 2019). Durante a sonolência, as ondas alfa tendem a aumentar em amplitude (SILVEIRA; KOZAKEVICIUS; RODRIGUES, 2016; RUNDO et al., 2019).
4. Ritmo *teta*: são ondas que têm uma faixa de frequência de 4 a 7 Hz e estão associadas ao estado de sonolência e ao sono leve (SILVEIRA; KOZAKEVICIUS; RODRIGUES, 2016). Essas ondas são comumente vistas durante a transição entre o estado de alerta e o de sono e podem indicar um estado de relaxamento ou meditativo (MAJUMDER et al., 2019; RUNDO et al., 2019).
5. Ritmo *delta*: são as ondas cerebrais mais lentas, com uma faixa de frequência de 0,5 a 4 Hz (SILVEIRA; KOZAKEVICIUS; RODRIGUES, 2016). Essas ondas estão presentes durante o sono profundo e são indicativos de um estado altamente relaxado e inativo (RUNDO et al., 2019). No contexto de DD, um aumento na atividade da onda delta durante o estado de alerta pode sugerir alta sonolência ou fadiga (MAJUMDER et al., 2019).

Note que os ritmos cerebrais de interesse para DD não ultrapassam 50Hz. Dessa forma, dados amostrados a 100Hz são suficientes para essa aplicação (SILVEIRA; KOZAKEVICIUS; RODRIGUES, 2016).

3 TRABALHOS RELACIONADOS

Esse capítulo discute métodos para realizar DD a partir de sinais EEG. Observamos diferentes abordagens que variam quanto ao tamanho das épocas, ao domínio de processamento, número de canais utilizados, tipo de classificadores (clássicos de ML ou DL) e temporalidade.

Alguns trabalhos identificam características dos sinais em domínio espectral (RAMZAN et al., 2019). Ao analisar tais características, pode-se detectar padrões indicativos de sonolência (ARIF; MUNAWAR; ALI, 2023). Para passar os dados de EEG do domínio temporal para o espectral, pode-se considerar várias técnicas de processamento de sinal, incluindo as transformadas discretas de Fourier (CHAABENE et al., 2021) e *wavelet* (SILVEIRA; KOZAKEVICIUS; RODRIGUES, 2015; CORREA; LEBER, 2010).

3.1 Detecção de Sonolência no Domínio Temporal

Sendo um problema de classificação, a maioria das abordagens para DD com sinais de EEG se baseia em um classificador treinado com dados anotados que prevê categorias de dados não-rotulados. Existem diversos métodos para se obter resultados nesse campo. A seguir seguem características de algumas dessas metodologias.

Bajaj et al. (2020) e Tripathy and Acharya (2018) consideram épocas de 30s, já Balam, Sameer and Chinara (2021) consideram épocas de 1s. Bajaj et al. (2020), Khare and Bajaj (2022) e Tripathy and Acharya (2018) realizam a filtragem do sinal de EEG com transformada *Wavelet Q-factor* e filtro passa-faixa respectivamente, com os dois primeiros

Tabela 3.1 – Comparação entre os trabalhos que realizam DD no domínio temporal.

Referência	Canal único	Tamanho das épocas	Pré-processamento	Extração automática de características	Classificador	Validação
Bajaj et al. (2020)	×	30s	Filtro Passa-faixa	×	ELM	10-fold CV
Khare and Bajaj (2022)	✓	-	Transformada <i>Wavelet Q-factor</i>	×	SVM	10-fold CV
Tripathy and Acharya (2018)	✓	30s	Transformada <i>Wavelet Q-factor</i>	×	Rede Neural Profunda	10-fold CV
Balam, Sameer and Chinara (2021)	✓	1s	-	✓	CNN Multi-entrada	<i>Splits</i> fixos

capitalizando na natureza não-estacionária dos sinais de EEG e o terceiro focando na simplicidade e limites bem definidos das frequências de interesse. Ao contrário destes, Balam, Sameer and Chinara (2021) trabalham com os sinais sem filtragem.

Balam, Sameer and Chinara (2021) apostam na extração automática de características (*learnt-based features*), enquanto que Bajaj et al. (2020), Tripathy and Acharya (2018) e Khare and Bajaj (2022) extraem características manualmente (*hand-crafted features*). Bajaj et al. (2020) fazem uso dos valores mínimo e máximo referentes a mobilidade *Hjorth* (medida que quantifica a rapidez das mudanças na amplitude de um sinal), Tripathy and Acharya (2018) usam a variância e dispersão de entropia referentes aos sinais filtrados em bandas alfa, beta, gama, delta, teta e Khare and Bajaj (2022), dependendo do resultado do teste *Kruskal Wallis*, usam mobilidade de *Hjorth*, complexidade de *Hjorth*, tri-média, média e desvio padrão dos sinais. Tripathy and Acharya (2018), Khare and Bajaj (2022), Balam, Sameer and Chinara (2021) utilizam canal único e Bajaj et al. (2020) usa canais múltiplos.

Bajaj et al. (2020) consideram diversos algoritmos de classificação, como árvore de decisão, regressão logística, máquina de vetores de suporte (*Support Vector Machine*, SVM), KNN ponderado, conjunto de árvores impulsionadas e máquina de aprendizado extremo (*Extreme Learning Machine*, ELM), obtendo maior acurácia através do classificador ELM. Tripathy and Acharya (2018) utilizam uma rede neural profunda e Balam, Sameer and Chinara (2021) uma CNN multi-entrada (*multi-branch*) com duas unidades de processamento linear. Khare and Bajaj (2022) também considera múltiplos classificadores – como árvore simples, árvore complexa, árvore média, regressão logística, SVM – obtendo melhor resultado com a SVM. Tripathy and Acharya (2018), Bajaj et al. (2020) e Khare and Bajaj (2022) consideram validação cruzada por *10-fold cross validation (CV)*, enquanto Balam, Sameer and Chinara (2021) faz validação por *splits* de treino, validação e teste fixos.

A Tabela 3.1 sumariza as semelhanças e diferenças entre os trabalhos recém revisados.

3.2 Detecção de Sonolência no Domínio Espectral

O domínio temporal é o domínio natural dos sinais EEG, e para filtrá-los no domínio espectral, existem técnicas como *Butterworth pass* (ABOALAYON; OCBAGABIR; FAEZIPOUR, 2014), transformadas de Fourier (MURUGAPPAN et al., 2014) e *Wave-*

Tabela 3.2 – Comparação entre os trabalhos que realizam DD no domínio temporal.

Referência	Canal único	Tamanho das épocas	Pré-processamento	Extração automática de características	Classificador	Validação
Belakhdar et al. (2018)	✓	30s	FFT	×	ANN	10-fold CV
Anitha (2018)	✓	30s	FFT	×	SVM	10-fold CV
Yeo et al. (2009)	×	10s	FFT	×	SVM	5-fold CV
Budak et al. (2019)	✓	30s	Transformada <i>Wavelet</i>	×	LSTM	10-fold CV
Correa, Orosco and Laciari (2014)	✓	5s	STFT	×	ANN	10-fold CV

let (AMIN et al., 2015) (utilizada nesse trabalho). Cada uma delas tem suas vantagens e desvantagens, com a transformada *Wavelet* se destacando na captura de tempo-frequência dos sinais de EEG (QIAO et al., 1998), o que permite uma análise de como os componentes de frequência mudam ao longo do tempo (HAQUE et al., 2009). Já *Butterworth* se destaca pela simplicidade e filtros com frequências de corte bem definidas para atingir faixas de frequência específicas (ROBERTS; ROBERTS, 1978). Por fim, *Fourier* conta com conceito simples e visão clara das frequências dominantes no sinal (NG; KADISH; GOLDBERGER, 2007). Diferentes trabalhos usam uma metodologia ou outra para análise espectral.

Anitha (2018), Belakhdar et al. (2018) e Budak et al. (2019) consideram épocas de 30s, enquanto Yeo et al. (2009) trabalham com épocas de 10s e Correa, Orosco and Laciari (2014) usam épocas de 5s. Yeo et al. (2009), Belakhdar et al. (2018) e Anitha (2018) fazem uso da transformada rápida de *Fourier* (*fast Fourier transform*, FFT) para converter os dados ao domínio espectral. Budak et al. (2019) e Correa, Orosco and Laciari (2014) utilizam transformada *Wavelet* para tal, com Correa, Orosco and Laciari (2014) também empregando uso da transformada de *Fourier* de curto termo (*short-time Fourier transform*, STFT).

