Journal of Health Informatics

J Health Inform. 2026;18:e1782
DOI: https://doi.org/10.59681/2175-4411.v18.iEspecial.2026.1782

ARTIGO COMPLETO
CBIS 2026

Identificação da doença de Parkinson pela dinâmica da marcha sob dupla tarefa com machine learning

Identification of Parkinson's disease from gait dynamics under dual-task with machine learning

João Victor Andrade de Aquino Saraiva[1], Afonso Ueslei da Fonseca[2], Fabrizzio Soares[2], Juliana Paula Felix[2] ✉

ORCID: 0009-0007-5759-2405 · 0000-0001-5517-2051 · 0000-0003-1598-1377 · 0000-0003-4095-1639

[1] Pontifícia Universidade Católica de Goiás, Goiânia (GO), Brasil.

[2] Universidade Federal de Goiás, Goiânia (GO), Brasil.

FICHA DO ARTIGO

TIPO
Artigo completo · CBIS 2026

IDENTIFICADOR
e1782

DOI
10.59681/2175-4411.v18.iEspecial.2026.1782

RECEBIDO
17/05/2026

APROVADO
20/07/2026

PROCESSO DE AVALIAÇÃO
Double Blind Review

EDITOR RESPONSÁVEL
Juliano de Souza Gaspar

ACESSO
Aberto, CC BY 4.0

AUTOR CORRESPONDENTE
Juliana Paula Felix
julianafelix@ufg.br

LICENÇA

Este é um artigo publicado em acesso aberto sob a licença Creative Commons CC BY 4.0, que permite uso, distribuição e reprodução em qualquer meio, desde que o trabalho original seja corretamente citado.

CC BY 4.0

RESUMO

Objetivo: Este trabalho avalia o uso de aprendizado de máquina para detectar a Doença de Parkinson a partir de sinais de marcha coletados sob dupla tarefa cognitiva. **Método:** Vinte e sete participantes usaram sensores que registraram séries temporais de força de reação do solo enquanto caminhavam realizando subtrações matemáticas em sequência. A partir desses dados, foram extraídas características globais após processamento e segmentação, as quais alimentaram uma rede neural Multilayer Perceptron (MLP) avaliada por validação cruzada estratificada por paciente com balanceamento SMOTE. **Resultados:** A acurácia média alcançou 96% e a sensibilidade chegou a 100%, sem nenhum falso negativo registrado, o que significa que todos os portadores da doença foram corretamente classificados. **Conclusão:** Esses resultados sustentam a eficácia clínica do experimento com dupla tarefa e mostram que a abordagem é viável em dispositivos de baixo custo computacional para o diagnóstico da Doença de Parkinson.

Descritores: aprendizado de máquina; Doença de Parkinson; dupla tarefa; redes neurais de computação.

ABSTRACT

Objective: This work evaluates the use of machine learning to detect Parkinson's Disease from gait signals collected under a cognitive dual-task condition. **Method:** Twenty-seven participants wore sensors that recorded ground reaction force time series while they walked and performed sequential mathematical subtractions. From this data, global features were extracted after processing and segmentation, which fed a Multilayer Perceptron (MLP) neural network evaluated by patient-stratified cross-validation with SMOTE balancing. **Results:** Mean accuracy reached 96% and sensitivity reached 100%, with no false negatives recorded, meaning every patient with the disease was correctly classified. **Conclusion:** These results support the clinical efficacy of the dual-task experiment and show that the approach is feasible on low-computational-cost devices for Parkinson's Disease diagnosis.

Keywords: machine learning; Parkinson disease; dual task; neural networks computer.

CBIS 2026 XXI CONGRESSO BRASILEIRO DE INFORMÁTICA EM SAÚDE

Artigo apresentado no XXI Congresso Brasileiro de Informática em Saúde (CBIS 2026), realizado de 23 a 25 de setembro de 2026, em Brasília (DF), e publicado na seção CBIS 2026 do Journal of Health Informatics.

COMO CITAR ESTE ARTIGO: Saraiva JVAA, da Fonseca AU, Soares F, Felix JP. Identificação da doença de Parkinson pela dinâmica da marcha sob dupla tarefa com machine learning. J Health Inform 2026;18:e1782. doi: https://doi.org/10.59681/2175-4411.v18.iEspecial.2026.1782

1 INTRODUÇÃO

Em 1817, James Parkinson descreveu uma condição caracterizada por "movimento trêmulo involuntário, com diminuição da força muscular em partes não em ação e mesmo quando apoiadas; com propensão a curvar o tronco para a frente e a passar de um passo de caminhada para um passo de corrida, enquanto os sentidos e o intelecto permanecem inalterados" [1]. Inicialmente denominada "paralisia agitante" [2], essa condição passou posteriormente a ser conhecida como Doença de Parkinson (DP). A DP é a segunda doença neurodegenerativa mais comum, atrás apenas da doença de Alzheimer, além de representar o distúrbio hipocinético do movimento mais comum [3]. Trata-se de uma afecção do sistema nervoso central, a qual é expressa de forma crônica e progressiva, resultante da morte dos neurônios produtores de dopamina da substância negra. Clinicamente, a doença é caracterizada pelos sinais cardinais de rigidez, acinesia, bradicinesia, tremor e instabilidade postural [4], tendo uma prevalência de aproximadamente 0,5% a 1% entre aqueles com 65 a 69 anos de idade, aumentando para 1% a 3% entre pessoas com 80 anos de idade ou mais [5].

