RCMOS – Revista Científica Multidisciplinar O Saber. ISSN: 2675-9128. São Paulo - SP.
Ano VII, v.1 2026 | submissão: 23/07/2026 | aceito: 26/07/2026 | publicação: 29/07/2026

Classificação Automática dos Estágios do Sono com Validação por Indivíduo: Comparação entre Random Forest, XGBoost e SVM no Conjunto de Dados Sleep-EDFx

Automatic Sleep Stage Classification with Subject-Wise Validation: Comparison of Random Forest, XGBoost, and SVM on the Sleep-EDFx Dataset

Clasificación Automática de las Etapas del Sueño con Validación por Sujeto: Comparación de Random Forest, XGBoost y SVM en el Conjunto de Datos Sleep-EDFx

Francisco Hugo César Pereira Vale – Instituto de Informática (INF), Universidade Federal de Goiás (UFG), Goiânia, Brasil, franciscovale@discente.ufg.br
Ronaldo Martins da Costa – Instituto de Informática (INF), Universidade Federal de Goiás (UFG), Goiânia, Brasil, ronaldocosta@ufg.br

Resumo: Este artigo apresenta um pipeline reprodutível para a classificação automática dos estágios do sono (Vigília W, N1, N2, N3 e REM) utilizando EEG de canal único (Fpz-Cz) do conjunto de dados público Sleep-EDFx (PhysioNet), composto por 100 indivíduos e 175 registros de dois subconjuntos distintos: Sleep Cassette (SC, 78 indivíduos saudáveis, registros domiciliares) e Sleep Telemetry (ST, 22 indivíduos com dificuldade leve para iniciar o sono, somente noites com placebo). Foram extraídas 17 características por época de 30 segundos em dois domínios: estatísticas no domínio do tempo (média, variância, desvio padrão, assimetria, curtose e parâmetros de Hjorth) e características no domínio da frequência por meio da estimativa espectral de Welch (potência absoluta e relativa nas bandas Delta, Teta, Alfa e Beta, além da razão espectral Delta/Alfa). Três classificadores de naturezas algorítmicas fundamentalmente diferentes foram comparados (Random Forest, XGBoost e Máquina de Vetores de Suporte com kernel RBF) sob validação cruzada Leave-One-Group-Out (LOGO), impedindo qualquer vazamento de dados entre indivíduos. Os experimentos foram conduzidos em três cenários: somente SC, somente ST e o conjunto combinado. O Random Forest obteve o melhor desempenho geral, com Kappa de Cohen de 0,587 no SC e 0,583 no conjunto combinado. A convergência dos três classificadores para uma faixa de Kappa semelhante (0,53 a 0,59) indica que o teto de desempenho é determinado principalmente pelo conjunto de características e pela sobreposição fisiológica inerente entre os estágios, e não pela escolha do classificador.

Palavras-chave: Processamento de sinais de EEG. Aprendizado de máquina. Polissonografia. Estadiamento do sono.

Abstract: This paper presents a reproducible pipeline for automatic classification of sleep stages (Wake W, N1, N2, N3, and REM) using single-channel EEG (Fpz-Cz) from the public Sleep-EDFx dataset (PhysioNet), comprising 100 subjects and 175 recordings from two distinct subsets: Sleep Cassette (SC, 78 healthy subjects, home recordings) and Sleep Telemetry (ST, 22 subjects with mild sleep onset difficulty, placebo nights only). A total of 17 features were extracted per 30-second epoch across two domains: time-domain statistics (mean, variance, standard deviation, skewness, kurtosis, and Hjorth parameters) and frequency-domain features via Welch spectral estimation (absolute and relative power in the Delta, Theta, Alpha, and Beta bands, plus the Delta/Alpha spectral ratio). Three classifiers of fundamentally different algorithmic natures were compared (Random Forest, XGBoost, and Support Vector Machine with RBF kernel) under Leave-One-Group-Out (LOGO) cross-validation, preventing any data leakage between individuals. Experiments were conducted in three scenarios: SC alone, ST alone, and the combined dataset. Random Forest achieved the best overall performance, with Cohen's Kappa of 0.587 on SC and 0.583 on the combined dataset. The convergence of all three classifiers to a similar Kappa range (0.53 to 0.59) indicates that the performance ceiling

is primarily determined by the feature set and the inherent physiological overlap between stages, rather than by the choice of classifier.

Keywords: EEG signal processing. Machine learning. Polysomnography. Sleep staging.