Anitha (2018) considera como características a combinação de quatro componentes de frequência e seus respectivos componentes de magnitude. Belakhdar et al. (2018) extraem um conjunto de características dos sinais de EEG baseado na análise de sub-bandas de 1 Hz, representando a sub-banda alfa como a frequência individual alfa, ao invés de toda sub-banda (8–12 Hz), a fim de minimizar o problema da variabilidade interpessoal e fornecer resultados estáveis, independentemente das características intrínsecas dos motoristas. A extração de características de Budak et al. (2019) se trata de três blocos,

com o primeiro considerando a distribuição de energia e distribuição de *zero-crossings*, calculados a partir dos sinais brutos de EEG e das entropia espectral e recursos de frequência instantânea, calculados de espectrogramas. No segundo bloco, a extração de características profundas é empregada diretamente nos espectrogramas. Por fim, no terceiro bloco, é usada transformada *Wavelet Q-Factor* para decompor os sinais de EEG. Correa, Orosco and Laciari (2014) expõem um total de dezenove características espectrais, e, através do critério lambda de *Wilks*, seleciona sete para seu modelo final. Yeo et al. (2009) realizam a divisão da função de densidade do espectro de potência resultante da FFT em quatro segmentos – de acordo com as bandas delta, teta, alfa e beta – extraíndo quatro características para cada banda de frequência.

Anitha (2018), Belakhdar et al. (2018), Budak et al. (2019), Correa, Orosco and Laciari (2014) fazem uso de canal único e Yeo et al. (2009) utilizam múltiplos canais. Belakhdar et al. (2018) e Correa, Orosco and Laciari (2014) implementam redes neurais artificiais rasas (*artificial neural network*, ANN). Anitha (2018) e Yeo et al. (2009) usam classificador SVM. Para Budak et al. (2019), cada grupo de características de cada um de seus blocos é alimentado à uma rede Memória Longa de Curto Prazo (LSTM). Anitha (2018), Belakhdar et al. (2018), Budak et al. (2019), Correa, Orosco and Laciari (2014) validam seus modelos por *10-fold CV* e Yeo et al. (2009) por validação *5-fold CV*.

A Tabela 3.2 lista os diferentes aspectos dos trabalhos recém revisados.

3.3 CNNs Multi-entrada para Análise do Sono

Algumas abordagens usam o conceito de CNNs multi-entrada para tarefas relacionadas à análise do sono. Zhu, Luo and Yu (2020) usam tal tipo de arquitetura junto de múltiplos canais de sinais EEG, passando cada canal para uma entrada diferente e endereçando o problema de classificação de estágios de sono. Xiang et al. (2022) usam CNN multi-entrada 3D para detecção de fadiga, extraíndo características espaciais e temporais de dados de vídeo. O modelo considerado por tais autores conta com três entradas, cada uma recebendo imagens de um olho e da boca do motorista. Utilizando-se de uma representação conjunta de sinais brutos e imagens tempo-frequência, Chen et al. (2023) considera uma rede neural convolucional em grafos (*graph convolutional network*, GCN) multi-entrada também aplicada à classificação de estágios de sono. Por fim, Balam, Sameer and Chinara (2021), modelo no qual esse trabalho foi inspirado, passam sinais de EEG não-tratados, no domínio temporal, para uma CNN multi-entrada, com duas unida-

des de processamento. Cada entrada de tal modelo processa a mesma entrada e extrai diferentes informações que são posteriormente combinadas.

3.4 Semelhanças com o Método Proposto

Concluindo, existem diversos trabalhos que realizam DD com ML e sinais de EEG, se utilizando de variadas configurações, como canais múltiplos ou únicos, tamanho das épocas, método de pré-processamento, extração automática ou manual de características, classificadores e métodos de validação. Nesse contexto, buscamos apresentar trabalhos que também optam por configurações semelhantes às do nosso modelo, como utilização de canal único (ANITHA, 2018), segmentação das épocas em 1s (BALAM; SAMEER; CHINARA, 2021), utilização de transformada *Wavelet* (BUDAK et al., 2019), extração automática de características (BALAM; SAMEER; CHINARA, 2021), classificadores CNN multi-entrada (ZHU; LUO; YU, 2020) e validação por *split* fixo (BALAM; SAMEER; CHINARA, 2021) e *5-fold CV* (YEO et al., 2009).

4 MÉTODO PROPOSTO

Esse capítulo apresenta a metodologia proposta, discutida de forma geral na Seção 4.1. A Seção 4.2 detalha a base de dados considerada. A Seção 4.3 expõe o pré-processamento dos dados adotado neste trabalho. A Seção 4.4 oferece uma breve explicação sobre como a DWT de Haar foi utilizada no escopo de nossa proposta. A Seção 4.5 apresenta arquitetura da CNN multi-entradas proposta.

4.1 Visão Geral

A metodologia proposta compreende três passos: pré-processamento, filtragem espectral dos sinais e classificação. A Figura 4.1 ilustra esses passos. Os dados de entrada do método proposto são sinais de EEG, enquanto o de saída é um rótulo predito indicando o estado de alerta ou de sonolência. O restante deste capítulo explica em detalhes cada um desses passos, começando pela base de dados adotada.

4.2 Base de Dados

A base de dados *Sleep-EDF Database Expanded*¹ contém gravações polissonográficas de cerca de 20 horas cada, as quais são registradas durante dois períodos diurno e noturno subsequentes nas casas dos vinte três participantes do estudo (KEMP et al., 2018). A base de dados conta com sinais de EEG (das localizações dos eletrodos Fpz-Cz e Pz-Oz), EOG (horizontal) e EMG do queixo submentoniano. Neste trabalho, assim como em Balam, Sameer and Chinara (2021), Hasan and Koo (2023), Elidrissi et al. (2023), consideramos o canal Pz-Oz, uma vez que, dentre os dois disponíveis, esse canal permite melhor identificação da sonolência (HASAN; KOO, 2023). Os sinais de EEG são amostrados a 100Hz e são acompanhados de um hipnograma correspondente. O hipnograma é a anotação dos estágios do sono observados por especialistas durante o período. Essa anotação segue o padrão de R&K. Um rótulo é dado a cada época de 30s de sinal registrado. A anotação disponível conta com os estados de alerta, sonolência e outros quatro estágios de sono. Como em Balam, Sameer and Chinara (2021), Silveira, Kozakevicius and Rodrigues (2016), Ghadami et al. (2022), neste trabalho, apenas os dois primeiros

¹Disponível publicamente em <<https://www.physionet.org/content/sleep-edfx/1.0.0/>>.

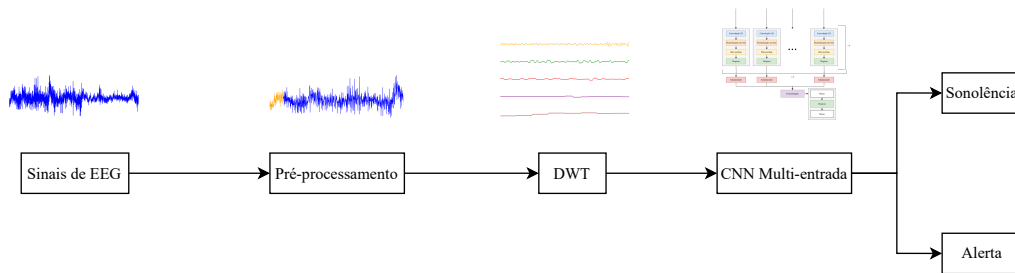


Figura 4.1 – Visão geral da metodologia proposta.

são considerados para DD.

4.3 Pré-processamento

DD exige tempo de resposta rápido e, portanto, vários trabalhos utilizam épocas de 1s (BALAM; SAMEER; CHINARA, 2021; MENDONÇA et al., 2022), 2s (MOHAMMEDI; MOKRANI; MOUHOUBI, 2023; CHOI et al., 2019) ou 5s (MIN et al., 2023; CORREA; OROSCO; LACIAR, 2014). Portanto, neste trabalho, subdividimos épocas de 30s em épocas de 1s e as rotulamos de acordo, excluindo os trechos que não correspondem aos estados de “alerta” e “sonolência”. Anotações que correspondem a defeitos de registro (“*bad readings*”) também são excluídas. Das épocas restantes, selecionamos aleatoriamente 600 épocas correspondentes a cada classe como em (BALAM; SAMEER; CHINARA, 2021). A Figura 4.2 ilustra épocas de 30s rotuladas como estados de “alerta” e “sonolência”. Destaca-se que essas épocas foram divididas em segmentos de 1s neste trabalho.

Os sinais de EEG disponibilizados na *Sleep-EDF Database Expanded* têm baixa magnitude por serem medidos em volts. Para as etapas seguintes de nossa metodologia, aplicamos uma padronização dos dados de tal forma que eles tenham média zero e variância unitária (CUI et al., 2022). Esse procedimento garante uma maior estabilidade no treinamento de CNNs (ETTAHIRI; VICENTE; FECHTALI, 2022).