Entre os sinais centrais da DP, destacam-se a instabilidade postural (variabilidade do movimento) e a bradicinesia (lentidão), que se manifestam na locomoção. Devido às alterações motoras e não motoras que a doença propicia, os indivíduos com a DP obtêm maior risco de acidentes por quedas quando comparados aos indivíduos saudáveis [6]. As quedas são as causas mais comuns de acidentes em pessoas acima de 65 anos de idade, e são a principal causa de mortalidade devido a lesões externas nesta faixa etária [7]. Portanto, a avaliação objetiva e quantitativa dessas disfunções da marcha emerge como uma ferramenta essencial para o diagnóstico precoce e o monitoramento da progressão da doença.

O diagnóstico da DP é realizado por meio da observação e avaliação clínica no histórico do paciente [2], ocasionando variabilidade interobservadora e um possível diagnóstico tardio. Por outro lado, o aprendizado de máquina tem surgido como um forte aliado para auxiliar no diagnóstico da DP. Na literatura, diversos são os estudos que propõem a análise de sinais motores como alternativa para auxiliar no diagnóstico de DP [8-12].

Nesse contexto, a análise de padrões de marcha, em especial, tem sido bastante explorada [8-10]. Ferreira *et al.* [8] analisaram características espaço-temporais da marcha usual em velocidade autosselecionada capturada por câmeras, alcançando uma acurácia de 84,6% na classificação entre DP e grupo controle (CO) através do algoritmo *Naive Bayes*, já Balaji *et al.* [9] utilizaram dados de Força de Reação Vertical do Solo (VGRF) de participantes submetidos à caminhada em esteira e sob estímulo auditivo rítmico (RAS), obtendo 98,6% de acurácia na separação entre pacientes com DP e controles, por meio de redes profundas *Long Short-Term Memory* (LSTM). Park *et al.* [10] combinaram sensores vestíveis e análise de movimento para capturar a marcha para trás e com giros de 360 graus, conseguindo distinguir com 100% de acurácia as escalas da severidade da DP.

Neste trabalho, investigamos a predição da DP através de análise da marcha sob condições de dupla tarefa, isto é, a caminhada executada simultaneamente a operações matemáticas. A análise é realizada sob um conjunto de dados público, explorando séries temporais de força aplicada ao solo coletadas dos participantes durante um percurso de caminhada. Um conjunto de características que combina informações estatísticas e harmônicas das séries temporais de reação de força é proposto para investigação, utilizando uma rede neural *Multilayer Perceptron* (MLP) e técnicas de sobreamostragem de dados para a classificação preditiva. Assim, classificando isoladamente com os dados da dupla tarefa com subtração seriada, permite-se uma análise de variabilidade do ritmo da marcha em função da demanda de atenção cognitiva.

O restante deste artigo está organizado da seguinte forma: a Seção Métodos detalha os materiais e métodos, detalhando a base de dados, o pré-processamento dos dados e os modelos de classificações usados com métodos de avaliação; a Seção Resultados e Discussão discute sobre os resultados obtidos, e por fim, a Seção Conclusão discorre sobre as conclusões extraídas sobre os resultados e métodos.

2 MÉTODOS

A Figura 1 apresenta o *pipeline* do método proposto neste trabalho. As seções seguintes detalham cada uma das etapas que o compõem, desde a coleta dos dados até a predição da DP.

2.1 Base de Dados

O banco de dados de livre acesso GaitPDB, disponível no repositório da PhysioNet [13], e composto por dados públicos previamente anonimizados, o que dispensa submissão ao Comitê de Ética em Pesquisa (CEP), foi utilizado nesta pesquisa. O banco contém registros de marchas coletadas a partir de 166 indivíduos, onde 93 (58 homens e 35 mulheres) são pessoas com DP e 73 (40 homens e 33 mulheres) são registros de pessoas saudáveis consistindo no grupo controle. O total de amostras disponíveis no banco de dados resulta de três estudos diferentes, sendo eles Ga [14], Ju [15] e Si [16]. Cada estudo foi conduzido sob protocolos de caminhada diferentes. Neste trabalho, utilizamos apenas os dados provenientes do estudo Ga [14], conduzido pela Unidade de Distúrbios do Movimento no Centro Médico Sourasky de Tel-Aviv, com o intuito de permitir a análise dos padrões de marcha dos

participantes sob execução de uma tarefa paralela de caráter cognitivo. Mais especificamente, foram utilizados os dados da subtarefa 10 do experimento de coleta, na qual os participantes caminhavam por aproximadamente 2 minutos em um corredor de terreno plano sob a dinâmica de uma dupla tarefa, consistente na subtração serial de números de 7 em 7. Os dados foram coletados de cada participante a partir de um par de palmilhas instrumentadas contendo 8 sensores de VGRF em cada pé, e registrados em uma frequência de 100 Hz. Posteriormente, séries temporais referentes à força total de cada pé, obtidas a partir do somatório das forças registradas pelos sensores ao longo do tempo, foram disponibilizadas. Apenas as séries da força total do pé esquerdo e do pé direito são utilizadas neste trabalho. A Figura 2 apresenta uma visualização das séries temporais de força total do pé direito (Força(N) × Tempo(s)) de um participante do grupo DP (a) e de um indivíduo do grupo CO (b). Ao todo, 27 participantes realizaram essa subtarefa, sendo 21 (4 mulheres e 17 homens) com DP e 6 (4 mulheres e 2