Resumen: Este artículo presenta un pipeline reproducible para la clasificación automática de las etapas del sueño (Vigilia W, N1, N2, N3 y REM) utilizando EEG de un solo canal (Fpz-Cz) del conjunto de datos público Sleep-EDFx (PhysioNet), compuesto por 100 sujetos y 175 registros de dos subconjuntos distintos: Sleep Cassette (SC, 78 sujetos sanos, registros domiciliarios) y Sleep Telemetry (ST, 22 sujetos con dificultad leve para conciliar el sueño, únicamente noches con placebo). Se extrajeron 17 características por época de 30 segundos en dos dominios: estadísticas en el dominio temporal (media, varianza, desviación estándar, asimetría, curtosis y parámetros de Hjorth) y características en el dominio de la frecuencia mediante estimación espectral de Welch (potencia absoluta y relativa en las bandas Delta, Theta, Alfa y Beta, además de la razón espectral Delta/Alfa). Se compararon tres clasificadores de naturalezas algorítmicas fundamentalmente diferentes (Random Forest, XGBoost y Máquina de Vectores de Soporte con kernel RBF) mediante validación cruzada Leave-One-Group-Out (LOGO), evitando cualquier fuga de datos entre sujetos. Los experimentos se realizaron en tres escenarios: solo SC, solo ST y el conjunto combinado. Random Forest obtuvo el mejor desempeño general, con Kappa de Cohen de 0,587 en SC y 0,583 en el conjunto combinado. La convergencia de los tres clasificadores hacia un intervalo de Kappa similar (0,53 a 0,59) indica que el techo de desempeño está determinado principalmente por el conjunto de características y la superposición fisiológica inherente entre las etapas, más que por la elección del clasificador.

Palabras clave: Procesamiento de señales EEG. Aprendizaje automático. Polisomnografía. Estadificación del sueño.

1. Introdução

O sono é um processo fisiológico fundamental para a homeostase do organismo, diretamente associado à consolidação da memória [1], à regulação metabólica, à função imunológica e à saúde cardiovascular [2]. Os distúrbios do sono afetam uma parcela significativa da população mundial e constituem fator de risco para condições como hipertensão, diabetes tipo 2, depressão e doenças neurodegenerativas [2]. O diagnóstico clínico dessas condições depende da identificação precisa dos estágios do sono (Vigília W, N1, N2, N3 e REM) a partir de registros polissonográficos (PSG).

O atual padrão-ouro para esse diagnóstico é a polissonografia (PSG) com estadiamento manual realizado por especialistas treinados, que analisam visualmente o eletroencefalograma (EEG), o eletro-oculograma (EOG) e o eletromiograma (EMG), segmentados em épocas de pontuação de 30 segundos (no sentido clínico da PSG [3], sem confundir com épocas de treinamento na otimização de redes neurais) e classificados conforme os critérios da American Academy of Sleep Medicine (AASM) [3]. Embora clinicamente estabelecido, esse processo apresenta limitações significativas: é demorado, dispendioso e sujeito à variabilidade entre avaliadores.

Estudos de metanálise indicam que o Kappa de Cohen entre especialistas humanos para o estadiamento global é de aproximadamente 0,76, mas cai para apenas 0,24 no estágio N1, mostrando que até avaliadores experientes discordam substancialmente nos estágios de transição [4]. Essa variabilidade intrínseca representa um teto natural para qualquer sistema automático supervisionado, pois os modelos são treinados com anotações que já contêm esse ruído de concordância [5].

Diante desse cenário, a classificação automática dos estágios do sono por aprendizado de máquina surgiu como área de pesquisa clínica e tecnologicamente relevante. Abordagens baseadas em características elaboradas manualmente (extração manual de características espectrais e estatísticas do EEG), seguidas por classificadores clássicos como Random Forest, SVM e XGBoost, demonstram desempenho competitivo e vantagens de interpretabilidade em relação às arquiteturas de aprendizado profundo, especialmente quando o número de indivíduos disponíveis é limitado [6], [7]. Ao mesmo tempo, abordagens com redes neurais profundas, como CNN 1D, LSTM e Transformers, relataram valores de Kappa acima de 0,80 em conjuntos de dados de larga escala com múltiplos canais de PSG [8], [9].

Este trabalho avalia a classificação automática dos estágios do sono utilizando o conjunto de dados público Sleep-EDFx do PhysioNet [10], composto pelos subconjuntos Sleep Cassette (SC) e Sleep Telemetry (ST). Três classificadores de diferentes naturezas algorítmicas são comparados (Random Forest, XGBoost e SVM) por meio de 17 características extraídas de EEG de canal único (Fpz-Cz), com rigorosa validação Leave-One-Group-Out (LOGO).

