Journal of Health Informatics

J Health Inform. 2026;18:e1862
DOI: https://doi.org/10.59681/2175-4411.v18.iEspecial.2026.1862

ARTIGO COMPLETO
CBIS 2026

Análise automática de sinais brutos de marcha no diagnóstico de esclerose lateral amiotrófica

Automatic analysis of raw gait signals in the diagnosis of amyotrophic lateral sclerosis

Breno Yuri Chaves da Silva[1], Ana Luísa de Bastos Chagas[2], Solange da Silva[1], Marcos Lajovic Carneiro[1], Fabrizzio Soares[2], Juliana Paula Felix[2] ✉

ORCID: 0009-0009-3508-4631 · 0009-0002-9831-0068 · 0009-0006-7646-4196 · 0000-0003-1408-3049 · 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
e1862

DOI
10.59681/2175-4411.v18.iEspecial.2026.1862

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: Avaliar o potencial de técnicas de aprendizado de máquina aplicadas a sinais brutos de marcha para auxílio no diagnóstico da Esclerose Lateral Amiotrófica (ELA) e no diagnóstico diferencial em relação à Doença de Parkinson (DP) e à Doença de Huntington (DH). **Método:** Características (features) foram extraídas automaticamente de sinais de marcha utilizando a biblioteca tsfresh. Diferentes estratégias de seleção de características e classificadores foram avaliados com validação baseada em grupos. **Resultados:** O melhor desempenho foi obtido no cenário ELA vs. Controle, com acurácia de 96,06% utilizando Eliminação Recursiva de Características (RFE) e Máquina de Vetores de Suporte (SVM). Nos cenários ELA vs. DH e ELA vs. DP foram obtidas acurácias de até 95,13% e 87,88%, respectivamente. Nos cenários multiclasse, os modelos alcançaram acurácias entre 87,44% e 91,18%. **Conclusão:** A análise automática de sinais brutos de marcha associada ao aprendizado de máquina possui potencial para auxiliar no diagnóstico da ELA e no diagnóstico diferencial envolvendo outras doenças neurodegenerativas.

Descritores: Esclerose Lateral Amiotrófica; análise da marcha; aprendizado de máquina.

ABSTRACT

Objective: To evaluate the potential of machine learning techniques applied to raw gait signals for supporting Amyotrophic Lateral Sclerosis (ALS) diagnosis and differential diagnosis against Parkinson's Disease (PD) and Huntington's Disease (HD). **Methods:** Features were automatically extracted from gait signals using the tsfresh library. Different feature selection strategies and classifiers were evaluated using group-based cross-validation. **Results:** The best performance was achieved in the ALS vs. Control scenario, with 96.06% accuracy using Recursive Feature Elimination (RFE) and Support Vector Machine (SVM). In the ALS vs. HD and ALS vs. PD scenarios, accuracies of up to 95.13% and 87.88% were obtained, respectively. In multiclass scenarios, the models achieved accuracies between 87.44% and 91.18%. **Conclusion:** Automatic analysis of raw gait signals combined with machine learning has potential to support ALS diagnosis and differential diagnosis involving other neurodegenerative diseases.

Keywords: Amyotrophic Lateral Sclerosis; gait analysis; machine learning.

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: da Silva BYC, Chagas ALB, da Silva S, Carneiro ML, Soares F, Felix JP. Análise automática de sinais brutos de marcha no diagnóstico de esclerose lateral amiotrófica. J Health Inform 2026;18:e1862. doi: https://doi.org/10.59681/2175-4411.v18.iEspecial.2026.1862

1 INTRODUÇÃO

A Esclerose Lateral Amiotrófica (ELA) é uma doença neurodegenerativa de caráter progressivo, que afeta o sistema nervoso central e atinge os neurônios motores. Dentre vários sintomas, é possível destacar alterações na marcha, fraquezas musculares, espasmos, cãibras e quedas [1]. Não há cura para a ELA e atualmente não existe um teste definitivo para seu diagnóstico, que é essencialmente clínico e baseado na observação e acompanhamento da progressão dos sintomas ao longo do tempo. Esse processo pode levar anos e o diagnóstico tardio retarda o início do tratamento e agrava os sintomas, comprometendo a qualidade de vida dos pacientes [2,3].