Figura 1. Pipeline do método avaliado neste estudo

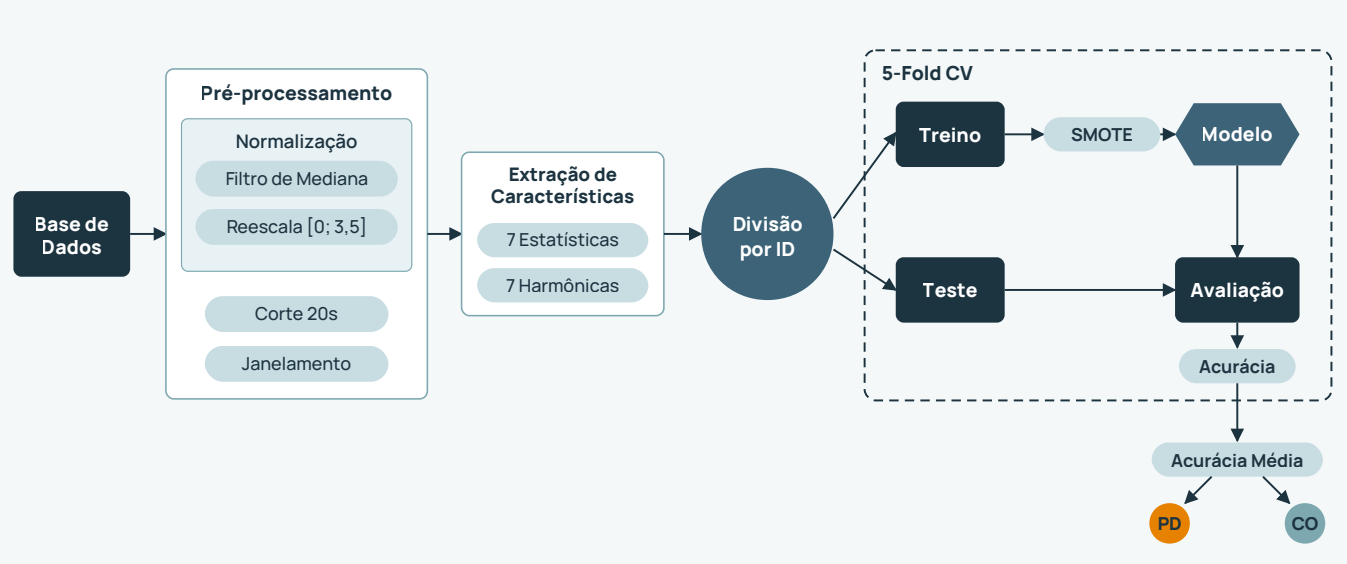

Fonte: Elaborado pelos autores (2026).

Figura 2. VGRF pé direito de participante com DP (a) e CO (b)

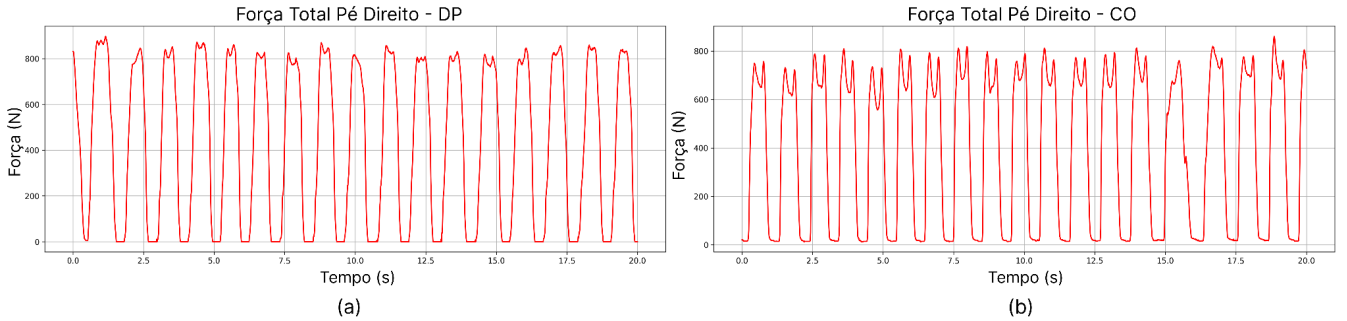

Fonte: Elaborado pelos autores (2026).

homens) saudáveis (CO).

2.2 Pré-Processamento

Tendo em vista que os segundos iniciais dos sinais coletados correspondem ao início da caminhada, período no qual o participante ainda pode estar se adaptando ao experimento, foram removidos os 20 primeiros segundos de cada coleta, eliminando os efeitos ligados à fase de inicialização e adaptação, permitindo a análise de uma marcha mais estável sob carga cognitiva. Após essa etapa, foi realizado o processo de normalização das séries temporais. Inicialmente, aplicou-se um filtro de mediana de n=25 para remoção de ruídos e suavização dos sinais captados, contribuindo para a melhoria do desempenho do processo de classificação. Em seguida, os sinais de cada sensor foram reescalados para o intervalo entre 0 e 3,5 pela transformação *min-max,* com limites definidos a partir de observações sobre o comportamento dos sensores de força utilizados [17]. Esse procedimento visa preservar as proporções relativas entre as amostras e eliminar discrepâncias de amplitude causadas pela diferença física entre os participantes.

A marcha é, por natureza, uma série temporal contínua, e sua análise em aplicações de aprendizado

de máquina, por vezes, exige segmentação em unidades discretas. Aqui, aplicou-se o janelamento (*windowing*), técnica que divide o registro completo de caminhada em segmentos menores de duração fixa, cumprindo dois objetivos. O primeiro é o aumento de dados, visto que segmentar gravações longas em múltiplas janelas de curta duração eleva o número de instâncias disponíveis para treinamento, a qual é uma estratégia especialmente relevante em estudos de doenças raras, onde amostras independentes são escassas. Nesse contexto, Fraiwan e Hassanin [18] apontam essa segmentação como essencial para maximizar o conjunto de treinamento nesse tipo de cenário. O segundo objetivo é o isolamento de eventos, onde cada janela pode conter ciclos de passada tratáveis como unidades autônomas pelo modelo, considerando cada janela como uma amostra independente.

