

Identificação da Doença de Parkinson através da Análise de Dados Coletados por Smartwatch

Rafael Alves Padilha¹, Pedro Lemes Sixel Lobo¹,
Rogerio Salvini¹, Fabrizzio Soares¹, Juliana Felix^{1,2}

¹Instituto de Informática, Universidade Federal de Goiás (UFG)

² Escola Politécnica e de Artes, Pontifícia Universidade Católica de Goiás (PUC-Goiás)

{rafaelpadilha, pedro.lemes}@discente.ufg.br
{rogeriosalvini, fabrizzio, julianafelix}@ufg.br

Abstract. *Parkinson's disease (PD) is a neurodegenerative disease that is difficult to diagnose early and causes progressive neuronal degeneration, leading to changes in gait and movement. Computational diagnostic methods based on machine learning offer a potential solution to this problem. This paper reports the main results obtained by investigating the use of harmonic features extracted from movement signals and classical supervised machine learning algorithms for the classification of Parkinson's disease. The results highlight the potential of machine learning algorithms to assist in this purpose.*

Resumo. *A doença de Parkinson (DP) é uma doença neurodegenerativa de difícil diagnóstico precoce que causa degeneração progressiva dos neurônios, provocando alterações na marcha e movimentos. Métodos diagnósticos computacionais baseados em aprendizado de máquina são uma possível solução para essa problemática. Este trabalho reporta os principais resultados obtidos investigando o uso de características harmônicas extraídas de sinais de movimento e de algoritmos clássicos de aprendizado de máquina supervisionado para a classificação da Doença de Parkinson. Os resultados evidenciam o potencial de algoritmos de aprendizado de máquina para auxiliar nesse propósito.*

1. Introdução

A doença de Parkinson (DP) é um distúrbio neurodegenerativo caracterizado pela degeneração progressiva da função motora, afetando principalmente adultos com mais de cinquenta anos de idade. Os pacientes com Parkinson apresentam perda anormal de células nervosas dopaminérgicas na substância negra do cérebro, responsáveis pela síntese de dopamina e controle de movimento, desencadeando sintomas motores como tremor de repouso, rigidez, e instabilidade postural [Zhou et al. 2023]. As doenças neurodegenerativas, categoria que inclui a DP e outras doenças como Esclerose Lateral Amiotrófica (ELA) e a Doença de Huntington, são caracterizadas pela degeneração progressiva dos neurônios, manifestando sintomas que incluem movimentos involuntários, fraqueza muscular, marcha instável e, frequentemente, sintomas não-motores como alterações cognitivas e do sono [Bloem et al. 2021].

O processo diagnóstico usual para a Doença de Parkinson, baseado na progressão clínica dos sintomas, é caro, impreciso e demorado. Isso é um desafio, uma vez que ocasiona no seu reconhecimento tardio, reforçando a importância de explorar métodos alternativos para identificação da doença. Considerando que os sintomas motores estão entre as primeiras manifestações da DP, vários estudos exploram o uso de aprendizado de máquina

combinado com análise de sinais motores para dar suporte ao seu diagnóstico. Por exemplo, abordagens que utilizam redes LSTM com dados de marcha demonstraram potencial para distinguir entre diferentes doenças neurodegenerativas, aproveitando a capacidade dessas redes de modelar sequências temporais [Ordóñez and Roggen 2016]. Além disso, modelos mais recentes exploram arquiteturas baseadas em *Transformer Encoder* para detectar sintomas como congelamento da marcha [Hasan 2025]. Por fim, trabalhos de revisão apontam que algoritmos clássicos como *Support Vector Machines* (SVM) são amplamente aplicados ao problema, e métodos mais recentes, como modelos baseados em redes neurais e *ensembles*, também têm mostrado bons resultados [Ali et al. 2021].

Com o avanço da tecnologia em sensores portáteis de baixo custo, como os sensores de *smartwatch*, facilitou-se a coleta de dados motores para monitorar e analisar sintomas em pacientes, permitindo que a marcha e outros movimentos sejam capturados em dados numéricos com maior facilidade. Assim, o uso desses dispositivos de baixo custo atrelados à métodos de aprendizado de máquina fornece uma solução acessível, não invasiva e escalável para diagnóstico da DP.