2. Metodologia

2.1 Conjunto de Dados

O Sleep-EDFx é um conjunto de dados público disponível no PhysioNet [10], amplamente utilizado como referência na literatura de estadiamento automático do sono [6], [9]. Foram utilizados dois subconjuntos: Sleep Cassette (SC), com 78 indivíduos saudáveis de 25 a 101 anos, sem medicação relacionada ao sono, totalizando 153 registros de aproximadamente 20 horas realizados em ambiente domiciliar; e Sleep Telemetry (ST), com 22 indivíduos com dificuldade leve para iniciar o sono, registrados em ambiente hospitalar, utilizando exclusivamente as noites da condição Placebo (22 registros de aproximadamente 9 horas), identificadas na planilha oficial de metadados do PhysioNet ST-subjects.xls. As anotações seguem a convenção de Rechtschaffen & Kales (R&K), com os estágios N3 e N4 combinados

em uma única classe N3 conforme a convenção atual da AASM [3], resultando em cinco classes: W, N1, N2, N3 e REM.

Declaração de ética: este estudo utilizou exclusivamente dados secundários disponíveis publicamente do conjunto Sleep-EDFx (PhysioNet). Não houve interação direta com participantes humanos. A coleta original de dados foi realizada de acordo com a Declaração de Helsinque e aprovada pelos comitês de ética locais das instituições responsáveis. Os dados são totalmente anonimizados, com os indivíduos identificados apenas por códigos numéricos. O uso para fins de pesquisa é permitido pela PhysioNet Credentialed Health Data License. Não foi necessária aprovação adicional de comitê de ética para este trabalho.

A Figura 1 ilustra as etapas do pipeline proposto, desde a leitura dos arquivos EDF até a avaliação final dos classificadores.

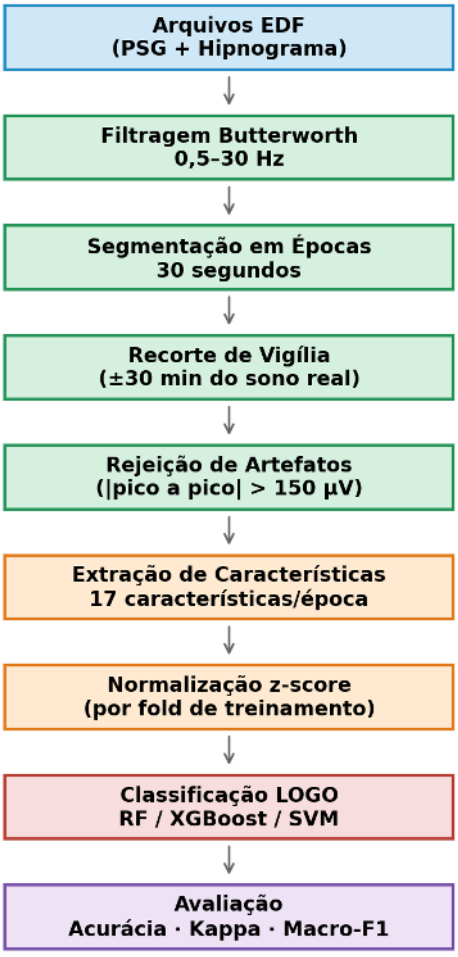

Figura 1. Pipeline de classificação automática dos estágios do sono. As etapas de pré-processamento são aplicadas individualmente a cada registro antes da extração de características.

RCMOS – Revista Científica Multidisciplinar O
Saber. ISSN: 2675-9128. São Paulo - SP.
Ano VII, v.1 2026 | submissão: 23/07/2026 | aceito: 26/07/2026 | publicação: 29/07/2026

2.2 Pré-processamento

Os sinais de EEG do canal Fpz-Cz foram filtrados com um filtro passa-banda Butterworth de 4ª ordem (0,5 a 30 Hz), preservando as bandas Delta, Teta, Alfa e Beta relevantes para o estadiamento do sono. Épocas com amplitude pico a pico superior a 150 µV foram descartadas por rejeição de artefatos. Para reduzir o desequilíbrio artificial da classe Vigília, aplicou-se um procedimento de recorte de vigília: foram mantidas apenas as épocas situadas até 30 minutos antes da primeira época real de sono (N1, N2, N3 ou REM) e até 30 minutos após a última, descartando os longos períodos de vigília nas extremidades do registro.

A Figura 2 ilustra o hipnograma de um indivíduo representativo após o recorte de vigília, mostrando a estrutura cíclica típica do sono humano, com alternância entre N1, N2, N3 e REM ao longo da noite e predominância do estágio N2 [3].