Nesse contexto, a análise de marcha surge como um método alternativo para auxiliar no diagnóstico precoce de doenças neurodegenerativas [4,5]. Com o avanço da área de aprendizado de máquina, diferentes abordagens têm sido propostas para distinguir automaticamente indivíduos com ELA de controles saudáveis com base em dados de marcha [6]. No entanto, a maior parte desses trabalhos concentra-se exclusivamente no cenário ELA vs. Controle, sem abordar o diagnóstico diferencial em relação a outras doenças neurodegenerativas com manifestações motoras similares, como a Doença de Parkinson (DP) e a Doença de Huntington (DH). Essa distinção possui relevância clínica importante, dado que essas condições compartilham alterações de mobilidade que podem dificultar a identificação correta da doença na prática clínica.

Prabhu *et al.* (2020) [7] aplicaram a Análise de Quantificação de Recorrência (RQA) combinada com medidas estatísticas para extração de características (*features*) de sinais de marcha, utilizando Máquina de Vetores de Suporte (SVM) e Rede Neural Probabilística (*Probabilistic Neural Network*, PNN) na classificação binária entre sujeitos com ELA, DP e DH e controles saudáveis (CO). Para o cenário de ELA vs. CO, o SVM obteve a maior acurácia com 96,15%. Elden *et al.* (2018) [8] propuseram uma abordagem baseada na reconstrução do espaço de fase e na RQA aplicadas ao sinal de força de reação vertical do solo (VGRF), com a Análise de Componentes Principais (PCA) e SVM com *kernel* de função de base radial (SVM-RBF), avaliando os cenários de doenças neurodegenerativas (NDD) vs. CO, ELA vs. CO, DP vs. CO e DH vs. CO, com acurácias de 92,19%, 86,21%, 90,32% e 80,56%, respectivamente.

Felix *et al.* (2020) [9] propuseram um método automático para diagnóstico de ELA utilizando apenas um minuto da marcha da base de dados em doenças neurodegenerativas (*Gait in Neurodegenerative Disease Database*, GaitNDD), extraindo características estatísticas dos intervalos de passada, balanço e apoio para classificação binária ELA vs. CO. A árvore de decisão obteve o melhor resultado, com 96,6% de acurácia e 100% de sensibilidade. Bucci *et al.* (2025) [10] aplicaram um modelo *transformer encoder-only* diretamente sobre os sinais brutos de marcha da mesma base, também na tarefa ELA vs. CO, com separação de dados por indivíduo para evitar vazamento de dados, alcançando 92,47% de acurácia.

Diante desse cenário, este trabalho propõe uma abordagem de auxílio ao diagnóstico da ELA, a partir de características extraídas automaticamente a partir dos sinais brutos de marcha, sem depender da segmentação das fases temporais do ciclo e sem precisar utilizar os intervalos de passada, balanço e apoio como base para a extração de características. Além do cenário tradicional ELA vs. CO, são explorados múltiplos cenários de classificação binária envolvendo comparações com Parkinson e DH, contribuindo para a análise do diagnóstico diferencial entre doenças neurodegenerativas com manifestações motoras similares. Ademais, são avaliados diferentes métodos de seleção de características e de classificação, com estratégia de validação para evitar vazamento de dados.

O restante do trabalho está organizado da seguinte forma: na Seção 2, estão os materiais e métodos utilizados para a condução do estudo; nas Seções 3 e 4 estão, respectivamente, os resultados e a discussão sobre eles; por fim, as conclusões estão na Seção 5.

2 MÉTODOS

Os métodos utilizados neste trabalho são apresentados na Figura 1, sendo detalhados nas subseções seguintes.