Este trabalho reporta os principais resultados obtidos durante uma série de experimentos que tinham por objetivo avaliar a capacidade preditiva de características harmônicas [Pietrosanti et al. 2023], aliadas a dados de movimentos obtidos por sensores de *smartwatch*, para classificar a Doença de Parkinson (DP) em contraste a controles saudáveis (CO) e diagnósticos diferenciais (DD). Para tal fim, foram empregadas três tarefas de classificação binárias (DP vs CO, DP vs DD e DD vs CO), utilizando algoritmos de aprendizado de máquina incluindo SVM, *Extra Trees*, *LightGBM* e *XGBoost*.

O restante deste artigo está organizado da seguinte forma: a Seção 2 descreve a metodologia utilizada, detalhando a base de dados, o pré-processamento dos dados, a extração de características harmônicas e os algoritmos de classificação implementados; a Seção 3 apresenta os resultados obtidos e uma discussão sobre eles; por fim, a Seção 4 discorre sobre as conclusões e perspectivas futuras da pesquisa.

2. Materiais e Métodos

A Figura 1 fornece uma visão geral da metodologia discutida neste documento. As subseções seguintes detalham tais etapas.




Figura 1. Fluxograma da metodologia utilizada neste trabalho.

2.1. Base de Dados

A base de dados utilizada neste estudo é o *PADS - Parkinson's Disease Smartwatch dataset* [Varghese et al. 2024], desenvolvida como parte de um estudo transversal conduzido entre 2018 e 2021, com o objetivo de explorar biomarcadores digitais para a doença de Parkinson. A pesquisa foi realizada na Clínica de Distúrbios do Movimento do Hospital Universitário de *Münster*, Alemanha, utilizando um sistema especializado que integrou dispositivos móveis inteligentes para capturar avaliações neurológicas interativas.

O conjunto de dados é composto por 469 participantes categorizados em três grupos principais: 276 pacientes com doença de Parkinson (DP), 79 controles saudáveis (HC)

e 114 indivíduos com diagnósticos diferenciais (DD), incluindo tremor essencial, parkinsonismo atípico como paralisia supranuclear progressiva (PSP) ou atrofia de múltiplos sistemas (MSA), causas secundárias de parkinsonismo e esclerose múltipla. Todos os diagnósticos foram estabelecidos por neurologistas certificados.

A coleta de dados ocorreu em duas fases principais. Primeiramente, os participantes preencheram um questionário eletrônico, fornecendo detalhes como idade, altura, peso, gênero, histórico familiar de DP e o impacto do álcool nos tremores. Em seguida, os participantes realizaram 11 tarefas de movimento, cada uma durando entre 10 e 20 segundos, enquanto permaneciam sentados e usando um *Apple Watch Series 4* em cada um dos pulsos esquerdo e direito.

Durante essas tarefas, os sensores dos *smartwatches* registraram dados de aceleração e rotação em uma frequência de 100 Hz. Para análise, as tarefas de levantar e segurar os braços, apontar com o dedo e tocar os indicadores foram excluídas por contribuírem minimamente para a classificação [Varghese et al. 2024]. As tarefas de movimento restantes estão detalhadas na Tabela 1.

Tabela 1. Descrição das tarefas realizadas durante a coleta de dados.