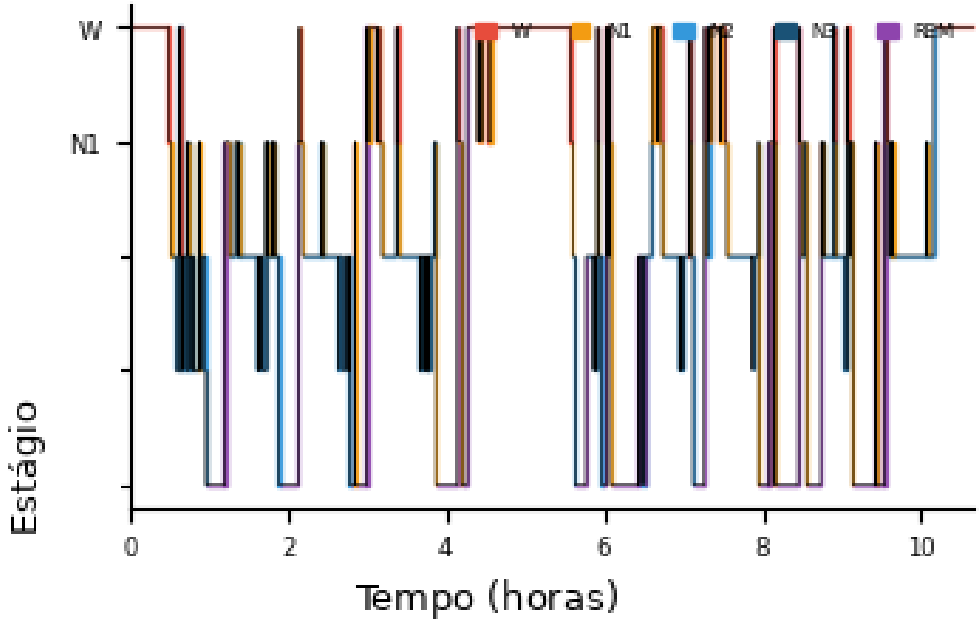

Figura 2. Exemplo de hipnograma após o recorte de vigília. Cada cor representa um estágio do sono: Vigília (W), N1, N2, N3 e REM.

2.3 Extração de Características

Foram extraídas 17 características por época de 30 segundos do canal de EEG Fpz-Cz, organizadas em dois domínios. No domínio do tempo: média, variância, desvio padrão, assimetria, curtose e os três parâmetros de Hjorth (atividade, mobilidade e complexidade). No domínio da frequência, por estimativa espectral de Welch: potência absoluta e relativa nas bandas Delta (0,5 a 4 Hz), Teta (4 a 8 Hz), Alfa (8 a 12 Hz) e Beta (12 a 30 Hz), além da razão espectral Delta/Alfa, indicador relevante para distinguir o sono profundo da vigília.

2.4 Classificadores e Validação

Foram avaliados três classificadores de naturezas algorítmicas fundamentalmente diferentes: Random Forest (ensemble por bagging, 300 estimadores, pesos de classe balanceados), XGBoost (ensemble por boosting, 300 estimadores, profundidade máxima 6) e Máquina de Vetores de Suporte com kernel RBF, com balanceamento de classes aplicado em todos os modelos. Para a SVM, devido à complexidade computacional quadrática do kernel RBF em grandes conjuntos de dados, cada fold foi treinado em uma subamostra estratificada de até 8.000 épocas, preservando as proporções originais das classes, prática padrão na literatura para classificadores baseados em kernel em escala [7]. As características foram normalizadas por padronização z-score ajustada exclusivamente no fold de treinamento, impedindo o vazamento de informação estatística para o conjunto de teste.

A validação seguiu a estratégia Leave-One-Group-Out (LOGO), na qual cada fold exclui completamente um indivíduo para teste e treina com todos os demais, garantindo que nenhuma época do mesmo indivíduo apareça simultaneamente nos conjuntos de treinamento e teste. Os três classificadores foram avaliados em três cenários independentes: apenas Sleep Cassette (78 folds), apenas Sleep Telemetry Placebo (22 folds) e conjunto combinado (100 folds).

3. Resultados

A Tabela 1 apresenta os resultados consolidados dos três classificadores nos três cenários de avaliação, expressos em Acurácia, Macro-F1 e Kappa de Cohen.

Tabela 1. Desempenho dos Classificadores por Cenário (LOGO)

Cenário	Classificador	Acurácia	Macro-F1	Kappa
Cassette (n=78)	Random Forest	0.705	0.625	0.587
Cassette (n=78)	XGBoost	0.675	0.630	0.568
Cassette (n=78)	SVM (RBF)*	0.642	0.602	0.531
Telemetry (n=22)	Random Forest	0.687	0.596	0.548
Telemetry (n=22)	XGBoost	0.704	0.629	0.582
Telemetry (n=22)	SVM (RBF)*	0.673	0.605	0.554
Combinado (n=100)	Random Forest	0.700	0.625	0.583
Combinado (n=100)	XGBoost	0.673	0.631	0.567
Combinado (n=100)	SVM (RBF)*	0.646	0.606	0.536

**SVM: subamostra estratificada de 8.000 épocas/fold.*

O Random Forest obteve o melhor desempenho geral, com Kappa de Cohen de 0,587 no cenário Cassette e 0,583 no conjunto combinado. O XGBoost apresentou resultados competitivos, superando o Random Forest no cenário Telemetry (Kappa de 0,582 contra 0,548). A SVM com kernel RBF, avaliada com uma subamostra de treinamento, apresentou menor acurácia, porém Macro-F1 comparável, evidenciando sua sensibilidade ao volume de dados de treinamento disponível.