Figura 3. Janelamento de W = 5s e S = 2s em uma série de 10s

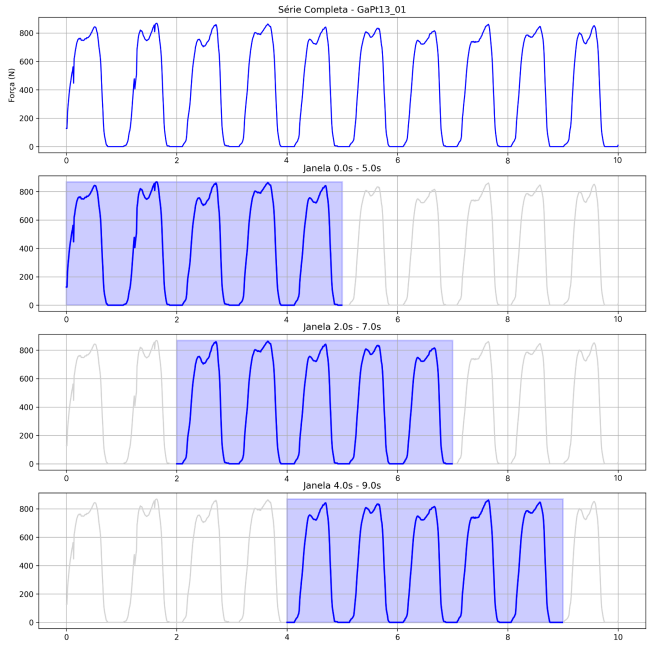

Fonte: Elaborado pelos autores (2026).

Na estratégia de janelamento, o tamanho da janela W e o passo S definem a natureza das amostras geradas. Quando S < W, as janelas se sobrepõem, ampliando o volume de dados disponível, o que se denomina janelamento com interseção. Para esse estudo, adotou-se uma janela de 5 segundos com passo de 2 segundos, ou seja, com interseção. A decisão do tamanho da janela fundamenta-se na garantia de que cada janela represente ao menos 2 passadas (tempo decorrido entre um pé tocar o solo até ele tocar o solo novamente), que dura, em média, 1,2 s. A Figura 3 ilustra o processo aplicado a um segmento de marcha de um paciente com DP, decompondo uma série de 10 segundos em janelas de 5 segundos com passo de 2 segundos.

2.3 Extração de Características

Com o conjunto de dados normalizado e segmentado em janelas, realizou-se a extração de características de cada série temporal de forma independente. O objetivo é transformar séries temporais em representações compactas que preservem as informações mais relevantes para a tarefa de classificação. Cada janela foi tratada como uma unidade de análise, da qual se extraiu um conjunto de 14 características, conforme adotado em [19]. Esse conjunto foi dividido em duas categorias, cada uma capturando dinâmicas distintas da marcha humana, onde juntas traduzem cada janela em valores numéricos que o modelo de aprendizado usa para distinguir padrões de marcha saudáveis dos patológicos.

A primeira categoria reúne sete métricas estatísticas e de dispersão temporal: média, desvio padrão, assimetria (*skewness*), curtose, coeficiente de variação, entropia de Shannon e expoente de Hurst, no qual o expoente de Hurst foi calculado via *Detrended Fluctuation Analysis* (DFA). Essas medidas, demonstradas com fórmulas na Tabela 1, quantificam a regularidade, a estabilidade e as flutuações intrínsecas do sinal, aspectos relevantes visto que a marcha de indivíduos com DP tende a apresentar instabilidade e perda de ritmo progressivas conforme a doença avança. Nas fórmulas, N é o tamanho da série temporal, y_i o valor do ponto i, e $p(y_i)$ a probabilidade estimada de ocorrência de y_i.

A segunda categoria é composta por sete características relacionadas à distorção harmônica: a Distorção Harmônica Total (THD) e as frequências e potências das três primeiras componentes harmônicas do sinal (THD, 1ª, 2ª e 3ª ordens da Frequência e 1ª, 2ª e 3ª ordens da Potência), resultando então em 7 características de caráter harmônico. Embora esse tipo de análise seja tradicional em engenharia elétrica, sua aplicação à marcha, introduzida por Félix [19], permite quantificar irregularidades nos sinais de VGRF em relação à componente fundamental.

Assim, a etapa de extração de características atua processando os sinais de marcha em um vetor numérico estático de 28 atributos globais (14 características × 2 séries, sendo elas a força total do pé esquerdo e a força total do pé direito). Dessa forma, a exigência de modelar as dependências temporais internamente na arquitetura da rede é eliminada, sem a necessidade de estruturas mais complexas, justificando o uso de uma arquitetura como a *feedforward* totalmente conectada usada como modelo.

Tabela 1. Características estatísticas e de distorção harmônica, com as fórmulas

Categoria	Nome da Métrica	Fórmula / Método de Obtenção
Estatísticas	Média (μ)	$\mu = \frac{1}{N}\sum_{i=1}^{N} y_i$
	Desvio Padrão (σ)	$\sigma = \sqrt{\frac{1}{N-1}\sum_{i=1}^{N}(y_i - \mu)^2}$
	Coeficiente de Variação (CV)	$CV = 100 \cdot \frac{\sigma}{\mu}$
	Entropia de Shannon	$H(y) = -\sum_{i=1}^{N} p(y_i)\log(p(y_i))$
	Assimetria (Skewness)	$Skew = \frac{1}{N}\sum_{i=1}^{N}\left(\frac{y_i - \mu}{\sigma}\right)^3$
	Curtose (Kurtosis)	$Kurt = \frac{1}{N}\sum_{i=1}^{N}\left(\frac{y_i - \mu}{\sigma}\right)^4$
	Expoente de Hurst (α)	$F(n) = \sqrt{\frac{1}{n}\sum_{k=1}^{n}[y(k) - y_n(k)]^2}$
		$\alpha = \frac{d\log F(n)}{d\log n}$
Distorção Harmônica	Distorção Harmônica Total (THD)	Métricas obtidas por análise espectral do sinal, considerando a frequência fundamental e harmônicas de ordem 1 a 3, conforme implementação computacional.
	Frequência (1ª Ordem)	
	Frequência (2ª Ordem)	
	Frequência (3ª Ordem)	
	Potência (1ª Ordem)	
	Potência (2ª Ordem)	
	Potência (3ª Ordem)	

Fonte: Elaborado pelos autores (2026).