4.4 Filtragem Espectral

DWTs são amplamente utilizadas em processamento de sinais (GHAZALI et al., 2007). Nesse trabalho, a fim de realizar a filtragem dos sinais de EEG no domínio espectral, foi utilizada a DWT multinível de Haar (HAAR, 1910). A DWT de Haar permite análise e síntese dos sinais sem a necessidade de tratar condições de fronteira (STOLL-

que a transformação direta de único nível via DWT de Haar é dada por

$$\mathbf{w} = \mathbf{Q}_j \cdot \mathbf{v}. \quad (4.4)$$

No processo de transformação do sinal \mathbf{v} , a matriz \mathbf{C}_j captura frequências em $[0, \frac{f}{2})$ ao passo que \mathbf{D}_j captura frequências em $[\frac{f}{2}, f]$ (STOLLNITZ; DEROSE; SALESIN, 1995). Como a DWT de Haar é decimada (SILVEIRA; KOZAKEVICIUS, 2016), os primeiros 2^{J-1} coeficientes de \mathbf{w} correspondem a uma aproximação do sinal e os últimos 2^{J-1} coeficientes às variações dessa aproximação com relação ao sinal original (detalhes):

$$\mathbf{w} = [w_0 \ w_1 \ \dots \ w_{2^{J-1}-1} \mid w_{2^{J-1}} \ \dots \ w_{2^J-2} \ w_{2^J-1}]^\top. \quad (4.5)$$

A matriz \mathbf{Q}_j é ortonormal, o que significa que a transformação inversa de único nível via DWT de Haar é dada por

$$\mathbf{v} = \mathbf{Q}_j^\top \cdot \mathbf{w}. \quad (4.6)$$

A fim de realizar uma transformação direta de Haar com $L = J - J_0$ níveis sobre \mathbf{v} , considera-se

$$\mathbf{w} = \hat{\mathbf{Q}}_{J_0} \cdot \dots \cdot \hat{\mathbf{Q}}_{J-2} \cdot \hat{\mathbf{Q}}_{J-1} \cdot \mathbf{Q}_J \cdot \mathbf{v}, \quad (4.7)$$

em que

$$\hat{\mathbf{Q}}_j = \left[\begin{array}{c|c} \mathbf{Q}_j & 0 \\ \hline 0 & \mathbf{I}_{2^{J-2j}} \end{array} \right] \quad (4.8)$$

e $\mathbf{I}_{2^{J-2j}}$ é a matriz de identidade de dimensão $2^J - 2^j$.

Nesse caso, apenas os primeiros 2^{J_0} coeficientes compõem uma aproximação do sinal. Os demais coeficientes são *detalhes* associados aos diferentes L níveis:


$$\mathbf{w} = [w_0 \ \dots \ w_{2^{J_0}-1} \mid w_{2^{J_0}} \ \dots \ w_{2^{J_0+1}-1} \mid \dots \mid w_{2^{J-2}} \ \dots \ w_{2^{J-1}-1} \mid w_{2^{J-1}} \ \dots \ w_{2^J-1}]^\top. \quad (4.9)$$

A transformação inversa de Haar de L níveis é dada por

$$\mathbf{v} = \mathbf{Q}_J^\top \cdot \hat{\mathbf{Q}}_{J-1}^\top \cdot \hat{\mathbf{Q}}_{J-2}^\top \cdot \hat{\mathbf{Q}}_{J_0}^\top \cdot \dots \cdot \mathbf{w}. \quad (4.10)$$

O processo de truncamento de parte dos coeficientes do vetor transformado \mathbf{w} seguido da transformação inversa (Eq. (4.7)) permite selecionar faixas de frequência de tal

Figura 4.3 – Coeficientes da DWT de Haar associados a diferentes ritmos cerebrais. Amostras da época original são destacadas em azul. Os coeficientes destacados em cor estão, em ordem, associados aos ritmos gama, beta, alfa, teta e delta.



Fonte: o autor.

forma que o sinal resultante ($\tilde{\mathbf{v}}$) contém apenas bandas de frequência de interesse (SILVEIRA; KOZAKEVICIUS; RODRIGUES, 2016). Por exemplo, ao manter apenas os primeiros 2^{J_0} coeficientes e zerar os demais, temos

$$\tilde{\mathbf{w}} = [w_0 \dots w_{2^{J_0}-1} | 0 \dots 0 | \dots | 0 \dots 0 | 0 \dots 0]^T. \quad (4.11)$$

Ao aplicar (4.7) sobre $\tilde{\mathbf{w}}$, obtemos

$$\tilde{\mathbf{v}} = \mathbf{Q}_J^T \cdot \hat{\mathbf{Q}}_{J-1}^T \cdot \hat{\mathbf{Q}}_{J-2}^T \cdot \hat{\mathbf{Q}}_{J_0}^T \cdot \dots \cdot \tilde{\mathbf{w}}. \quad (4.12)$$

O vetor $\tilde{\mathbf{v}}$ é uma versão filtrada de \mathbf{v} que contém apenas as frequências em $[0, \frac{f}{2^L})$.


A Tabela 4.1 indica que faixas de frequência são capturadas em cada nível de decomposição da DWT de Haar considerando $f = 100\text{Hz}$ e os ritmos cerebrais associados. A Figura 4.3 apresenta graficamente o sinal de EEG de entrada e os coeficientes transformados associados a cada ritmo cerebral.

Tabela 4.1 – Frequências associadas aos níveis de decomposição da DWT e ritmos cerebrais relacionados.

Nível de decomposição	Frequência (Hz)	Ritmo Cerebral
1	25,0000 – 50,0000	Gama
2	12,5000 – 25,0000	Beta
3	6,2500 – 12,5000	Alfa
4	3,1250 – 6,2500	Teta
5	1,5625 – 3,1250	Delta
5	0,0000 – 1,5625	Delta

A Figura 4.4 ilustra um sinal de EEG com $N = 128$ amostras e cinco versões filtradas associadas aos ritmos gama, alfa, beta, delta e teta. Como as cinco versões do sinal original cobrem todo seu espectro, a soma dessas reconstrói o sinal original.

Figura 4.4 – Sinal de EEG não processado e versões desse sinal associadas aos diferentes ritmos cerebrais (gama, beta, alfa, teta e delta, em ordem).



Fonte: o autor.

4.5 CNN Multi-entrada

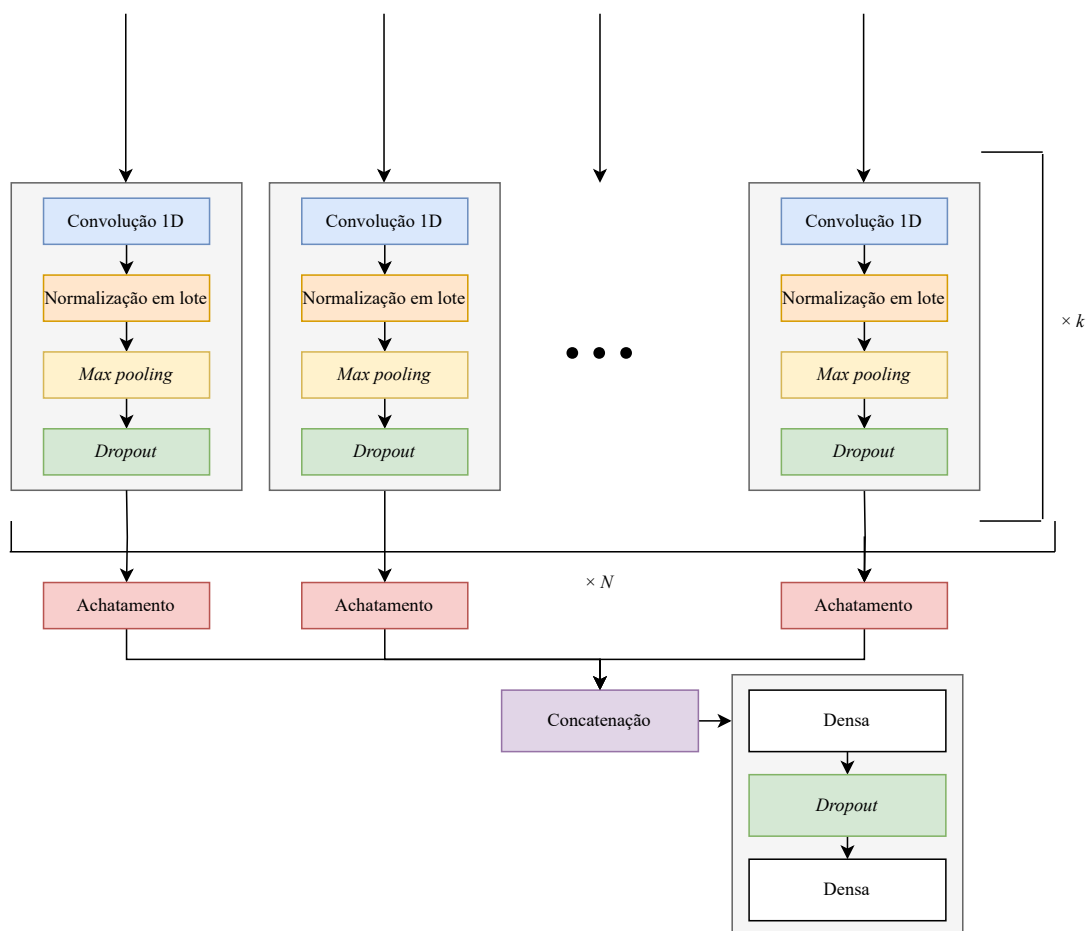
Inspirado pelo modelo de Balam, Sameer and Chinara (2021), a arquitetura proposta neste trabalho é uma CNN com múltiplas entradas. Entretanto, aqui, diferentemente de Balam, Sameer and Chinara (2021), cada entrada recebe um conjunto de dados distinto. Mais precisamente, cada entrada da CNN proposta recebe uma versão do sinal de EEG filtrada de acordo com as faixas de frequência associadas a um ritmo cerebral. Nossa hipótese é que as diferentes versões do sinal permitem que o modelo melhor ajuste os filtros de forma a identificar padrões relacionados aos estados de sonolência e alerta.