Tarefa	Duração (s)	Descrição
1	20	Repouso com olhos fechados enquanto sentado, posicionamento padronizado
2	20	Repouso enquanto o paciente está calculando séries de sete
3	10	Levantar e estender os braços
4	10	Segurar peso de um quilograma em cada mão por 5 segundos
5	10	Beber de um copo. Pegar um copo vazio como se estivesse bebendo. Começar com a mão direita, depois repetir com a esquerda
6	10	Cruzar e estender ambos os braços
7	10	Tocar o próprio nariz com o dedo indicador. Começar com a direita, depois com o indicador esquerdo. Em seguida estender os braços
8	20	Sincronia. O examinador bate o pé no chão, paciente imita o ritmo. Repetir com o pé esquerdo

A Figura 2 apresenta exemplos de dados de rotação do pulso esquerdo para as tarefas de levantar e estender os braços (*StretchHold*) e cruzar os braços (*CrossArms*) realizadas por indivíduos com doença de Parkinson (DP), diagnóstico diferencial (DD) e controle saudável (CO). Estes gráficos ilustram os dados de movimento pré-processados disponíveis no conjunto de dados, demonstrando as diferenças características nos padrões de movimento entre os três grupos.

Além dos dados de movimento, cada participante completou um questionário abrangente de sintomas não-motores da doença de Parkinson denominado PDNMS, baseado no questionário da Sociedade Internacional de Parkinson e Distúrbios do Movimento. Este questionário compreende 30 questões de sim/não cobrindo um amplo espectro de domínios, incluindo problemas cognitivos como alucinações, depressão, apatia e ansiedade, disfunção sexual, distúrbios do sono e problemas intestinais.

2.2. Pré-processamento

Os dados foram processados utilizando um *script Python* fornecido no artigo associado à base de dados [Varghese et al. 2024]. As séries temporais de aceleração foram ajustadas

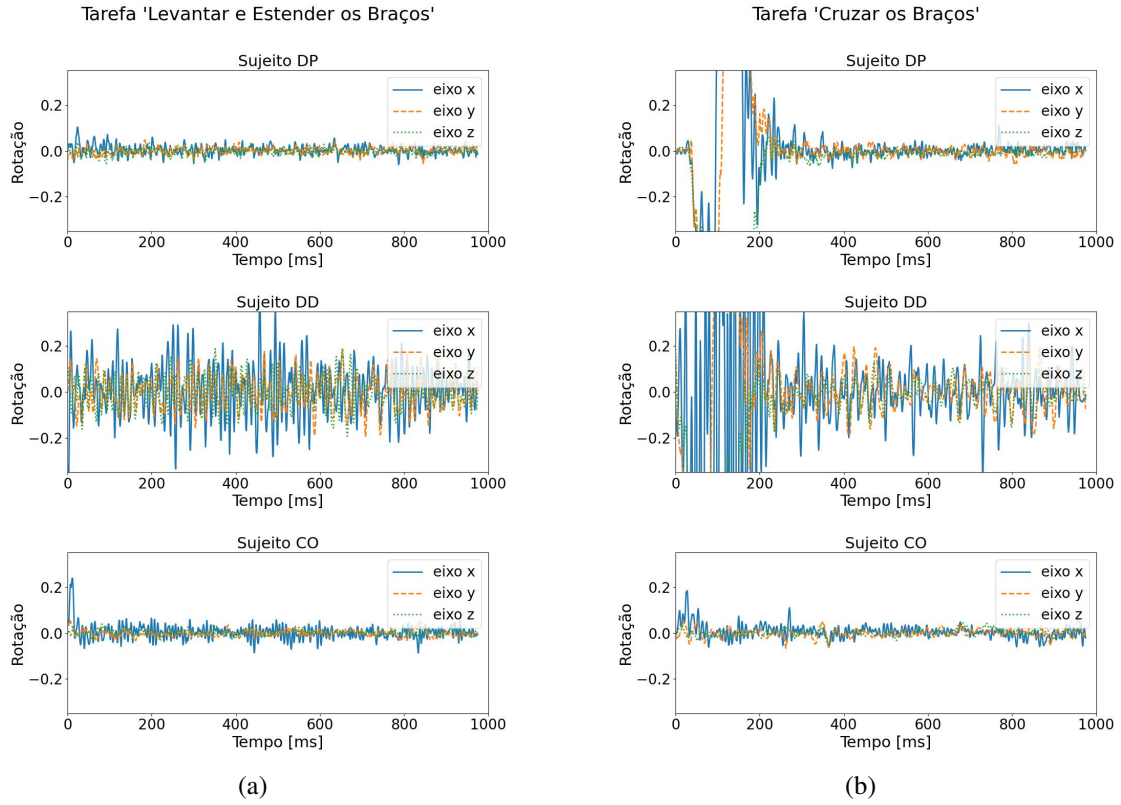


Figura 2. Dados de rotação do pulso esquerdo para as tarefas *StretchHold* (a) e *CrossArms* (b) realizadas por indivíduos com doença de Parkinson (DP), diagnóstico diferencial (DD) e controle saudável (CO).