2.4 Avaliação do Modelo

A avaliação interna dos modelos foi conduzida por validação cruzada *K-Fold* com 5 *folds*. No *K-Fold*, o conjunto de dados é dividido em k partições de tamanho equivalente, onde a cada iteração, uma partição é reservada para validação enquanto as demais compõem o treinamento, de modo que todo exemplo é usado para validação exatamente uma vez. Essa é uma técnica de extrema importância para resolver os vieses que podem surgir de uma representação desigual das classes nos subconjuntos de dados, resultando em uma estimativa mais confiável do desempenho do modelo em todas as categorias [20].

Entretanto, o janelamento com interseção introduz risco de vazamento de dados (*data leakage*) com o K-Fold, visto que janelas de dados originadas de um mesmo indivíduo compartilham características de marcha e, se distribuídas em conjuntos de treino e teste, o modelo pode aprender o padrão individual em vez do padrão da doença, inflando artificialmente as métricas analisadas. Para evitar isso, a divisão dos *folds* foi realizada com separação estrita por paciente a partir de seu identificador único (ID), garantindo que todas as janelas de um mesmo indivíduo fiquem sempre no mesmo conjunto (ou treino, ou teste).

O subconjunto de dados utilizado conta com 21 pacientes com DP e apenas 6 controles, desbalanceamento que, sem tratamento, gera uma tendência de enviesamento do modelo para a classe majoritária. Para contornar esse problema, foi aplicado o *SMOTE* (*Synthetic Minority Over-sampling Technique*), que gera amostras sintéticas da classe minoritária por interpolação entre vizinhos no espaço de características. O método é aplicado estritamente dentro de cada *fold* de treinamento, nunca sobre o conjunto de validação, evitando que dados sintéticos contaminem a avaliação e resultem em *data leakage*.

A Figura 4 ilustra o efeito do *SMOTE* em um *fold*, com a classe 0 representando os controles (CO) (minoritária) e a classe 1 os pacientes com DP (majoritária). A visualização foi gerada com Análise de Componentes Principais (PCA) reduzindo o espaço de características a duas componentes, sendo este recurso usado exclusivamente para fins gráficos, sem influência sobre o treinamento ou a classificação.

2.5 Modelos

O modelo de classificação utilizado foi o *MLP*, o qual consiste em uma rede neural artificial *Feedforward* totalmente conectada por camadas ocultas e neurônios. A escolha por esta arquitetura, em detrimento de

modelos de aprendizado profundo focados em séries temporais (como as redes convolucionais ou recorrentes), fundamenta-se na natureza do problema e na eficiência computacional, possibilitando uma classificação acessível e de baixo custo [21].

A Figura 5 ilustra a arquitetura do MLP utilizada, onde a camada de entrada recebe o vetor de entrada de n=28 dimensões, composto pelas características extraídas das séries de força total do pé esquerdo (E1, E2, ..., E14) e do pé direito (E15, E16, ..., E28). Uma camada oculta totalmente conectada com cinco neurônios é utilizada em seguida. A camada de saída possui neurônios correspondentes às classes DP e CO, com função de ativação logística para a classificação binária final. Os demais hiperparâmetros seguiram os valores padrão do *MLPClassifier* da biblioteca *scikit-learn*, que adota a função de ativação *ReLU* nas camadas ocultas e o otimizador Adam para atualização dos pesos e viés (*bias*). Além disso, visto que a aplicação foi feita utilizando *Python,* não apenas na rede MLP, mas em todo o processamento da pesquisa, o parâmetro *random_state*=0 foi fixado para garantir a reprodutibilidade dos experimentos.

2.6 Avaliação e Métrica de Análise

A avaliação do modelo seguiu a abordagem por paciente, onde o diagnóstico final de cada indivíduo é determinado por votação majoritária entre as janelas que lhe pertencem. Essa agregação produziu desempenho superior à avaliação direta por janela, que também foi testada, mas não é apresentada neste documento por restrições de espaço.

O desempenho do classificador foi quantificado por acurácia, sensibilidade e especificidade, expressas nas Equações (a), (b) e (c). A acurácia (Acc.) representa a proporção global de diagnósticos corretos, onde verdadeiros positivos (VP) são pacientes com DP corretamente identificados e verdadeiros negativos (VN) são controles corretamente descartados, sobre o total de pacientes avaliados. A sensibilidade (Sens.) mede a capacidade do modelo em identificar corretamente os pacientes com DP, sendo que falsos negativos (FN) têm custo clínico direto por deixarem indivíduos doentes sem diagnóstico. A especificidade (Espec.) quantifica a taxa de acerto sobre os controles saudáveis, refletindo a capacidade do modelo em evitar classificar erroneamente indivíduos sem a patologia como falsos positivos (FP).

$$\text{Acc.} = \frac{VP + VN}{VP + VN + FP + FN} \quad \text{(a)}$$

$$\text{Sens.} = \frac{VP}{VP + FN} \quad \text{(b)}$$

$$\text{Espec.} = \frac{VN}{VN + FP} \quad \text{(c)}$$

Para complementar a análise, foram utilizadas matrizes de confusão, que organizam resultados em forma tabular entre reais contra preditos. A diagonal principal reúne os acertos de cada classe, enquanto as células fora dela expõem os erros de predição, permitindo avaliar o equilíbrio do modelo no reconhecimento de DP e CO e avaliar para qual classe o modelo está errando.