Figura 1. Fluxograma da metodologia empregada no trabalho

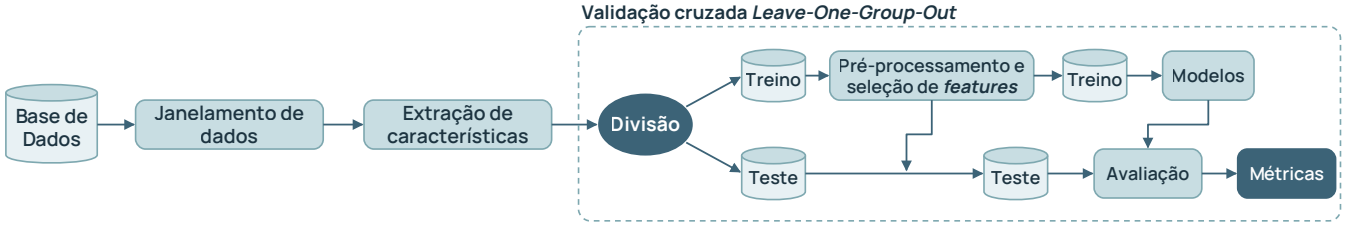

Fonte: Elaborado pelos autores (2026).

Tabela 1. Descrição demográfica dos participantes com média e desvio padrão

Tipo de Participante	Quantidade	Sexo	Velocidade (m/s)	Idade (anos)	Peso (kg)	Altura (m)
ELA	13	10M/3F	1,05 (0,22)	55,6 (12,8)	77,1 (21,1)	1,74 (0,10)
DP	15	10M/5F	1,00 (0,20)	66,8 (10,9)	75,1 (16,9)	1,87 (0,15)
DH	20	6M/14F	1,15 (0,35)	46,6 (12,6)	72,0 (17,0)	1,83 (0,11)
CO	16	2M/14F	1,35 (0,16)	39,3 (18,5)	66,8 (11,1)	1,83 (0,08)

Fonte: Elaborado pelos autores (2026).

2.1 Base de dados

Neste estudo, utilizou-se a base de dados *Gait in Neurodegenerative Disease Database* [11], disponibilizada pela plataforma PhysioNet [12] e publicada por Jeffrey M. Hausdorff em 2000. A base foi desenvolvida com o objetivo de investigar alterações dinâmicas da marcha associadas a doenças neurodegenerativas. Os dados foram coletados a partir de pacientes com doenças variadas, incluindo ELA, DP e DH. A base é composta por registros de 64 indivíduos, sendo 13 pacientes com ELA, 15 com DP, 20 com DH e 16 indivíduos saudáveis utilizados como grupo controle (CO).

A aquisição dos sinais foi realizada por meio de sensores resistivos sensíveis à força posicionados sob os pés dos participantes durante a caminhada, com taxa de amostragem de 300 Hz. Esses sensores registram de forma contínua a força exercida pelos pés contra o solo ao longo do ciclo da marcha, produzindo sinais temporais relacionados ao contato plantar. Durante a coleta, os participantes caminharam por cinco minutos, em seu ritmo habitual e sem auxílio, em um corredor de 77 metros, utilizando calçados instrumentados com sensores. Cada registro da base contém arquivos referentes aos sinais do pé esquerdo e direito, além de séries temporais derivadas contendo parâmetros da marcha. Entre esses parâmetros estão o tempo de passada (*stride interval*), o tempo de balanço (*swing interval*), o tempo de apoio (*stance interval*) e o tempo de duplo suporte (*double support interval*), expressos tanto em segundos quanto em porcentagem do ciclo da marcha. A GaitNDD é uma base de dados secundária, pública e disponibilizada de forma anonimizada por meio da plataforma PhysioNet. A coleta original dos dados foi conduzida pelos autores da base utilizando procedimento não invasivo e em conformidade com os aspectos éticos aplicáveis à pesquisa com seres humanos, incluindo o consentimento dos participantes, conforme descrito em Hausdorff *et al.* (2000) [11]. Assim, por utilizar exclusivamente dados públicos, secundários e sem possibilidade de identificação dos participantes, o presente estudo dispensou submissão e aprovação por Comitê de Ética em Pesquisa (CEP).