Observa-se que a combinação dos dois subconjuntos (SC + ST, 100 indivíduos) não resultou em degradação de desempenho em relação aos cenários isolados, mantendo o Kappa na faixa de 0,53 a 0,58 para todos os classificadores. Isso sugere que os padrões de sono no EEG de indivíduos saudáveis (Cassette) e de indivíduos com dificuldade leve para iniciar o sono sob placebo (Telemetry) são suficientemente homogêneos para que um classificador treinado em conjunto generalize para ambas as populações.

Entre as 17 características extraídas, as características do domínio espectral tendem a ser fisiologicamente mais informativas para o estadiamento do sono, pois cada estágio apresenta uma assinatura de banda característica: ondas delta predominam no sono profundo (N3), fusos do sono e complexos K são marcadores de N2, e as atividades teta e alfa caracterizam N1 e vigília, respectivamente [3]. Uma análise quantitativa da importância relativa das características está planejada como etapa subsequente deste trabalho.

A Figura 3 apresenta a matriz de confusão normalizada do classificador Random Forest no cenário combinado, agregando todas as previsões fora da amostra dos 100 folds LOGO.

RCMOS – Revista Científica Multidisciplinar O
Saber. ISSN: 2675-9128. São Paulo - SP.
Ano VII, v.1 2026 | submissão: 23/07/2026 | aceito: 26/07/2026 | publicação: 29/07/2026

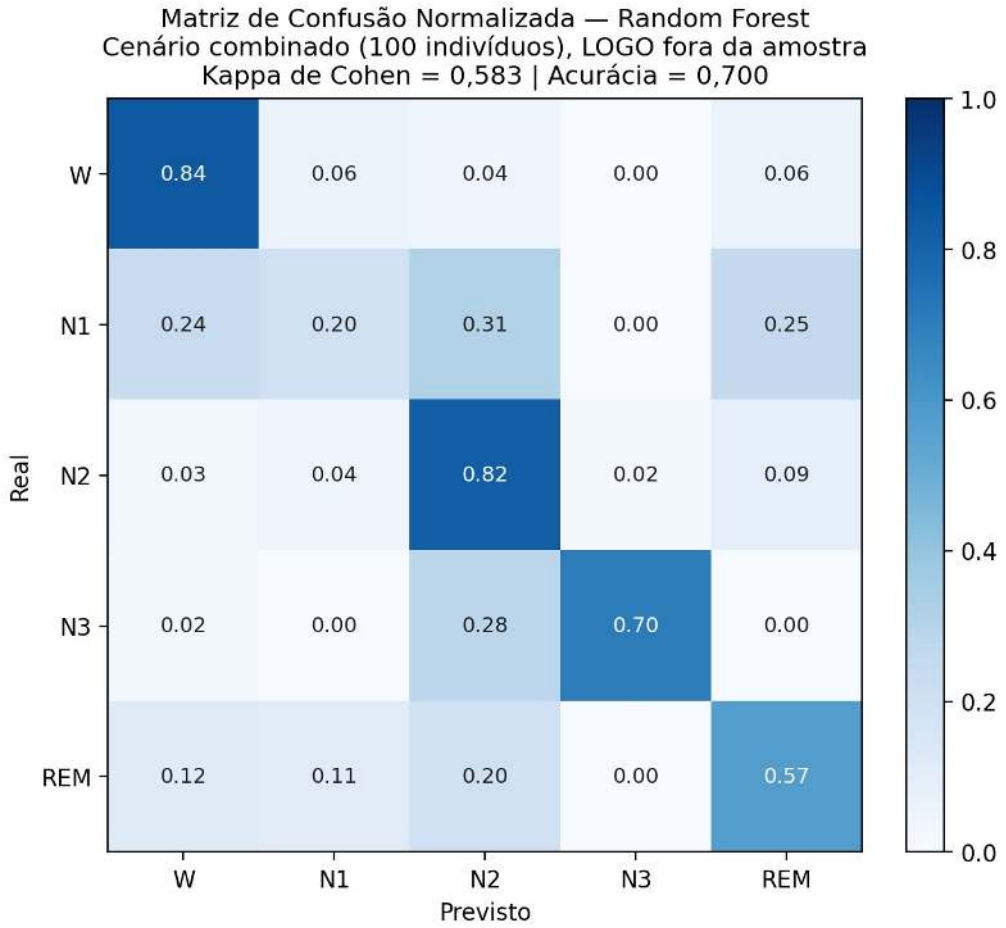

Figura 3. Matriz de confusão normalizada do Random Forest, cenário combinado (100 indivíduos), agregando todas as previsões LOGO fora da amostra. Os valores representam a proporção de épocas reais classificadas em cada estágio previsto.