para considerar a influência da gravidade, e o primeiro meio segundo de cada série temporal foi removido, para eliminar os efeitos do motor vibratório utilizado para notificar os participantes sobre o início do teste. Os dados processados resultantes foram salvos no formato *.bin* e indexados por meio de uma planilha *.csv* correspondente.

Na fase subsequente de pré-processamento de dados, foi aplicada a normalização *Z-score* das características à saída do *script* de pré-processamento, onde essas foram transformadas de forma que a nova distribuição tenha média zero e desvio padrão um, tornando-as comparáveis em uma escala comum. A fórmula utilizada para esse fim está explicitada na Equação 1, onde x , μ e σ são o valor, a média e o desvio padrão originais, respectivamente, e z é o valor normalizado.

$$z = \frac{x - \mu}{\sigma} \quad (1)$$

Essa etapa de normalização é essencial para muitos algoritmos de aprendizado de máquina, pois assegura que todas as características contribuam igualmente para o modelo, evitando que aquelas com magnitudes maiores dominem as de magnitudes menores. Ao padronizar os dados, o algoritmo pode convergir mais rapidamente e alcançar resultados de classificação mais confiáveis.

2.3. Extração de Características

Neste estudo, utilizamos características harmônicas, que previamente levaram a resultados significativos para identificação da Doença de Parkinson através de análise de dados de movimento dos membros superiores [Pietrosanti et al. 2023]. Aqui, exploramos a capacidade preditiva das características harmônicas sob o ponto de vista da análise de dados obtidos através de outras atividades motoras, também provenientes do membro superior.

Um total de oito características harmônicas foram extraídas de cada sinal temporal. Essas características foram calculadas utilizando a Transformada Rápida de Fourier (*Fast Fourier Transform* – FFT), um algoritmo matemático que converte sinais no domínio do tempo para suas representações no domínio da frequência [van Dronghen 2007], permitindo uma análise detalhada das propriedades harmônicas do movimento capturado pelo sensor giroscópio. As características extraídas são:

- **Hamp1** – amplitude máxima da frequência fundamental do sinal, correspondente ao primeiro harmônico no espectro.
- **Hamp2 e Hamp3** – métricas que indicam as amplitudes máximas do segundo e terceiro harmônicos, respectivamente.
- **Freq** – descreve a frequência dominante do sinal, diretamente associada ao ciclo primário do movimento registrado.
- **HD2 e HD3** – métricas harmônicas calculadas como as razões entre as amplitudes do segundo e terceiro harmônicos e a amplitude da frequência fundamental, fornecendo uma medida relativa dos componentes harmônicos.
- **Distorção Harmônica Total (THD)** – obtida pela normalização da soma das amplitudes dos harmônicos de ordem superior pela amplitude da frequência fundamental. Essa métrica avalia a complexidade do sinal considerando harmônicos até a sétima ordem.
- **Asym** – métrica de assimetria angular entre os dois braços, que compara as amplitudes máximas da frequência fundamental (Hamp1) entre os lados esquerdo e direito. Essa métrica identifica diferenças de comportamento entre ambos os lados do corpo, sendo particularmente relevante em estudos sobre equilíbrio, controle motor e recuperação funcional em contextos clínicos.