Figura 4. Balanceamento com SMOTE durante treino em fold

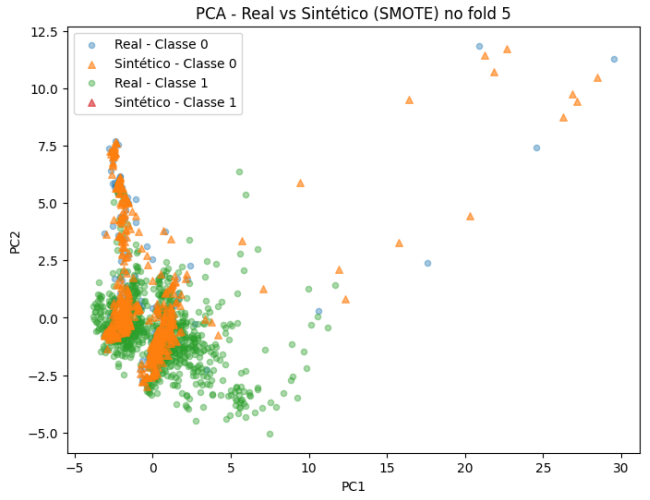

Fonte: Elaborado pelos autores (2026).

Figura 5. MLP, com 1 camada oculta com 5 neurônios, e a camada de saída.

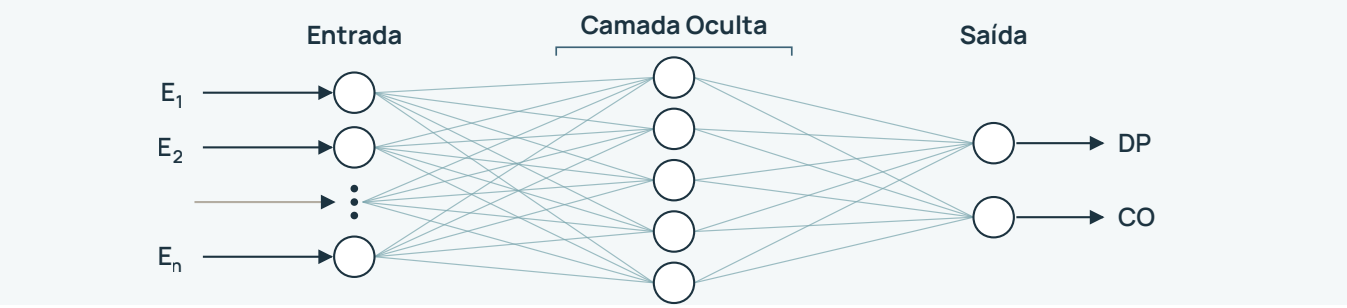

Fonte: Elaborado pelos autores (2026).

3 RESULTADOS E DISCUSSÃO

O MLP atingiu acurácia média de 96,00% na classificação binária entre pacientes com DP e controles saudáveis, com sensibilidade de 100,00% e especificidade de 83,33%, avaliado por validação cruzada de 5 *folds* com separação por paciente. A matriz de confusão agregada, ilustrada na Figura 6, detalha esses resultados, visto que dos 27 participantes, 26 foram classificados corretamente. Os 21 pacientes com DP foram identificados sem nenhum erro, resultando em zero falsos negativos. Entretanto, dos 6 controles, 5 foram corretamente classificados como saudáveis e um foi classificado errado como DP, constituindo o único falso positivo do experimento.

Do ponto de vista clínico, a ausência de falsos negativos é um resultado relevante, pois garante que nenhum paciente doente seria dispensado sem acompanhamento. Tendo em vista um sistema de triagem, essa consequência é aceitável, onde o indivíduo saudável sinalizado seria encaminhado para exames neurológicos confirmatórios, sem que nenhum paciente com DP deixasse de ser identificado.

A premissa central deste estudo repousa na classificação com *machine learning* e tarefa cognitivo-motora para diagnosticar DP sob a marcha. Ao exigir que o paciente realize cálculos matemáticos enquanto caminha, os recursos atencionais disponíveis para sustentar a automaticidade da marcha são reduzidos, forçando a manifestação da instabilidade motora. A capacidade do modelo proposto em detectar a totalidade dos pacientes patológicos evidencia que o estresse da dupla tarefa atua como um forte catalisador da desordem rítmica da marcha.

A eficácia dessa metodologia destaca-se ao ser comparada com a literatura recente focada estritamente em dupla tarefa. Tîrnăucă *et al.* [11] aplicaram o estresse de subtração seriada, porém utilizando sensores inerciais, e alcançaram uma sensibilidade de 71,00% e acurácia de 81,50%. O resultado de zero falsos negativos, o qual é reportado neste estudo, comprova que a VGRF é um biomarcador notavelmente mais responsivo à interferência cognitiva do que a cinemática angular. Além disso, Pooja *et al.* [12] avaliaram a marcha na mesma base VGRF (PhysioNet) sob dupla tarefa, porém fonética, mas relataram dificuldades de aprendizado ao aplicar Redes Neurais baseadas em atributos convencionais, obtendo apenas 84,60% de acurácia e 88,00% de sensibilidade, porém reportaram 97,22% de acurácia quando utilizado o Naive Bayes [12]. O desempenho alcançado neste estudo, com o modelo MLP, confirma que a adoção de um vetor de características enxuto, impulsionado por métricas de distorção harmônica, otimiza o aprendizado da rede neural e estabelece um método

Figura 6. Matriz de Confusão

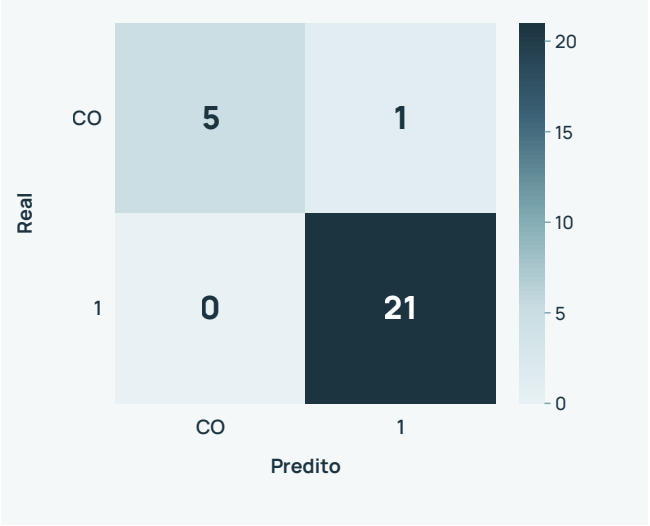

Fonte: Elaborado pelos autores (2026).

seguro para a triagem clínica.