Além dos sinais de marcha, a base também disponibiliza informações clínicas e demográficas dos participantes, incluindo idade, sexo, altura, peso, velocidade de caminhada e medidas relacionadas à severidade ou duração da doença, conforme apresentado na Tabela 1.

2.2 Pré-processamento

O sinal bruto dos dados foi submetido a uma etapa de pré-processamento antes da extração de características, composta pela remoção do segmento inicial, janelamento e organização por sujeito. Nesta etapa, nenhum filtro ou normalização foi aplicado, de modo que as características foram extraídas diretamente do sinal bruto para preservar os padrões morfológicos originais e evitar que etapas de filtragem mascarem características discriminativas associadas às doenças.

Inicialmente, os sinais de marcha passaram por uma etapa de remoção dos primeiros 20 segundos de aquisição, visando eliminar instabilidades iniciais associadas ao início da caminhada e à adaptação do indivíduo ao processo de coleta. Em seguida, os sinais foram segmentados em janelas temporais fixas de 10 segundos, sem sobreposição, com o objetivo de transformar os sinais contínuos em múltiplas amostras independentes para treinamento dos modelos de aprendizado de máquina. Por fim, cada janela recebeu o identificador do paciente de origem, informação utilizada na etapa de validação para garantir que janelas de um mesmo sujeito não apareçam simultaneamente nos conjuntos de treino e teste. A Figura 2 ilustra o processo de janelamento aplicado aos sinais.

O presente estudo utiliza diretamente os sinais brutos pré-processados para extração automática de padrões relacionados ao movimento durante a caminhada. Essa abordagem permite explorar características associadas ao comportamento global do sinal, com o objetivo de representar padrões motores relacionados às alterações de marcha observadas na ELA e em outras doenças neurodegenerativas avaliadas.

Figura 2. Janelamento de dados de um paciente com ELA

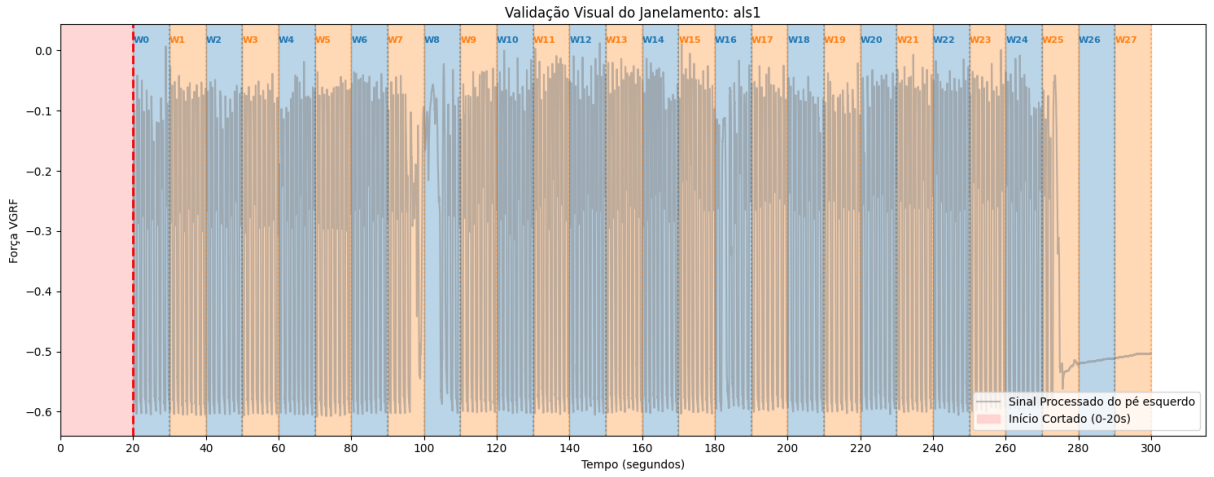

Fonte: Elaborado pelos autores (2026).