O cálculo dessas características é realizado para cada série temporal, considerando diferentes combinações de tarefas, sensores, punhos e eixos. No total, há 11 segmentos de tarefas, derivados de 8 tarefas distintas, sendo que 3 delas são divididas em duas séries temporais separadas de 10 segundos. Essas combinações envolvem um sensor giroscópio, dois punhos (esquerdo e direito) e três eixos analisados (X, Y, Z), resultando em 66 séries temporais ($11 \text{ tarefas} \times 1 \text{ sensor} \times 2 \text{ punhos} \times 3 \text{ eixos}$).

De cada série temporal, são extraídas sete características principais: Hamp1, Hamp2, Hamp3, Freq, HD2, HD3 e THD. Considerando as 66 séries temporais, isso resulta em 462 combinações de características. Nos casos em que há medições bilaterais (esquerdo e direito), uma métrica de assimetria (*Asym*) também é incluída para Hamp1. Isso adiciona 33 características adicionais, correspondentes aos 11 segmentos de tarefas medidos em três eixos. Consequentemente, o número total de características extraídas por sujeito é proporcional ao número de séries temporais disponíveis, resultando em cada sujeito sendo representado por 495 características.

2.4. Classificação e Avaliação

Para as tarefas de classificação, foram empregados quatro classificadores: *Support Vector Machine* (SVM) com núcleo linear e três modelos baseados em ensembles de árvores –

Extra Trees, *LightGBM* e *XGBoost* –, todos em suas configurações padrão, explicitadas na Tabela 2.

Tabela 2. Parâmetros utilizados nos classificadores empregados.

Classificador	Parâmetros
SVM	C=1.0, kernel=linear, degree=3, gamma=scale, coef0=0.0, shrinking=True, probability=False, tol=1e-3, cache_size=200, verbose=False, max_iter=-1, decision_function_shape=ovr, break_ties=False
Extra Trees	n_estimators=100, criterion=gini, min_samples_split=2, min_samples_leaf=1, min_weight_fraction_leaf=0.0, max_features=sqrt, bootstrap=False
LightGBM	boosting_type=gbdt, num_leaves=31, max_depth=-1, learning_rate=0.1, n_estimators=100, subsample=1.0, colsample_bytree=1.0, reg_alpha=0.0, reg_lambda=0.0
XGBoost	objective=binary:logistic, booster=gbtree, n_estimators=100, max_depth=6, learning_rate=0.3, subsample=1.0, colsample_bytree=1.0, reg_alpha=0.0, reg_lambda=1.0, gamma=0.0

O processo de avaliação foi realizado por meio de uma abordagem de validação cruzada estratificada com 5 dobras (*5-fold cross-validation*). Esse método consiste em dividir o conjunto de dados em “dobras” (ou *folds*), e subsequentemente separar uma dobra para avaliação (teste) e as demais para a geração dos modelos (treinamento). Esse processo é repetido diversas vezes (no nosso caso, 5 vezes), onde a cada iteração uma dobra é usada como teste e as demais para treinamento. Os resultados são reportados fazendo-se a média das dobras de teste. No processo de validação cruzada estratificada a distribuição original de classes é mantida a cada dobra, o que é importante em conjuntos de dados com distribuições desbalanceadas. Essa abordagem proporciona uma estimativa mais confiável do desempenho do modelo em todas as classes, reduzindo possíveis vieses associados à representação desigual das classes nos conjuntos de validação [Prusty et al. 2022].

As métricas de avaliação utilizadas para avaliação dos modelos foram:

- **Acurácia** – a proporção de classificações corretas em relação ao total de amostras.
- **Acurácia balanceada** – a média das taxas de acerto em cada classe (especialmente útil quando há desbalanceamento entre classes).
- **Precisão** – quantifica a proporção de exemplos classificados como positivos que de fato pertencem à classe positiva.
- **Recall** – mede a proporção de exemplos positivos corretamente identificados pelo modelo.
- **F1-score** – a média harmônica entre precisão e recall.

Essas métricas foram empregadas para avaliar todos os classificadores de acordo com três distintas tarefas de classificação, descritas a seguir:

- **DP vs. CO** – Doença de Parkinson vs. Controle
- **DP vs. DD** – Doença de Parkinson vs. Diagnóstico Diferencial.