4 CONCLUSÕES

Foi proposto como objetivo deste trabalho um método de classificação, utilizando *machine learning* com base na marcha sob dupla tarefa, para diagnóstico da Doença de Parkinson. O método utiliza sinais de marcha coletados de caminhadas durante a tarefa de subtração seriada de sete de aproximadamente 2 minutos a partir de sensores de força alocados em cada pé dos 27 voluntários com DP e saudáveis. Dessa forma, os sinais brutos obtidos de cada pé foram normalizados e segmentados com o processo de janelamento, permitindo a análise de amostras independentes e seus ciclos além do aumento do banco de dados. Além disso, foram extraídas características do âmbito harmônico e estatísticas de cada amostra. O classificador MLP, avaliado por validação cruzada *K-Fold* estratificada por paciente com balanceamento via *SMOTE*, atingiu acurácia de 96,00% e sensibilidade de 100,00%, identificando todos os pacientes com DP sem nenhum falso negativo. Cabe ressaltar, contudo, que o tamanho amostral reduzido e o forte desbalanceamento entre grupos limitam a robustez estatística dos resultados. Mesmo com o SMOTE aplicado corretamente apenas no conjunto de treinamento, métricas como sensibilidade e especificidade tendem a ser superestimadas em amostras pequenas, devendo ser interpretadas como indicativos preliminares e não como desempenho generalizável.

Comparado a trabalhos da literatura, que em geral utilizam todo o conjunto de dados disponível no GaitPDB sem isolar condições específicas de tarefa, este estudo restringiu a análise exclusivamente à subtarefa de subtração serial, o que reduz o volume de dados, mas permite uma avaliação mais controlada do efeito da dupla tarefa cognitiva sobre os padrões de marcha. O modelo proposto, mesmo operando sobre um

conjunto reduzido, atingiu uma acurácia e sensibilidade de boa performance, o que sugere que os sinais coletados durante essa condição específica contêm informação discriminativa suficiente para a classificação.

A escolha por uma arquitetura MLP, de baixa complexidade computacional, contribui para que o método permaneça acessível, com potencial de uso em dispositivos móveis ou embarcados com menor poder de processamento. Dessa forma, considerando o Sistema Único de Saúde (SUS), o método apresenta potencial para compor ferramentas de apoio à decisão clínica e triagem de pacientes. Ressalta-se que sua aplicação em ambientes clínicos depende de estudos adicionais de validação. Como trabalhos futuros, propõe-se a expansão do banco de dados de tarefa dupla com maior número de controles, a investigação de outras subtarefas cognitivas e a avaliação do método em outras condições neurodegenerativas.

Contribuição dos autores. João Victor Andrade de Aquino Saraiva contribuiu para a concepção e o delineamento do estudo, desenvolvimento de software, validação, análise e interpretação dos dados, elaboração de figuras e redação da versão inicial do manuscrito. Afonso Ueslei da Fonseca contribuiu para a definição da metodologia, análise formal e revisão crítica do manuscrito. Fabrizzio Soares contribuiu para a análise formal, supervisão da pesquisa e revisão crítica do manuscrito. Juliana Paula Felix contribuiu para a concepção e o delineamento do estudo, definição da metodologia, supervisão da pesquisa e revisão crítica do manuscrito. Todos os autores leram e aprovaram a versão final do manuscrito.

Agradecimentos. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES), Código de Financiamento 001, e Edital nº 30/2022 - PDPG - Solidariedade Acadêmica.

Financiamento. Os autores não declararam fonte de financiamento.

Disponibilidade de dados e materiais. Os dados utilizados neste estudo são de acesso público e estão disponíveis gratuitamente na base GaitPDB, hospedada no repositório PhysioNet, em https://physionet.org/content/gaitpdb/1.0.0/.

Conflitos de interesse. Os autores não declararam conflitos de interesse.

Declaração de uso de IA. Os autores utilizaram o ChatGPT, desenvolvido pela OpenAI, como ferramenta para apoio à revisão de código. O material gerado foi analisado, revisado e validado pelos autores antes de sua incorporação ao trabalho final.