Neste trabalho, avaliamos variado número de entradas N . Cada entrada é processada por k blocos sequenciais compostos de uma camada convolucional (com 9 filtros de tamanho 3), normalização em lote (*batch normalization*), *pooling* de máximo e *dropout*. Os mapas de características processados pelas N entradas são achatados (*flatten*) e concatenados. O tensor resultante é submetido a uma camada totalmente conectada (com 64 unidades) com *dropout* e, então, uma última camada totalmente conectada (com uma unidade). A Figura 4.5 apresenta uma representação gráfica da arquitetura proposta. Aqui é considerado $k = 4$, atribuído experimentalmente. São testados diferentes valores de $N = 1, 2, \dots, 5$ (confira os resultados na Seção 5.2). As camadas de convoluções e a penúltima camada totalmente conectada são ativadas por unidades lineares retificadas (ReLU). A última camada totalmente conectada é ativada por uma função sigmoide. A

função de perda adotada é uma entropia cruzada binária (*binary cross entropy*) (RUBY; YENDAPALLI, 2020).

Para o treinamento, foram considerados os seguintes hiperparâmetros: tamanho do lote igual a 64, *momentum* igual a 0.9 e *epsilon* igual a 0.001 para normalização em lote e 0.2 para as camadas de *dropout*. O otimizador *Adam* é utilizado com taxa de aprendizado inicial 0.001. Consideramos 20 épocas para o treinamento. Valores atribuídos empiricamente.

Figura 4.5 – Arquitetura da CNN multi-entrada proposta.



Fonte: o autor.

5 RESULTADOS

5.1 Recursos Computacionais

Os experimentos deste trabalho foram conduzidos em um computador Intel(R) Core(TM) i5-11400H @ 2.70GHz, 16GB RAM, 256GB SSD e placa gráfica NVIDIA RTX 3050. As implementações associadas a este trabalho foram realizadas em Python 3.10.11. Além disso, foram usadas as bibliotecas Numpy (para operações e manipulação de arranjos de dados), Matplotlib (para geração de gráficos), MNE (para leitura e manipulação dos sinais de EEG), Tensorflow (para modelagem e treinamento da CNN) e Sklearn (para gerenciamento da base de dados e avaliação dos modelos). O repositório do código desenvolvido pode ser encontrado em: <<https://github.com/LuccaMilano/CNN-Model/tree/main>>.

5.2 Comparações com uma CNN Multi-entrada do Estado da Arte

Ainda há considerável discussão sobre qual domínio dos dados extraídos de sinais de EEG permite a modelos de ML maior acurácia em DD (STANCIN; CIFREK; JOVIC, 2021; LUO, 2023). O presente trabalho vai ao encontro dessa discussão, se inspirando no modelo de (BALAM; SAMEER; CHINARA, 2021), que utiliza CNNs multi-entrada. No entanto, enquanto Balam, Sameer and Chinara (2021) utilizam épocas sem qualquer filtragem – passando os mesmos dados para duas unidades – nós filtramos o sinal em diferentes bandas e passamos cada versão do sinal a uma entrada diferente.

Implementamos a arquitetura de Balam, Sameer and Chinara (2021) conforme descrição do artigo original. Ao melhor de nosso conhecimento, Balam, Sameer and Chinara (2021) atinge o estado da arte em DD quando considerando CNNs multi-entrada. Contatamos os autores, mas não tivemos acesso ao modelo e/ou pesos pre-treinados. A arquitetura de Balam, Sameer and Chinara (2021) conta com duas unidades de processamento linear para CNN multi-entrada. A primeira considera quatro camadas ocultas, contendo camadas convolucionais com nove filtros e tamanho de *kernel* igual a 3, normalização em lote, *pooling* e *dropout* alternadas em sequência. A segunda varia a quantidade de camadas ocultas, três, a quantidade de filtros por camada convolucional, três, e o tamanho dos *kernels* desses filtros – cinco. As saídas das duas *branches* são achatadas e concatenadas, sendo passadas a duas camadas densas. Os hiperparâmetros utilizados

foram os mesmos do nosso modelo.


Nessa seção, como em Balam, Sameer and Chinara (2021), para cada um dos sujeitos da base de dados, consideramos 600 épocas de 1s rotuladas como “alerta” e 600 épocas de 1s rotuladas como “sonolência”. Aqui, foram construídos *splits* fixos dos dados com 70% destes para treinamento, 15% para validação e 15% para teste.

Em nossos testes, a quantidade de bandas (associadas aos ritmos cerebrais gama, alfa, beta, delta e teta) é sempre igual a quantidade de unidades de processamento linear da CNN multi-entrada. Cada entrada processa dados associados a uma banda de frequência apenas. Múltiplas configurações com diferentes quantidades de entrada/ritmos cerebrais foram testadas, sendo que a maior acurácia foi com um modelo com cinco entradas.

O modelo com a arquitetura de cinco entradas atingiu 81.6% de acurácia e pontuação *F1* 82.3% na base de dados considerada. Em comparação, o modelo implementado de Balam, Sameer and Chinara (2021), obteve 80.53% de acurácia e pontuação *F1* 81.8%. Para fins de comparação, testamos um modelo com uma unidade de processamento linear (CNN com uma entrada apenas) que considera os sinais de EEG sem filtragem. Tal modelo alcançou uma acurácia de 80.58% e pontuação *F1* 81.3%. Devido a padronização dos dados feita no pré-processamento, a acurácia e pontuação *F1* possuem valores similares, e portanto, utilizamos acurácia no restante do experimento. As Figuras 5.1 e 5.2 apresentam as curvas de aprendizagem associadas aos modelos com uma e cinco entradas, respectivamente. Em ambas, observa-se uma saturação do aprendizado a partir da época 20. Tanto a curva de validação como a de treino apresentam comportamento semelhante, o que indica que o modelo não sofre *overfitting*. Nos testes seguintes, consideramos treinamentos com 20 épocas.


As Tabelas 5.1, 5.2 e 5.3 apresentam as matrizes de confusão para o modelo de cinco entradas proposto, o modelo de Balam, Sameer and Chinara (2021) e o modelo de única entrada, respectivamente. Para os três modelos, a classificação do estado de sonolência apresenta melhores resultados, visto que o maior número de erros é referente à falsos positivos nas três matrizes de confusão. A partir de tal informação, é possível capitalizar o uso das bandas de frequência, já que sabemos que ritmos como gama estão atrelados ao estado de alerta. Portanto, características que se utilizem de tal podem ser utilizadas para melhorar a taxa de acerto da classificação do estado de alerta.

Figura 5.1 – Curvas de aprendizado para o modelo com dados não-processados e uma unidade de processamento linear.



Fonte: o autor.

Figura 5.2 – Curva de aprendizado para o modelo com cinco ritmos cerebrais/unidades de processamento linear.



Fonte: o autor.