- **DD vs. CO** – Diagnóstico Diferencial vs. Controle.

Os resultados reportados correspondem à média de 30 execuções com diferentes sementes (*seeds*) aleatórias, sendo que cada execução representa a média das métricas ao longo dos cinco *folds*, proporcionando uma avaliação confiável e abrangente do desempenho dos classificadores.

3. Resultados e Discussão

A Tabela 3 apresenta os resultados numéricos obtidos nos experimentos em todos os três cenários de classificação, conforme a metodologia descrita na seção anterior. Cada item na tabela representa a média de trinta execuções e o seu desvio padrão.

Tabela 3. Resultados médios de classificação para as tarefas analisadas.

Modelo	Acurácia (%)	Acurácia Balanceada (%)	F1-score (%)	Precisão (%)	Recall (%)
DP vs CO					
SVM	78,42 ± 1,11	51,54 ± 2,04	46,76 ± 3,94	59,64 ± 24,86	51,54 ± 2,04
ExtraTrees	80,30 ± 2,07	56,78 ± 4,11	56,20 ± 6,45	80,74 ± 14,26	56,78 ± 4,11
LightGBM	84,05 ± 3,16	68,33 ± 6,08	71,14 ± 6,98	81,60 ± 7,27	68,33 ± 6,08
XGBoost	81,94 ± 3,21	64,56 ± 5,81	66,71 ± 6,96	76,99 ± 8,38	64,56 ± 5,81
DP vs DD					
SVM	73,45 ± 1,58	55,01 ± 2,30	51,38 ± 4,02	80,80 ± 10,41	55,01 ± 2,30
ExtraTrees	73,77 ± 2,94	57,65 ± 3,82	56,51 ± 5,44	72,90 ± 10,61	57,65 ± 3,82
LightGBM	73,52 ± 3,70	60,26 ± 4,88	60,57 ± 6,01	68,17 ± 7,96	60,26 ± 4,88
XGBoost	73,03 ± 3,49	60,05 ± 4,47	60,34 ± 5,46	67,34 ± 7,45	60,05 ± 4,47
DD vs CO					
SVM	73,21 ± 5,94	71,01 ± 6,44	71,17 ± 6,63	73,21 ± 6,75	71,01 ± 6,44
ExtraTrees	74,64 ± 5,84	73,43 ± 6,16	73,39 ± 6,25	74,40 ± 6,35	73,43 ± 6,16
LightGBM	72,84 ± 6,62	71,65 ± 6,89	71,60 ± 6,95	72,40 ± 7,09	71,65 ± 6,89
XGBoost	73,17 ± 6,71	72,01 ± 6,77	71,95 ± 6,88	72,89 ± 7,06	72,01 ± 6,77

No primeiro cenário, envolvendo os grupos DP e CO, o algoritmo baseado em árvores *LightGBM* demonstrou um desempenho superior aos demais classificadores, alcançando a maior acurácia ($84,05 \pm 3,16$). Além disso, as demais métricas indicam que este modelo apresenta o menor viés entre os testados, uma vez que obteve a pontuação mais alta em todas elas. No segundo cenário (DP vs. DD), todos os modelos apresentaram desempenhos semelhantes, com acurácia em torno de 73%. Os dois últimos modelos testados (*LightGBM* e *XGBoost*) obtiveram os resultados mais equilibrados, enquanto o classificador SVM destacou-se por atingir a maior precisão ($80,80 \pm 10,41$). No terceiro e último cenário, comparando DD e CO, os modelos novamente apresentaram desempenhos similares. No entanto, o classificador *ExtraTrees* superou os demais em todas as métricas por alguns pontos percentuais e obteve os resultados mais expressivos entre todos os cenários nas medidas de acurácia balanceada e *F1-score*.