REFERÊNCIAS

1. Parkinson J. An Essay on the Shaking Palsy. J Neuropsychiatry Clin Neurosci. 2002;14(2):223-36. doi: https://doi.org/10.1176/jnp.14.2.223
2. Munhoz RP, Tumas V, Pedroso JL, Silveira-Moriyama L. The clinical diagnosis of Parkinson's disease. Arq Neuropsiquiatr. 2024;82(06):001-10. doi: https://doi.org/10.1055/s-0043-1777775
3. Teive HAG, Munhoz RP, Lees AJ. Parkinson's disease – 200 years: the outstanding contribution of "Old Hubert". Arq Neuropsiquiatr. 2017;75(3):192-4. doi: https://doi.org/10.1590/0004-282x20170006
4. Souza CFM, Almeida HCP, Sousa JB, Costa PH, Silveira YSS, Bezerra JCL. A Doença de Parkinson e o Processo de Envelhecimento Motor. Rev Neurocienc. 2011;19(4):718-23. doi: https://doi.org/10.34024/rnc.2011.v19.8330
5. Tanner CM. Epidemiology of Parkinson's Disease. Neurol Clin. 1992;10(2):317-29. doi: https://doi.org/10.1016/s0733-8619(18)30212-3
6. Christofoletti G, Oliani MM, Gobbi LTB, Gobbi S, Stella F. Risco de quedas em idosos com doença de Parkinson e demência de Alzheimer: um estudo transversal. Braz J Phys Ther. 2006;10(4):429-33. doi: https://doi.org/10.1590/s1413-35552006000400011
7. Abrams WB, Berkow R, Fletcher AJ. Manual Merck de geriatria. [s.l.]: [s.n.]; 1995.
8. Ferreira MIASN, Barbieri FA, Moreno VC, Penedo T, Tavares JMRS. Machine learning models for Parkinson's disease detection and stage classification based on spatial-temporal gait parameters. Gait Posture. 2022;98:49-55. doi: https://doi.org/10.1016/j.gaitpost.2022.08.014
9. Balaji E, Brindha D, Vikrama R. Automatic and non-invasive Parkinson's disease diagnosis and severity rating using LSTM network. Appl Soft Comput. 2021;108:107463. doi: https://doi.org/10.1016/j.asoc.2021.107463
10. Park H, Youm C, Cheon SM, Kim B, Choi H, Hwang J, et al. Using machine learning to identify Parkinson's disease severity subtypes with multimodal data. J Neuroeng Rehabil. 2025;22(1):126. doi: https://doi.org/10.1186/s12984-025-01648-2
11. Tîrnăucă C, Stan D, Meissner JM, Salas-Gómez D, Fernández-Gorgojo M, Infante J. A Machine Learning Approach to Detect Parkinson's Disease by Looking at Gait Alterations. Mathematics. 2022;10(19):3500. doi: https://doi.org/10.3390/math10193500
12. Pooja, Veer K, Pahuja SK. Gender based assessment of gait rhythms during dual-task in Parkinson's disease and its early detection. Biomed Signal Process Control. 2022;72:103346. doi: https://doi.org/10.1016/j.bspc.2021.103346
13. Goldberger AL, Amaral LAN, Glass L, Hausdorff JM, Ivanov PC, Mark RG, et al. PhysioBank, PhysioToolkit, and PhysioNet. Circulation. 2000;101(23):e215-e220. doi: https://doi.org/10.1161/01.cir.101.23.e215

14. Yogev G, Giladi N, Peretz C, Springer S, Simon ES, Hausdorff JM. Dual tasking, gait rhythmicity, and Parkinson's disease: Which aspects of gait are attention demanding? Eur J Neurosci. 2005;22(5):1248-56. doi: https://doi.org/10.1111/j.1460-9568.2005.04298.x

15. Hausdorff JM, Lowenthal J, Herman T, Gruendlinger L, Peretz C, Giladi N. Rhythmic auditory stimulation modulates gait variability in Parkinson's disease. Eur J Neurosci. 2007;26(8):2369-75. doi: https://doi.org/10.1111/j.1460-9568.2007.05810.x

16. Frenkel-Toledo S, Giladi N, Peretz C, Herman T, Gruendlinger L, Hausdorff JM. Treadmill walking as an external pacemaker to improve gait rhythm and stability in Parkinson's disease. Mov Disord. 2005;20(9):1109-14. doi: https://doi.org/10.1002/mds.20507

17. Hausdorff JM, Ladin Z, Wei JY. Footswitch system for measurement of the temporal parameters of gait. J Biomech. 1995;28(3):347-51. doi: https://doi.org/10.1016/0021-9290(94)00074-e

18. Fraiwan L, Hassanin O. Computer-aided identification of degenerative neuromuscular diseases based on gait dynamics and ensemble decision tree classifiers. PLoS One. 2021;16(6):e0252380. doi: https://doi.org/10.1371/journal.pone.0252380

19. Félix JP, Nascimento HAD, Guimarães NN. Investigation of Machine Learning Techniques to Aid in the Diagnosis of Neurodegenerative Diseases. In: Anais Estendidos do XXIV Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS 2024). 2024. p. 115-20. doi: https://doi.org/10.5753/sbcas_estendido.2024.2828

20. Prusty S, Patnaik S, Dash SK. SKCV: Stratified K-fold cross-validation on ML classifiers for predicting cervical cancer. Front Nanotechnol. 2022;4:972421. doi: https://doi.org/10.3389/fnano.2022.972421

21. Felix JP, da Fonseca AU, do Nascimento HAD, Guimarães NN. Rede Neural Multicamadas para Classificação de Doenças Neurodegenerativas a partir de Sinais de Marcha. In: Congresso Brasileiro de Automática (CBA). 2022. doi: https://doi.org/10.20906/cba2022/3359

NOTAS EDITORIAIS

O Journal of Health Informatics é uma publicação científica mantida pela Sociedade Brasileira de Informática em Saúde, associação científica sem fins lucrativos dedicada ao desenvolvimento da Informática em Saúde e da Saúde Digital no Brasil. O processo editorial é conduzido com independência científica, sem interferência institucional, comercial ou de patrocinadores, e segue as boas práticas internacionais de ética em publicação científica.

Este artigo foi avaliado por pares, em sistema duplo-cego, por especialistas da área. A equipe editorial usou ferramentas de inteligência artificial, com supervisão humana, na triagem inicial, na conferência do texto, das referências e dos números e, quando necessário, no redesenho de figuras, quadros e tabelas, aprovado pelos autores na prova. As ferramentas e as salvaguardas estão na Política de uso de inteligência artificial da revista. As decisões editoriais foram tomadas por pessoas.

SBIS Sociedade Brasileira de Informática em Saúde