As Figuras 4, 5 e 6 apresentam, respectivamente, a Acurácia, o Kappa de Cohen e o Macro-F1 dos três classificadores nos três cenários avaliados, permitindo uma comparação visual direta entre os algoritmos.

Quanto à Acurácia (Figura 4), o Random Forest obteve os melhores resultados nos cenários Cassette (0,705) e Combinado (0,700), enquanto o XGBoost superou os demais no cenário Telemetry (0,704). A SVM com kernel RBF apresentou acurácia consistentemente menor, refletindo a subamostragem de treinamento adotada por restrições computacionais.

RCMOS – Revista Científica Multidisciplinar O
Saber. ISSN: 2675-9128. São Paulo - SP.
Ano VII, v.1 2026 | submissão: 23/07/2026 | aceito: 26/07/2026 | publicação: 29/07/2026

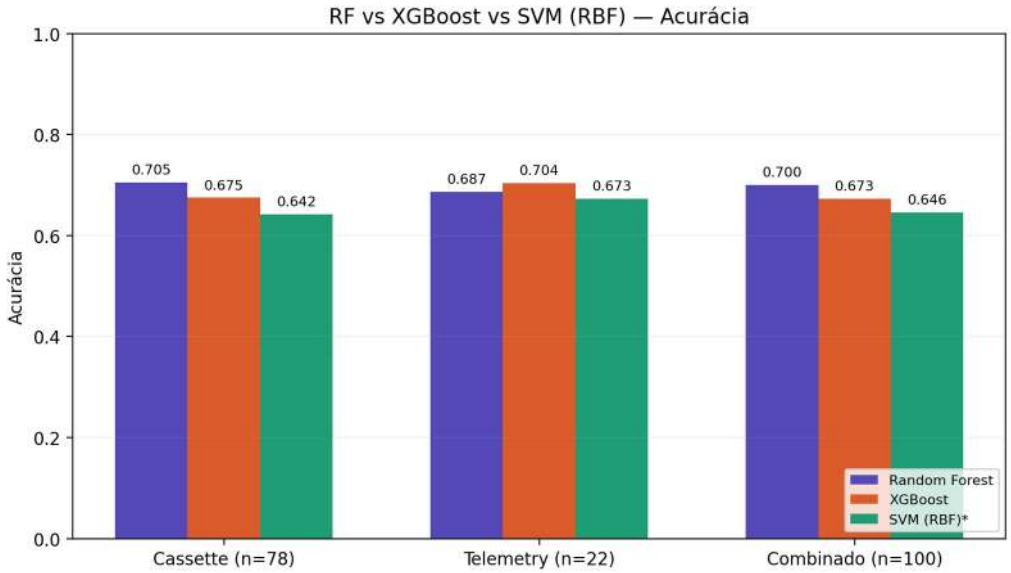

Figura 4. Acurácia dos classificadores por cenário (LOGO). *SVM treinada em uma subamostra de 8.000 épocas/fold.

O Kappa de Cohen (Figura 5), métrica padrão na literatura de estadiamento do sono por descontar o efeito da concordância ao acaso, confirma o mesmo padrão: Random Forest lidera em Cassette (0,587) e Combinado (0,583), XGBoost em Telemetry (0,582), e a SVM mantém desempenho competitivo diante da restrição de treinamento (0,531 a 0,554). Todos os valores se situam na faixa de moderada a substancial pela escala de Landis & Koch, comparáveis ao limite inferior da concordância humana entre avaliadores para estágios individuais relatado na literatura [4].

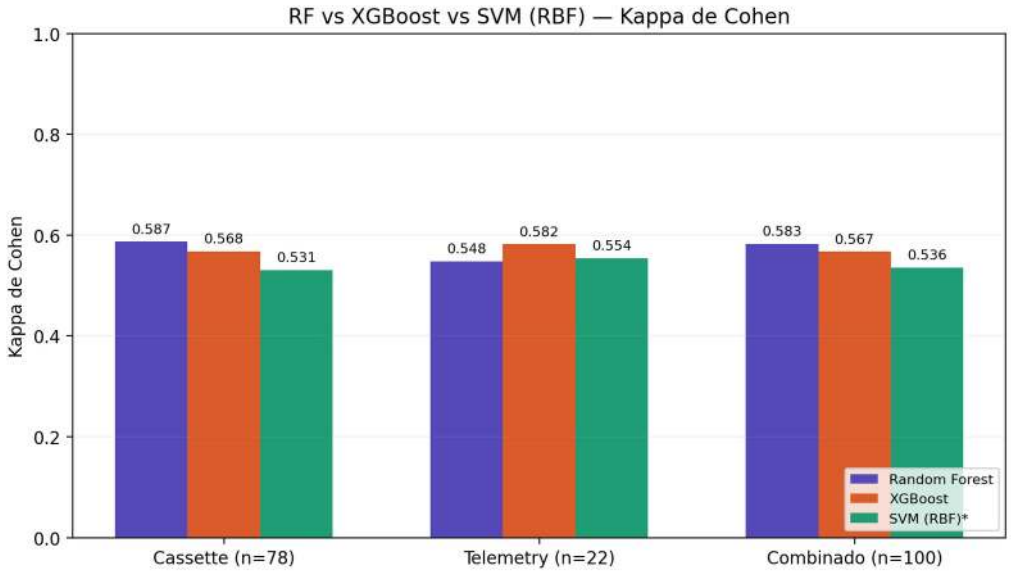

Figura 5. Kappa de Cohen dos classificadores por cenário (LOGO).