2.3 Extração de Características

A extração de características foi realizada utilizando a biblioteca tsfresh [13], empregada para análise automática de séries temporais. Foi utilizado o conjunto *"ComprehensiveFCParameters"*, utilizado para a geração automática de um conjunto extenso de descritores estatísticos, temporais e espectrais extraídos diretamente dos sinais brutos da marcha. Entre as características extraídas estão medidas estatísticas de primeira e segunda ordem, coeficientes de autocorrelação, métricas de entropia, coeficientes autorregressivos, medidas relacionadas à distribuição dos valores do sinal e atributos derivados do domínio da frequência. Essa abordagem permite representar diferentes aspectos do comportamento do sinal ao longo do tempo, por meio das diferentes características extraídas.

As características foram extraídas separadamente para os sinais correspondentes aos pés esquerdo e direito, incluindo informações relacionadas à dinâmica bilateral da marcha. Após a extração, características com apenas valores ausentes foram removidas, resultando em 1.566 características por janela. A redução adicional do espaço de características foi realizada na etapa subsequente de seleção de características.

2.4 Seleção de Características

Devido ao elevado número de características geradas, foram explorados diferentes métodos de seleção para reduzir o "mal da dimensionalidade" [14], além de eliminar atributos redundantes ou não informativos para melhorar a capacidade de generalização dos modelos. Foram avaliadas três estratégias de seleção, permitindo comparar abordagens baseadas na seleção manual, na relevância estatística e na importância para o classificador.

A seleção manual consistiu na definição de um subconjunto de 220 características, composto por métricas estatísticas e espectrais. Embora essa abordagem não dependa de otimização computacional, ela está sujeita à subjetividade na escolha dos atributos e pode não capturar padrões discriminativos presentes em características menos convencionais.

O *Recursive Feature Elimination* (RFE) é uma técnica de seleção iterativa que remove progressivamente as características menos relevantes com base na importância atribuída por um classificador de referência, repetindo o processo até atingir o número desejado de atributos [15]. Neste estudo, o RFE foi configurado para selecionar as 60 características mais relevantes e aplicado dentro de cada *fold* da validação cruzada, utilizando exclusivamente os dados de treino do *fold* corrente. Essa estratégia impede que informações do conjunto de teste influenciem a seleção, evitando vazamento de dados [16]. O número de características foi definido empiricamente.

O *Tsfresh Select* é um método de seleção estatística nativo da biblioteca tsfresh, baseado em testes de hipótese que avaliam a relevância de cada característica em relação à variável-alvo. A seleção é controlada pela taxa de falsas descobertas (*False Discovery Rate*), com nível de significância fixado em fdr_level = 0,001, e limitada a um máximo de 100 características. Além disso, assim como no RFE, a seleção foi realizada utilizando apenas os dados de treino de cada *fold* da validação cruzada.

A comparação entre diferentes estratégias de seleção de características possibilitou analisar o desempenho preditivo dos modelos e o impacto da redução do espaço de características na capacidade de generalização dos classificadores. Além disso, a utilização de subconjuntos menores de atributos contribui para a redução da complexidade computacional e para a potencial diminuição do sobreajuste em cenários de alta dimensionalidade [17].