5.3 Estudos de Ablação

A fim de avaliar o impacto das diferentes entradas, fizemos uma série de experimentos adicionais. A Tabela 5.4 apresenta diferentes configurações testadas. A Configuração 1 é a mesma avaliada na seção anterior, contando com cinco entradas – uma para cada versão filtrada do sinal. A primeira linha da Tabela 5.5 apresenta os resultados obtidos para as diferentes configurações de acordo com a Tabela 5.4. Note que a arquitetura da Configuração 1 registrou a maior acurácia.

A remoção do sinal associado ao ritmo delta gera o menor impacto nas arquiteturas com quatro entradas (Configuração 6), pontuando 80.57% de acurácia. Isso corrobora

Tabela 5.1 – Matriz de confusão para modelo com cinco ritmos cerebrais/unidades de processamento linear.

		Previsto	
		Alerta	Sonolência
Real	Alerta	1478	409
	Sonolência	283	1610

Tabela 5.2 – Matriz de confusão para modelo com dados não-processados e duas unidades de processamento linear (Balam, Sameer and Chinara (2021)).

		Previsto	
		Alerta	Sonolência
Real	Alerta	1381	484
	Sonolência	252	1663

Tabela 5.3 – Matriz de confusão para modelo com dados não-processados e uma unidade de processamento linear.

		Previsto	
		Alerta	Sonolência
Real	Alerta	1444	469
	Sonolência	265	1602

Tabela 5.4 – Frequências associadas aos ritmos cerebrais

Configuração	Ritmos Cerebrais
1	Alfa, beta, gama, delta, teta
2	Alfa, beta, delta, teta
3	Alfa, gama, delta, teta
4	Beta, gama, delta, teta
5	Alfa, beta, gama, delta
6	Alfa, beta, gama, teta
7	Alfa, delta, teta
8	Alfa, gama, delta
9	Alfa, beta, gama
10	Gama, delta
11	Delta, teta
12	Gama
13	Delta

Tabela 5.5 – Resultados de acurácia para cada configuração do modelo para validações 5-fold CV e splits fixos (70%-15%-15%)

Configuração	1	2	3	4	5	6	7	8	9	10	11	12	13
Validação Splits fixos	81.6	75.42	79.87	79.68	78.60	80.57	68.52	79.18	80.63	77.17	54.87	77.25	55.63
Validação 5-fold CV	82.2	72.82	80.54	78.49	79.62	79.60	66.17	79.01	79.13	75.85	55.65	72.54	56.39

a ideia de que os ritmos alfa, beta, teta e gama são os mais importantes para DD (ARIF; MUNAWAR; ALI, 2023). Ademais, percebe-se, que a remoção do sinal associado ao ritmo gama afeta a classificação negativamente (Configuração 2), apresentando a menor acurácia dentre os modelos com 4 entradas, 75.42%. O ritmo gama tem a maior frequência, e dada a natureza não-estacionária dos sinais de EEG, permite considerável variação. A manutenção do sinal associado a este ritmo se mostrou fundamental para decisão acerca do estado de vigília do sujeito.

Dentre os testes com três entradas (Configurações 7, 8, 9), experimentamos arquiteturas que desconsideraram a versão do sinal associada ao ritmo gama, com o intuito de verificar se o modelo seria capaz de preservar a acurácia. Tal resposta se mostrou negativa, visto que a acurácia da Configuração 7 foi de 68.52% em comparação com as Configurações 8 e 9, com 79.18% e 80.63% de acurácia em comparação. Tal resultado também mostra que arquiteturas de três entradas que consideraram o sinal associado ao ritmo gama conseguiram resultados com níveis aceitáveis de acurácia. Testes com duas entradas (Configurações 10, 11) foram feitos com as mesmas razões em mente, e demonstraram resultados semelhantes, com a arquitetura que leva o sinal gama em conta (Configuração 10) chegando a 77.17% de acurácia em contraste com a Configuração 11, sem o sinal gama, que chega a 54.87%. Por fim, surpreendentemente, o modelo manteve uma acurácia relativamente alta em comparação com as demais configurações, utilizando-se de apenas um entrada com o ritmo gama (Configuração 12).

A partir da matrizes de confusão das Tabelas 5.6 a 5.17, é possível identificar que nos modelos em que há uma queda da acurácia (em especial as Configurações 7, 10, 13), o motivo está nos falsos positivos, quando o modelo retorna o rótulo “alerta” para o que deveria ser “sonolência”. Mesmo nos modelos em que há uma queda mais significativa da acurácia, quando o ritmo gama é retirado, o modelo ainda rotula grande parte da “sonolência” corretamente (Tabelas 5.11, 5.14 e 5.17). Tal ocorrência está em linha com o conhecimento que temos sobre os ritmo gama, visto que este está associado à um estado de alerta e, portanto, quando retirado do modelo, a queda da classificação correta dos estados de “alerta” é esperado. No geral, os resultados desse experimento se comportaram dentro das expectativas considerando o conhecimento sobre os ritmos

cerebrais, fomentando a ideia de que seu uso apresenta benefícios na DD com ML.

Por fim, realizamos testes com *5-fold CV* – que podem ser comparados com aqueles com *splits* pré-definidos. Os resultados estão identificados na segunda linha da Tabela 5.5. Note que os desempenhos dos modelos nas várias configurações não é muito variável dependendo do modelo de avaliação, sugerindo que o desempenho do modelo é confiável e não depende muito do particionamento de dados.

Tabela 5.6 – Matriz de confusão para modelo com Configuração 2, referente a Tabela 5.4.

		Previsto	
		Alerta	Sonolência
Real	Alerta	1301	592
	Sonolência	337	1550

Tabela 5.7 – Matriz de confusão para modelo com Configuração 3, referente a Tabela 5.4.

		Previsto	
		Alerta	Sonolência
Real	Alerta	1458	468
	Sonolência	293	1561

Tabela 5.8 – Matriz de confusão para modelo com Configuração 4, referente a Tabela 5.4.

		Previsto	
		Alerta	Sonolência
Real	Alerta	1406	460
	Sonolência	308	1606

Tabela 5.9 – Matriz de confusão para modelo com Configuração 5, referente a Tabela 5.4.

		Previsto	
		Alerta	Sonolência
Real	Alerta	1367	538
	Sonolência	271	1604

Tabela 5.10 – Matriz de confusão para modelo com Configuração 6, referente a Tabela 5.4.

		Previsto	
		Alerta	Sonolência
Real	Alerta	1453	427
	Sonolência	296	1604

Tabela 5.11 – Matriz de confusão para modelo com Configuração 7, referente a Tabela 5.4.

		Previsto	
		Alerta	Sonolência
Real	Alerta	1166	658
	Sonolência	532	1424

Tabela 5.12 – Matriz de confusão para modelo com Configuração 8, referente a Tabela 5.4.

		Previsto	
		Alerta	Sonolência
Real	Alerta	1369	585
	Sonolência	202	1624

Tabela 5.13 – Matriz de confusão para modelo com Configuração 9, referente a Tabela 5.4.

		Previsto	
		Alerta	Sonolência
Real	Alerta	1438	487
	Sonolência	245	1610

Tabela 5.14 – Matriz de confusão para modelo com Configuração 10, referente a Tabela 5.4.

		Previsto	
		Alerta	Sonolência
Real	Alerta	1275	627
	Sonolência	236	1642

Tabela 5.15 – Matriz de confusão para modelo com Configuração 11, referente a Tabela 5.4.

		Previsto	
		Alerta	Sonolência
Real	Alerta	685	1168
	Sonolência	538	1389

Tabela 5.16 – Matriz de confusão para modelo com Configuração 12, referente a Tabela 5.4.

		Previsto	
		Alerta	Sonolência
Real	Alerta	1227	647
	Sonolência	213	1693

Tabela 5.17 – Matriz de confusão para modelo com Configuração 13, referente a Tabela 5.4.

		Previsto	
		Alerta	Sonolência
Real	Alerta	696	1186
	Sonolência	491	1407

6 CONCLUSÃO

Esse trabalho endereçou o problema de DD utilizando sinais de EEG de um único canal. Propomos a utilização de uma CNN multi-entrada que considera diferentes versões do sinal, cada um filtrada em uma determinada banda de frequências. Cada banda é associada a ritmos cerebrais conhecidos por serem associados à presença ou ausência de sonolência.

Nosso trabalho enriquece a discussão sobre qual dos domínios utilizar, temporal ou espectral, para DD. Naturalmente, essa discussão está longe de ser resolvida. No entanto, mostramos que é possível unir as duas ideias, fazendo com que sinais no domínio temporal, porém filtrados em domínio espectral, possam ser submetidos a um modelo de DL para extração automatizada de características. Além disso, nossos experimentos mostraram que, dentre as arquiteturas testadas, aquelas que consideram informações associadas ao ritmo gama têm melhor acurácia.