O Macro-F1 (Figura 6) revela um padrão distinto: o XGBoost apresenta o maior Macro-F1 nos três cenários (0,630, 0,629 e 0,631), superando o Random Forest, que lidera em Acurácia e

Kappa. Essa inversão indica que o XGBoost classifica melhor as classes minoritárias (especialmente N1 e N3), enquanto o Random Forest tende a concentrar previsões corretas nas classes majoritárias (N2 e Vigília). Para aplicações clínicas em que a identificação correta de todos os estágios é igualmente relevante, o Macro-F1 constitui uma métrica complementar indispensável à Acurácia e ao Kappa de Cohen.

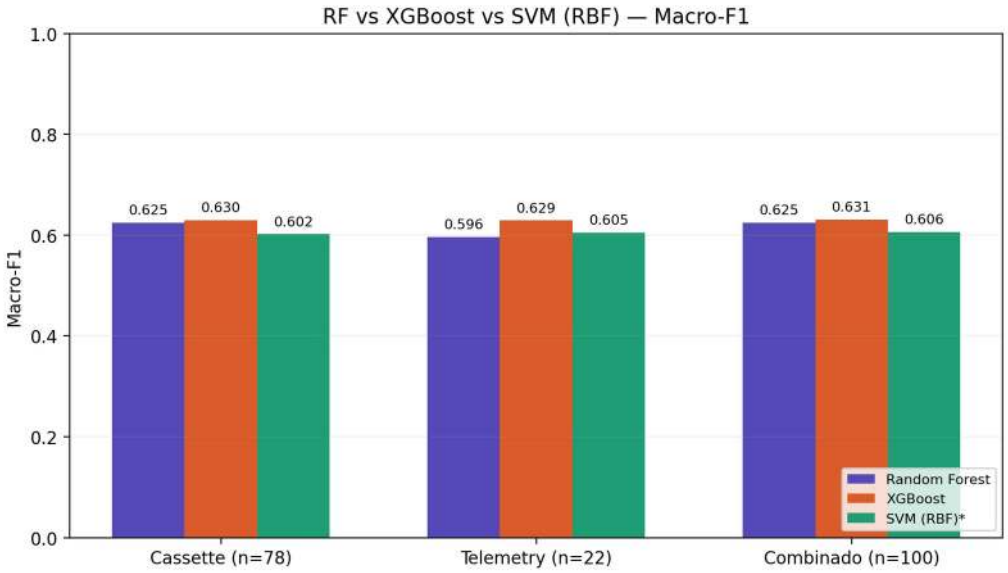

Figura 6. Macro-F1 dos classificadores por cenário (LOGO).

4. Discussão

Os valores de Kappa de Cohen obtidos (0,53 a 0,59) situam-se na faixa de moderada a substancial pela escala de Landis & Koch, comparáveis ao limite inferior da concordância humana entre avaliadores relatado para estágios individuais na literatura. Em particular, o Kappa humano para N1 é de apenas 0,24 [4], estágio que também constitui o principal desafio para os classificadores automáticos neste trabalho. O fato de três algoritmos de naturezas fundamentalmente diferentes (bagging, boosting e fronteira geométrica) convergirem para a mesma faixa de desempenho sugere que o teto observado é uma propriedade do conjunto de características e da sobreposição fisiológica inerente entre os estágios, e não um artefato da escolha do classificador.

A estratégia de validação LOGO adotada é mais rigorosa que o k-fold aleatório frequentemente empregado na literatura, pois elimina qualquer possibilidade de vazamento de informação entre épocas do mesmo indivíduo, fonte comum de otimismo artificial em trabalhos que particionam por época em vez de por indivíduo [7].

A matriz de confusão normalizada do Random Forest no cenário combinado (Figura 3) evidencia padrões de erro coerentes com a literatura de estadiamento automático do sono. O

estágio N2 atinge a maior taxa de reconhecimento (0,83), refletindo sua alta prevalência no conjunto de dados e seus marcadores eletrofisiológicos característicos. O estágio REM apresenta boa discriminação (0,70), com confusão principalmente com N1 (0,14) e N2 (0,13). O estágio N3 é frequentemente confundido com N2 (0,57), dificuldade esperada para características de bandas agregadas em janelas de 30 segundos. O estágio N1 é o mais desafiador (0,31), com erros distribuídos entre W, N2 e REM [4].