O trabalho original de aplicação de métodos de aprendizado de máquina na base de dados PADS representa o único estudo disponível na literatura até o momento que a utiliza[Varghese et al. 2024]. O pipeline de aprendizado de máquina nesse estudo incluiu

três abordagens para dados dos *smartwatches*: características definidas manualmente com ML clássico, extração automática de características via processamento de sinais clássico (algoritmo BOSS) e extração via aprendizado profundo (*XceptionTime*), além de um classificador baseado em árvore de decisão (*CatBoost*) para dados de questionários. Utilizando validação cruzada aninhada e empilhamento de classificadores, os autores reportaram acurácia balanceada de 91,16% para DP vs. CO e 72,42% para DP vs. DD, com *F1-scores* de 94,62% e 60,45%, respectivamente. O sistema multimodal que combina dados de questionários e *smartwatches* superou os classificadores individuais, demonstrando valor informacional complementar entre as modalidades de dados.

Em comparação, os resultados do cenário de classificação DP vs. CO do presente estudo, embora expressivos, ficaram abaixo dos valores previamente relatados, com acurácia balanceada e *F1-score* em torno de 60%, enquanto [Varghese et al. 2024] reportaram valores entre 70–80% para acurácia balanceada e 80–90% para *F1-score*. O segundo cenário (PD vs DD) apresentou um desempenho ligeiramente mais próximo do estudo anterior, porém sem superá-lo. No entanto, o terceiro cenário (DD vs CO), ausente na pesquisa mencionada e introduzido neste estudo como uma forma de avaliar o comportamento das características harmônicas, produziu resultados notáveis. Nele, todos os modelos testados apresentaram melhor desempenho em métricas sensíveis a vieses causados pelo desbalanceamento (acurácia balanceada e *F1-score*), com uma margem superior a 10% em relação aos cenários 1 e 2, além de uma acurácia geral comparável à do cenário 2. Ademais, os resultados obtidos nesse cenário foram, em média, superiores aos reportados para a classificação DP vs. DD no estudo anterior, tornando-se os melhores disponíveis para o grupo de diagnóstico diferencial.

No cenário DP vs. DD, os modelos *XGBoost* e *LightGBM* alcançaram os resultados mais notáveis, com *F1-scores* de 60,34% e 60,57%, respectivamente. Esses valores são comparáveis aos reportados por Varghese et al. para este mesmo cenário, utilizando uma *pipeline* mais simples [Varghese et al. 2024]. Isso demonstra que características harmônicas isoladas, aplicadas a algoritmos clássicos de aprendizado de máquina em suas configurações padrão, são suficientes para obter resultados competitivos.

O terceiro cenário (DD vs CO), ausente na pesquisa mencionada e introduzido neste estudo como uma forma de avaliar o comportamento das características harmônicas, produziu resultados notáveis. Nele, todos os modelos testados apresentaram melhor desempenho em métricas sensíveis a vieses causados pelo desbalanceamento (acurácia balanceada e *F1-score*), com uma margem superior a 10% em relação aos cenários 1 e 2, além de uma acurácia geral comparável à do cenário 2. Adicionalmente, observou-se nesse cenário equilíbrio entre todas as métricas e classificadores avaliados. Para o modelo *ExtraTrees*, que obteve os melhores resultados por menos de um por cento, a acurácia (74,64%), acurácia balanceada (73,43%), *F1-score* (73,39%), precisão (74,40%) e *recall* (73,43%) apresentaram valores muito próximos, padrão que se repetiu nos demais classificadores.

De modo geral, os resultados consolidam o uso das características harmônicas como uma opção viável para a identificação da Doença de Parkinson por meio de aprendizado de máquina. Além disso, postula-se que essas características podem contribuir para estudos futuros ao fornecer informações valiosas quando combinadas com outras características, como dados de questionários e medidas estatísticas, com o objetivo de alcançar classificações ainda mais confiáveis e consistentes.