Para trabalhos futuros, planejamos considerar arquiteturas mais profundas, e avaliar qual o impacto de adicionar ou remover camadas convolucionais – a depender da frequência dos sinais esperados numa dada entrada. Também planejamos explorar mecanismos como *attention* e *previous epoch stage*, como Zhu, Luo and Yu (2020), que faz uso de uma CNN multi-entrada para classificação de estágios de sono. Isso poderia viabilizar o desenvolvimento de um sistema completo para DD que trabalhe com séries temporais.

REFERÊNCIAS

ABOALAYON, K. A. I.; OCBAGABIR, H. T.; FAEZIPOUR, M. Efficient sleep stage classification based on eeg signals. In: **IEEE Long Island Systems, Applications and Technology (LISAT) Conference 2014**. 2014. p. 1–6.

ALASKAR, H. Convolutional neural network application in biomedical signals. **J Comput Sci Inform Tech**, v. 6, n. 2, p. 45–59, 2018.

ALBADAWI, Y.; ALREDHAEI, A.; TAKRURI, M. Real-time machine learning-based driver drowsiness detection using visual features. **Journal of Imaging**, MDPI AG, v. 9, n. 5, p. 91, 2023. Disponível na Internet: <<https://doi.org/10.3390/jimaging9050091>>.

ALYASSERI, Z. A. A. et al. EEG channel selection for person identification using binary grey wolf optimizer. **IEEE Access**, Institute of Electrical and Electronics Engineers (IEEE), v. 10, p. 10500–10513, 2022. Disponível na Internet: <<https://doi.org/10.1109/access.2021.3135805>>.

AMARASINGHE, K.; WIJAYASEKARA, D.; MANIC, M. EEG based brain activity monitoring using artificial neural networks. In: **2014 7th International Conference on Human System Interactions (HSI)**. IEEE, 2014. Disponível na Internet: <<https://doi.org/10.1109/hsi.2014.6860449>>.

AMIN, H. U. et al. Feature extraction and classification for eeg signals using wavelet transform and machine learning techniques. **Australasian physical & engineering sciences in medicine**, Springer, v. 38, p. 139–149, 2015.

ANITHA, C. Detection and analysis of drowsiness in human beings using multimodal signals. In: **Digital Business**. Springer International Publishing, 2018. p. 157–174. Disponível na Internet: <https://doi.org/10.1007/978-3-319-93940-7_7>.

AREFNEZHAD, S. et al. Driver drowsiness estimation using EEG signals with a dynamical encoder–decoder modeling framework. **Scientific Reports**, Springer Science and Business Media LLC, v. 12, n. 1, 2022. Disponível na Internet: <<https://doi.org/10.1038/s41598-022-05810-x>>.

ARIF, S.; MUNAWAR, S.; ALI, H. Driving drowsiness detection using spectral signatures of EEG-based neurophysiology. **Frontiers in Physiology**, Frontiers Media SA, v. 14, mar. 2023. Disponível na Internet: <<https://doi.org/10.3389/fphys.2023.1153268>>.

BAJAJ, V. et al. Feature extraction method for classification of alertness and drowsiness states EEG signals. **Applied Acoustics**, Elsevier BV, v. 163, p. 107224, jun. 2020. Disponível na Internet: <<https://doi.org/10.1016/j.apacoust.2020.107224>>.

BALAM, V. P.; SAMEER, V. U.; CHINARA, S. Automated classification system for drowsiness detection using convolutional neural network and electroencephalogram. **IET Intelligent Transport Systems**, Institution of Engineering and Technology (IET), v. 15, n. 4, p. 514–524, 2021. Disponível na Internet: <<https://doi.org/10.1049/itr2.12041>>.

BELAKHDAR, I. et al. Single-channel-based automatic drowsiness detection architecture with a reduced number of EEG features. **Microprocessors and Microsystems**, Elsevier BV, v. 58, p. 13–23, 2018. Disponível na Internet: <<https://doi.org/10.1016/j.micpro.2018.02.004>>.

BERKA, C. et al. Implementation of a closed-loop real-time eeg-based drowsiness detection system: Effects of feedback alarms on performance in a driving simulator. In: **1st International Conference on Augmented Cognition, Las Vegas, NV**. 2005. p. 151–170.

BUDAK, U. et al. An effective hybrid model for EEG-based drowsiness detection. **IEEE Sensors Journal**, Institute of Electrical and Electronics Engineers (IEEE), v. 19, n. 17, p. 7624–7631, 2019. Disponível na Internet: <<https://doi.org/10.1109/jsen.2019.2917850>>.

CHAABENE, S. et al. Convolutional neural network for drowsiness detection using EEG signals. **Sensors**, MDPI AG, v. 21, n. 5, p. 1734, mar. 2021. Disponível na Internet: <<https://doi.org/10.3390/s21051734>>.

CHEN, X. et al. MMSleepGNet: Mixed multi-branch sequential fusion model based on graph convolutional network for automatic sleep staging. **IEEE Transactions on Instrumentation and Measurement**, Institute of Electrical and Electronics Engineers (IEEE), p. 1–1, 2023. Disponível na Internet: <<https://doi.org/10.1109/tim.2023.3298402>>.

CHOI, H.-S. et al. Learning-based instantaneous drowsiness detection using wired and wireless electroencephalography. **IEEE Access**, Institute of Electrical and Electronics Engineers (IEEE), v. 7, p. 146390–146402, 2019. Disponível na Internet: <<https://doi.org/10.1109/access.2019.2946053>>.

CORREA, A. G.; LEBER, E. L. An automatic detector of drowsiness based on spectral analysis and wavelet decomposition of EEG records. In: **2010 Annual International Conference of the IEEE Engineering in Medicine and Biology**. IEEE, 2010. Disponível na Internet: <<https://doi.org/10.1109/iembs.2010.5626721>>.

CORREA, A. G.; OROSCO, L.; LACIAR, E. Automatic detection of drowsiness in EEG records based on multimodal analysis. **Medical Engineering & Physics**, Elsevier BV, v. 36, n. 2, p. 244–249, 2014. Disponível na Internet: <<https://doi.org/10.1016/j.medengphy.2013.07.011>>.

CORSI-CABRERA, M. et al. Time course of reaction time and EEG while performing a vigilance task during total sleep deprivation. **Sleep**, Oxford University Press (OUP), v. 19, n. 7, p. 563–569, 1996. Disponível na Internet: <<https://doi.org/10.1093/sleep/19.7.563>>.

CUI, J. et al. A compact and interpretable convolutional neural network for cross-subject driver drowsiness detection from single-channel eeg. **Methods**, Elsevier, v. 202, p. 173–184, 2022.

DKHIL, M. B.; WALI, A.; ALIMI, A. M. Drowsy driver detection by EEG analysis using fast fourier transform. In: **2015 15th International Conference on Intelligent Systems Design and Applications (ISDA)**. IEEE, 2015. Disponível na Internet: <<https://doi.org/10.1109/isda.2015.7489245>>.

ELIDRISSI, M. E. et al. Drivers' drowsiness detection based on an optimized random forest classification and single-channel electroencephalogram. **International Journal of Electrical and Computer Engineering (IJECE)**, v. 13, n. 3, p. 3398–3406, 2023.

ETTAHIRI, H.; VICENTE, J. M. F.; FECHTALI, T. Eeg signals in mental fatigue detection: A comparing study of machine learning technics vs deep learning. In: SPRINGER. **International Work-Conference on the Interplay Between Natural and Artificial Computation**. [S.l.], 2022. p. 625–633.

FOUAD, I. A. A robust and efficient EEG-based drowsiness detection system using different machine learning algorithms. **Ain Shams Engineering Journal**, Elsevier BV, v. 14, n. 3, p. 101895, 2023. Disponível na Internet: <<https://doi.org/10.1016/j.asej.2022.101895>>.

GHADAMI, A. et al. Automated driver drowsiness detection from single-channel eeg signals using convolutional neural networks and transfer learning. In: **2022 IEEE 25th International Conference on Intelligent Transportation Systems (ITSC)**. 2022. p. 4068–4073.

GHAZALI, K. H. et al. Feature extraction technique using discrete wavelet transform for image classification. In: **2007 5th Student Conference on Research and Development**. IEEE, 2007. Disponível na Internet: <<https://doi.org/10.1109/scored.2007.4451366>>.

HAAR, A. Zur theorie der orthogonalen funktionensysteme. **Mathematische Annalen**, Springer Science and Business Media LLC, v. 69, n. 3, p. 331–371, 1910. Disponível na Internet: <<https://doi.org/10.1007/bf01456326>>.