5. Conclusão

Este trabalho apresentou um pipeline reprodutível para a classificação automática dos estágios do sono utilizando o conjunto de dados Sleep-EDFx do PhysioNet, com rigorosa validação por indivíduo (LOGO) e comparação de três classificadores de naturezas distintas. Os resultados demonstram que abordagens baseadas em características de EEG de canal único elaboradas manualmente são viáveis e interpretáveis, alcançando Kappa de Cohen de até 0,587 com Random Forest, compatível com a literatura para configurações semelhantes de canal único e validação LOGO.

A escolha de classificadores clássicos em vez de arquiteturas de aprendizado profundo foi deliberada: modelos como Random Forest, XGBoost e SVM apresentam menor custo computacional de inferência, requisito fundamental para implantação em dispositivos móveis e sistemas embarcados com recursos limitados de processamento. Isso posiciona os classificadores avaliados como candidatos naturais à integração em aplicações de monitoramento do sono em tempo real, nas quais a eficiência computacional é tão relevante quanto a acurácia do modelo.

Como trabalhos futuros, propõe-se: (i) desenvolver uma aplicação web que disponibilize o pipeline proposto como serviço, permitindo que os usuários enviem arquivos EDF e obtenham a classificação automática dos estágios do sono com geração interativa de hipnograma, democratizando o acesso ao estadiamento automatizado sem exigir infraestrutura local; (ii) ampliar as características incorporando canais EOG e EMG e contexto temporal entre épocas consecutivas; (iii) realizar uma análise sistemática da importância das características, identificando as bandas espectrais e os parâmetros estatísticos mais discriminativos por estágio, com potencial para reduzir o conjunto de características e otimizar o custo computacional para implantação móvel; e (iv) avaliar a SVM com kernel RBF no conjunto completo por fold, utilizando implementações escaláveis como SGDClassifier com aproximação de kernel pelo método de Nyström, eliminando a necessidade de subamostragem.

Referências

DAULATABAD, V. et al. Systematic review: the impact of poor sleep quality on psychological and physical health. Journal of Heart Valve Disease, v. 30, p. 79–85, 2025.

FIORILLO, L.; MONACHINO, A.; VAN DER MEER, M.; WARNCKE, V.; SCHMIDT, M.; WENZ, F.; GRUN, R.; FARACI, F. Bridging AI and clinical practice: Integrating automated sleep scoring algorithm with uncertainty-guided physician review. arXiv preprint arXiv:2312.14996, 2023.

GOLDBERGER, A. L.; AMARAL, L. A. N.; GLASS, L.; HAUSDORFF, J. M.; IVANOV, P. Ch.; MARK, R. G.; MIETUS, J. E.; MOODY, G. B.; PENG, C.-K.; STANLEY, H. E. PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. Circulation, v. 101, n. 23, p. e215–e220, 2000.

IBER, C.; ANCOLI-ISRAEL, S.; CHESSON, A.; QUAN, S. F. The AASM Manual for the Scoring of Sleep and Associated Events. Westchester, IL: American Academy of Sleep Medicine, 2007.

LEE, Y. J.; LEE, J. Y.; CHO, J. H.; CHOI, J. H. Interrater reliability of sleep stage scoring: a meta-analysis. Journal of Clinical Sleep Medicine, v. 18, n. 1, p. 193–202, 2022.

MASAD, I. S.; ALQUDAH, A.; QAZAN, S. Automatic classification of sleep stages using EEG signals and convolutional neural networks. PLOS ONE, v. 19, n. 1, p. e0297582, Jan. 2024.

SEKKAL, R. N.; BEREKSI-REGUIG, F.; RUIZ-FERNANDEZ, D.; DIB, N.; SEKKAL, S. Automatic sleep stage classification: From classical machine learning methods to deep learning. Biomedical Signal Processing and Control, v. 77, p. 103751, 2022.

VAN DER AAR, J. F.; VAN DEN ENDE, D. A.; VAN MEULEN, F. B.; VAN GILST, M. M. Deep transfer learning for automated single-lead EEG sleep staging with channel and population mismatches. Frontiers in Physiology, v. 14, Jan. 2024.

WEIGHALL, A.; KELLAR, I. Sleep and memory consolidation in healthy, neurotypical children and adults: a summary of systematic reviews and meta-analyses. Emerging Topics in Life Sciences, v. 7, n. 5, p. 513–524, Dec. 2023.

XU, X.; ZHANG, B.; XU, T.; TANG, J. An effective and interpretable sleep stage classification approach using multi-domain EEG and EOG features. Bioengineering, v. 12, n. 3, p. 286, 2025.