4. Conclusão

Neste estudo, foi explorado o uso de características harmônicas derivadas de dados de giroscópio coletados por meio de *smartwatches* para auxiliar no diagnóstico da doença de Parkinson (DP) com o uso de aprendizado de máquina. A metodologia empregada incluiu pré-processamento, extração de características e classificação utilizando modelos de aprendizado de máquina, como *SVM*, *ExtraTrees*, *LightGBM* e *XGBoost*. O objetivo foi avaliar a capacidade preditiva das características harmônicas na diferenciação entre pacientes com DP, controles saudáveis (CO) e indivíduos com diagnósticos diferenciais (DD). Além disso, foi introduzido um cenário comparando os grupos DD e CO como uma forma de avaliar o comportamento das características.

Os resultados demonstraram que as características harmônicas, especialmente quando utilizadas com modelos baseados em *ensembles*, como o *LightGBM*, apresentaram um bom desempenho na classificação de DP vs. CO, atingindo uma acurácia de 84,05%. Os resultados obtidos são comparáveis com a literatura, mostrando o potencial preditivo dessas características mesmo em atividades diferentes daquelas analisadas anteriormente em trabalhos na literatura. No cenário DD vs. CO, analisado pela primeira vez neste trabalho, os modelos obtiveram um bom desempenho em métricas sensíveis a vieses, como a acurácia balanceada e o F1-score. Os dados apontam que as características harmônicas podem ser uma ferramenta valiosa no diagnóstico da doença de Parkinson auxiliado por aprendizado de máquina.

Para estudos futuros, prevê-se que a combinação das características harmônicas com outras fontes de dados, como medidas estatísticas e informações de questionários relatados pelos pacientes, contribuirá para aumentar a precisão e a confiabilidade do diagnóstico da DP. Recomenda-se que pesquisas futuras foquem na integração dessas características em modelos mais abrangentes, potencialmente resultando em classificações ainda mais robustas e consistentes.

Agradecimentos

O presente trabalho foi realizado com apoio do Conselho Nacional de Desenvolvimento Científico (CNPq) e da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) - Código de Financiamento 001, e Edital N° 30/2022 - Programa Emergencial de Solidariedade Acadêmica (PDPG).

Referências

- Ali, M. R., Na, I.-J., and Lee, J.-H. (2021). Machine learning for the diagnosis of parkinson's disease: A systematic review. *Frontiers in Aging Neuroscience*, 13:633752.
- Bloem, B. R., Okun, M. S., and Klein, C. (2021). Parkinson's disease. *Nature Reviews Disease Primers*, 7(1):52.
- Hasan, M. (2025). Parkinson's Disease Freezing of Gait Symptom Detection Using Machine Learning from Wearable Sensor Data. *arXiv preprint arXiv:2506.12561*.
- Ordóñez, F. J. and Roggen, D. (2016). Deep Convolutional and LSTM Recurrent Neural Networks for Multimodal Wearable Activity Recognition. In *2016 International Conference on Multisensor Fusion and Integration for Intelligent Systems (MFI)*, pages 425–432.

- Pietrosanti, L., Calado, A., Verrelli, C., Pisani, A., Suppa, A., Fattapposta, F., Zampogna, A., Patera, M., Rosati, V., Giannini, F., and Saggio, G. (2023). Harmonic Distortion Aspects in Upper Limb Swings during Gait in Parkinson's Disease. *Electronics*, 12:625.
- Prusty, S., Patnaik, S., and Dash, S. K. (2022). SKCV: Stratified K-fold cross-validation on ML classifiers for predicting cervical cancer. *Frontiers in Nanotechnology*, 4.
- van Drongelen, W. (2007). 6 - Continuous, Discrete, and Fast Fourier Transform. In van Drongelen, W., editor, *Signal Processing for Neuroscientists*, pages 91–105. Academic Press, Burlington.
- Varghese, J., Brenner, A., Fujarski, M., van Alen, C. M., Plagwitz, L., and Warnecke, T. (2024). Machine Learning in the Parkinson's disease smartwatch (PADS) dataset. *npj Parkinson's Disease*, 10(1):9.
- Zhou, Z. D., Yi, L. X., Wang, D. Q., Lim, T. M., and Tan, E. K. (2023). Role of dopamine in the pathophysiology of Parkinson's disease. *Translational Neurodegeneration*, 12(1):25.