HAL, B. V. et al. Low-cost EEG-based sleep detection. In: **2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society**. IEEE, 2014. Disponível na Internet: <<https://doi.org/10.1109/embc.2014.6944641>>.

HAQUE, A. et al. Detection of small variations of ecg features using wavelet. **ARPN Journal of Engineering and applied Sciences**, v. 4, n. 6, p. 27–30, 2009.

HASAN, M. N.; KOO, I. Mixed-input deep learning approach to sleep/wake state classification by using EEG signals. **Diagnostics**, MDPI AG, v. 13, n. 14, p. 2358, jul. 2023. Disponível na Internet: <<https://doi.org/10.3390/diagnostics13142358>>.

HE, J. et al. A noninvasive real-time driving fatigue detection technology based on left prefrontal attention and meditation EEG. In: **2014 International Conference on Multisensor Fusion and Information Integration for Intelligent Systems (MFI)**. IEEE, 2014. Disponível na Internet: <<https://doi.org/10.1109/mfi.2014.6997673>>.

HOBSON, J. A. A manual of standardized terminology, techniques and scoring system for sleep stages of human subjects: A. rechtschaffen and a. kales (editors). (public health service, u.s. government printing office, washington, d.c., 1968, 58 p., \$4.00). **Electroencephalography and Clinical Neurophysiology**, v. 26, p. 644, 1969. Disponível na Internet: <<https://api.semanticscholar.org/CorpusID:59533589>>.

IBER, C. et al. The aasm manual for the scoring of sleep and associated events: Rules, terminology and technical specifications. **Westchester, IL: American Academy of Sleep Medicine**, 01 2007.

JAYARATHNE, I.; COHEN, M.; AMARAKEERTHI, S. Person identification from EEG using various machine learning techniques with inter-hemispheric amplitude ratio. **PLOS ONE**, Public Library of Science (PLoS), v. 15, n. 9, p. e0238872, 2020. Disponível na Internet: <<https://doi.org/10.1371/journal.pone.0238872>>.

KEMP, B. et al. Analysis of a sleep-dependent neuronal feedback loop: the slow-wave microcontinuity of the EEG. **IEEE Transactions on Biomedical Engineering**, Institute of Electrical and Electronics Engineers (IEEE), v. 47, n. 9, p. 1185–1194, 2000. Disponível na Internet: <<https://doi.org/10.1109/10.867928>>.

KEMP, B. et al. **The Sleep-EDF Database [Expanded]**. physionet.org, 2018. Disponível na Internet: <<https://physionet.org/content/sleep-edfx/>>.

KHARE, S.; BAJAJ, V. Optimized tunable q wavelet transform based drowsiness detection from electroencephalogram signals. **IRBM**, Elsevier BV, v. 43, n. 1, p. 13–21, 2022. Disponível na Internet: <<https://doi.org/10.1016/j.irbm.2020.07.005>>.

KHURSHID, A.; SCHARCANSKI, J. An adaptive face tracker with application in yawning detection. **Sensors**, MDPI AG, v. 20, n. 5, p. 1494, mar. 2020. Disponível na Internet: <<https://doi.org/10.3390/s20051494>>.

KLONOWSKI, W. Everything you wanted to ask about EEG but were afraid to get the right answer. **Nonlinear Biomedical Physics**, Springer Science and Business Media LLC, v. 3, n. 1, 2009. Disponível na Internet: <<https://doi.org/10.1186/1753-4631-3-2>>.

KUMAR, J. S.; BHUVANESWARI, P. Analysis of electroencephalography (EEG) signals and its categorization—a study. **Procedia Engineering**, Elsevier BV, v. 38, p. 2525–2536, 2012. Disponível na Internet: <<https://doi.org/10.1016/j.proeng.2012.06.298>>.

LAL, S. K.; CRAIG, A. A critical review of the psychophysiology of driver fatigue. **Biological Psychology**, Elsevier BV, v. 55, n. 3, p. 173–194, 2001. Disponível na Internet: <[https://doi.org/10.1016/s0301-0511\(00\)00085-5](https://doi.org/10.1016/s0301-0511(00)00085-5)>.

LAROCCO, J.; LE, M. D.; PAENG, D.-G. A systemic review of available low-cost EEG headsets used for drowsiness detection. **Frontiers in Neuroinformatics**, Frontiers Media SA, v. 14, oct. 2020. Disponível na Internet: <<https://doi.org/10.3389/fninf.2020.553352>>.

LUO, T. Features and recognition algorithms in sleep staging and drowsiness detection by using EEG. **Highlights in Science, Engineering and Technology**, Darcy & Roy Press Co. Ltd., v. 39, p. 176–182, 2023. Disponível na Internet: <<https://doi.org/10.54097/hset.v39i.6521>>.

MA, Y. et al. Driving fatigue detection from EEG using a modified PCANet method. **Computational Intelligence and Neuroscience**, Hindawi Limited, v. 2019, p. 1–9, jul. 2019. Disponível na Internet: <<https://doi.org/10.1155/2019/4721863>>.

MAJUMDER, S. et al. On-board drowsiness detection using EEG: Current status and future prospects. In: **2019 IEEE International Conference on Electro Information Technology (EIT)**. IEEE, 2019. Available from Internet: <<https://doi.org/10.1109/eit.2019.8833866>>.

MARDI, Z.; ASHTIANI, S. N. M.; MIKAILI, M. EEG-based drowsiness detection for safe driving using chaotic features and statistical tests. **J. Med. Signals Sens.**, Medknow, v. 1, n. 2, p. 130–137, may 2011.

MEDA, H.; GANESH, J. M. P.; SAHANI, A. Machine learning models for drowsiness detection. In: **2021 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)**. IEEE, 2021. Available from Internet: <<https://doi.org/10.1109/i2mtc50364.2021.9460017>>.

MENDONÇA, F. et al. A-phase index: an alternative view for sleep stability analysis based on automatic detection of the a-phases from the cyclic alternating pattern. **Sleep**, Oxford University Press (OUP), v. 46, n. 1, 2022. Disponível na Internet: <<https://doi.org/10.1093/sleep/zsac217>>.

MIN, J. et al. Fusion of forehead eeg with machine vision for real-time fatigue detection in an automatic processing pipeline. **Neural Computing and Applications**, Springer, v. 35, n. 12, p. 8859–8872, 2023.

MOHAMMEDI, M.; MOKRANI, J.; MOUHOUBI, A. Real-time and efficient EEG based driver drowsiness detection system with VANET for safe driving. Research Square Platform LLC, jan. 2023. Disponível na Internet: <<https://doi.org/10.21203/rs.3.rs-1972742/v1>>.

MORADI, A.; NAZARI, S. S. H.; RAHMANI, K. Sleepiness and the risk of road traffic accidents: A systematic review and meta-analysis of previous studies. **Transportation Research Part F: Traffic Psychology and Behaviour**, Elsevier BV, v. 65, p. 620–629, 2019. Disponível na Internet: <<https://doi.org/10.1016/j.trf.2018.09.013>>.

MOSER, D. et al. Sleep classification according to AASM and rechtschaffen & kales: Effects on sleep scoring parameters. **Sleep**, Oxford University Press (OUP), v. 32, n. 2, p. 139–149, 2009. Disponível na Internet: <<https://doi.org/10.1093/sleep/32.2.139>>.

MURUGAPPAN, M. et al. Wireless eeg signals based neuromarketing system using fast fourier transform (fft). In: **2014 IEEE 10th International Colloquium on Signal Processing and its Applications**. 2014. p. 25–30.

NANNI, L.; GHIDONI, S.; BRAHNAM, S. Handcrafted vs. non-handcrafted features for computer vision classification. **Pattern Recognition**, Elsevier BV, v. 71, p. 158–172, nov. 2017. Disponível na Internet: <<https://doi.org/10.1016/j.patcog.2017.05.025>>.

NG, J.; KADISH, A. H.; GOLDBERGER, J. J. Technical considerations for dominant frequency analysis. **Journal of Cardiovascular Electrophysiology**, Wiley, v. 18, n. 7, p. 757–764, jul. 2007. Disponível na Internet: <<https://doi.org/10.1111/j.1540-8167.2007.00810.x>>.

NOVELLI, L.; FERRI, R.; BRUNI, O. Sleep classification according to AASM and rechtschaffen and kales: effects on sleep scoring parameters of children and adolescents. **Journal of Sleep Research**, Wiley, v. 19, n. 1p2, p. 238–247, mar. 2010. Disponível na Internet: <<https://doi.org/10.1111/j.1365-2869.2009.00785.x>>.

OGINO, M. et al. Analysis of prefrontal single-channel EEG data for portable auditory ERP-based brain–computer interfaces. **Frontiers in Human Neuroscience**, Frontiers Media SA, v. 13, jul. 2019. Disponível na Internet: <<https://doi.org/10.3389/fnhum.2019.00250>>.

POURSADEGHIYAN, M. et al. Using image processing in the proposed drowsiness detection system design. **Iran. J. Public Health**, v. 47, n. 9, p. 1371–1378, 2018.

QIAO, W. et al. Continuous wavelet analysis as an aid in the representation and interpretation of electrogastrographic signals. **Annals of Biomedical Engineering**, Springer Science and Business Media LLC, v. 26, n. 6, p. 1072–1081, nov. 1998. Disponível na Internet: <<https://doi.org/10.1114/1.27>>.

RAMZAN, M. et al. A survey on state-of-the-art drowsiness detection techniques. **IEEE Access**, Institute of Electrical and Electronics Engineers (IEEE), v. 7, p. 61904–61919, 2019. Disponível na Internet: <<https://doi.org/10.1109/access.2019.2914373>>.

ROBERTS, J.; ROBERTS, T. D. Use of the butterworth low-pass filter for oceanographic data. **Journal of Geophysical Research**, American Geophysical Union (AGU), v. 83, n. C11, p. 5510, 1978. Disponível na Internet: <<https://doi.org/10.1029/jc083ic11p05510>>.

RUBY, U.; YENDAPALLI, V. Binary cross entropy with deep learning technique for image classification. **Int. J. Adv. Trends Comput. Sci. Eng**, v. 9, n. 10, 2020.

RUEHLAND, W. R. et al. The 2007 AASM recommendations for EEG electrode placement in polysomnography: Impact on sleep and cortical arousal scoring. **Sleep**, Oxford University Press (OUP), v. 34, n. 1, p. 73–81, jan. 2011. Disponível na Internet: <<https://doi.org/10.1093/sleep/34.1.73>>.

RUNDO, F. et al. An innovative deep learning algorithm for drowsiness detection from EEG signal. **Computation**, MDPI AG, v. 7, n. 1, p. 13, 2019. Disponível na Internet: <<https://doi.org/10.3390/computation7010013>>.

SABY, J. N.; MARSHALL, P. J. The utility of EEG band power analysis in the study of infancy and early childhood. **Developmental Neuropsychology**, Informa UK Limited, v. 37, n. 3, p. 253–273, 2012. Disponível na Internet: <<https://doi.org/10.1080/87565641.2011.614663>>.

SALEEM, S. Risk assessment of road traffic accidents related to sleepiness during driving: a systematic review. **Eastern Mediterranean Health Journal**, World Health Organization Regional Office for the Eastern Mediterranean (WHO/EMRO), v. 28, n. 9, p. 695–700, 2022. Disponível na Internet: <<https://doi.org/10.26719/emhj.22.055>>.

SILVEIRA, T. da; KOZAKEVICIUS, A. de J.; RODRIGUES, C. R. Drowsiness detection for single channel EEG by DWT best m-term approximation. **Research on Biomedical Engineering**, FapUNIFESP (SciELO), v. 31, n. 2, p. 107–115, jun. 2015. Disponível na Internet: <<https://doi.org/10.1590/2446-4740.0693>>.

SILVEIRA, T. L. da; KOZAKEVICIUS, A. J.; RODRIGUES, C. R. Automated drowsiness detection through wavelet packet analysis of a single EEG channel. **Expert Systems with Applications**, Elsevier BV, v. 55, p. 559–565, 2016. Disponível na Internet: <<https://doi.org/10.1016/j.eswa.2016.02.041>>.

SILVEIRA, T. L. T. da; KOZAKEVICIUS, A. de J. **Transformada Wavelet de Haar: Conceitos, formulações e aplicações**. 1. ed. [S.l.]: Sociedade Brasileira de Matemática, 2016. Online.

SRIRAAM, N.; SHRI, T. K. P.; MAHESHWARI, U. Recognition of wake-sleep stage 1 multichannel eeg patterns using spectral entropy features for drowsiness detection. **Australasian Physical & Engineering Sciences in Medicine**, Springer Science and Business Media LLC, v. 39, n. 3, p. 797–806, 2016. Disponível na Internet: <<https://doi.org/10.1007/s13246-016-0472-8>>.

STANCIN, I.; CIFREK, M.; JOVIC, A. A review of EEG signal features and their application in driver drowsiness detection systems. **Sensors**, MDPI AG, v. 21, n. 11, p. 3786, 2021. Disponível na Internet: <<https://doi.org/10.3390/s21113786>>.

STOLLNITZ, E.; DEROSE, A.; SALESIN, D. Wavelets for computer graphics: a primer.1. **IEEE Computer Graphics and Applications**, Institute of Electrical and Electronics Engineers (IEEE), v. 15, n. 3, p. 76–84, 1995. Disponível na Internet: <<https://doi.org/10.1109/38.376616>>.

SUN, C.; MOU, C. Survey on the research direction of EEG-based signal processing. **Frontiers in Neuroscience**, Frontiers Media SA, v. 17, jul. 2023. Disponível na Internet: <<https://doi.org/10.3389/fnins.2023.1203059>>.

TARAFDER, S. et al. Drowsiness detection using ocular indices from EEG signal. **Sensors**, MDPI AG, v. 22, n. 13, p. 4764, jun. 2022. Disponível na Internet: <<https://doi.org/10.3390/s22134764>>.

TARAN, S.; BAJAJ, V. Drowsiness detection using instantaneous frequency based rhythms setaration for EEG signals. In: **2018 Conference on Information and Communication Technology (CICT)**. IEEE, 2018. Available from Internet: <<https://doi.org/10.1109/infocomtech.2018.8722429>>.

TEPLAN, M. et al. Fundamentals of eeg measurement. **Measurement science review**, v. 2, n. 2, p. 1–11, 2002.

TRIPATHY, R.; ACHARYA, U. R. Use of features from RR-time series and EEG signals for automated classification of sleep stages in deep neural network framework. **Biocybernetics and Biomedical Engineering**, Elsevier BV, v. 38, n. 4, p. 890–902, 2018. Disponível na Internet: <<https://doi.org/10.1016/j.bbe.2018.05.005>>.

TSAI, P.-Y. et al. A portable device for real time drowsiness detection using novel active dry electrode system. In: **2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society**. IEEE, 2009. Disponível na Internet: <<https://doi.org/10.1109/iembs.2009.5334491>>.

WAN, Z. et al. A review on transfer learning in EEG signal analysis. **Neurocomputing**, Elsevier BV, v. 421, p. 1–14, jan. 2021. Disponível na Internet: <<https://doi.org/10.1016/j.neucom.2020.09.017>>.

WEHRLE, R. et al. Functional microstates within human REM sleep: first evidence from fMRI of a thalamocortical network specific for phasic REM periods. **European Journal of Neuroscience**, Wiley, v. 25, n. 3, p. 863–871, 2007. Disponível na Internet: <<https://doi.org/10.1111/j.1460-9568.2007.05314.x>>.

XIANG, W. et al. Driving fatigue detection based on the combination of multi-branch 3d-CNN and attention mechanism. **Applied Sciences**, MDPI AG, v. 12, n. 9, p. 4689, 2022. Disponível na Internet: <<https://doi.org/10.3390/app12094689>>.

YEO, M. V. et al. Can SVM be used for automatic EEG detection of drowsiness during car driving? **Safety Science**, Elsevier BV, v. 47, n. 1, p. 115–124, jan. 2009. Disponível na Internet: <<https://doi.org/10.1016/j.ssci.2008.01.007>>.

YUAN, H. et al. State of the art of non-invasive electrode materials for brain–computer interface. **Micromachines**, MDPI AG, v. 12, n. 12, p. 1521, 2021. Disponível na Internet: <<https://doi.org/10.3390/mi12121521>>.

ZHU, M. et al. Vehicle driver drowsiness detection method using wearable EEG based on convolution neural network. **Neural Computing and Applications**, Springer Science and Business Media LLC, v. 33, n. 20, p. 13965–13980, 2021. Disponível na Internet: <<https://doi.org/10.1007/s00521-021-06038-y>>.

ZHU, T.; LUO, W.; YU, F. Multi-branch convolutional neural network for automatic sleep stage classification with embedded stage refinement and residual attention channel fusion. **Sensors**, MDPI AG, v. 20, n. 22, p. 6592, nov. 2020. Disponível na Internet: <<https://doi.org/10.3390/s20226592>>.

ZHU, X. et al. EOG-based drowsiness detection using convolutional neural networks. In: **2014 International Joint Conference on Neural Networks (IJCNN)**. IEEE, 2014. Disponível na Internet: <<https://doi.org/10.1109/ijcnn.2014.6889642>>.