Figura 3. Ilustração do processo de seleção de características e avaliação

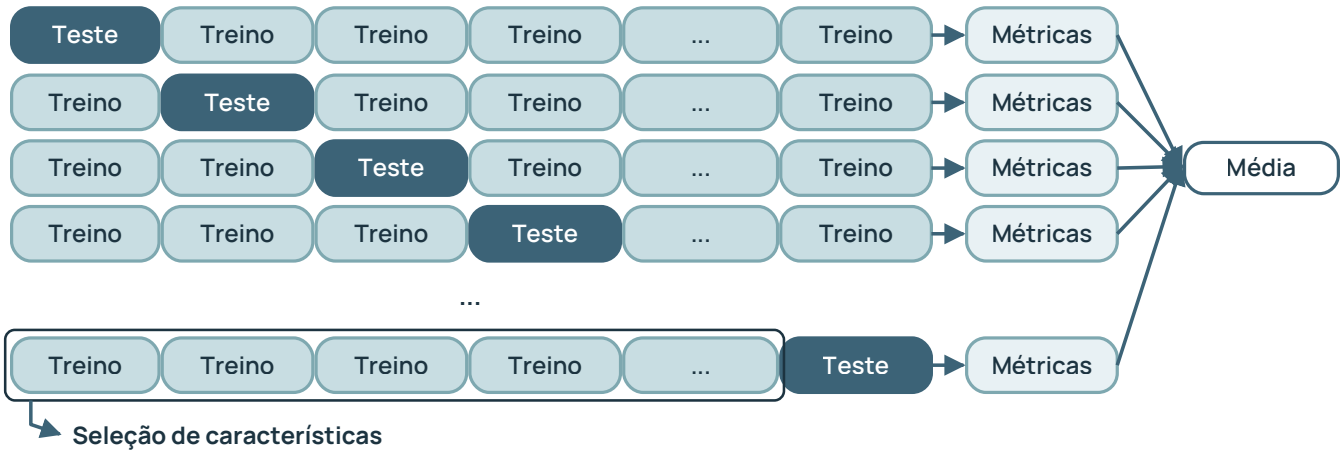

Fonte: Elaborado pelos autores (2026).

2.5 Classificação e Avaliação

Foram avaliados oito algoritmos de aprendizado de máquina para cada combinação de cenário e técnica de seleção de características: *SVM*, *XGBoost*, *LightGBM*, *Multilayer Perceptron* (MLP), *Random Forest*, *Decision Tree*, *Stochastic Gradient Descent* (SGD) e *Extra Trees*. Todos os classificadores foram utilizados com hiperparâmetros padrão, sem otimização adicional.

Foram definidos cinco cenários de classificação binária e multiclasse para avaliação do desempenho dos modelos: ELA versus Controle (ELA vs. CO), ELA versus Doença de Parkinson (ELA vs. DP), ELA versus Doença de Huntington (ELA vs. DH), ELA versus Parkinson e Huntington combinados (ELA vs. DP + DH), e ELA versus todos os demais grupos (ELA vs. CO + DP + DH). Esses cenários foram definidos com o objetivo de avaliar a separabilidade entre pacientes com ELA e indivíduos saudáveis e ELA de outras doenças neurodegenerativas com manifestações motoras similares.

A avaliação experimental foi conduzida utilizando validação cruzada *Leave-One-Group-Out Cross-Validation* (LOGO-CV), considerando cada paciente como um grupo independente [18]. Nessa estratégia, todas as janelas pertencentes a um mesmo indivíduo permanecem exclusivamente no conjunto de treino ou no conjunto de teste em cada *fold*, impedindo que diferentes segmentos do mesmo paciente sejam utilizados simultaneamente em ambos os conjuntos. Dessa forma, a avaliação é mais justa do ponto de vista clínico, reduzindo os riscos de sobreajuste associados à similaridade entre janelas do mesmo sujeito e evitando que os modelos aprendam características específicas dos indivíduos, em vez de padrões relacionados às doenças analisadas.

A imputação de valores ausentes e a normalização via *Z-Score* foram ajustadas exclusivamente com os dados de treino de cada *fold*, sendo posteriormente aplicadas ao conjunto de teste sem acesso às suas estatísticas. A integridade da separação entre treino e teste foi verificada por meio de checagens explícitas em cada *fold* da validação cruzada, interrompendo automaticamente a execução em caso de qualquer interseção entre pacientes dos dois conjuntos. Além disso, os métodos de seleção de características também foram aplicados exclusivamente aos dados de treino em cada *fold*, evitando vazamento de informação ao longo do *pipeline* experimental. A Figura 3 apresenta o fluxo geral do processo de validação utilizado neste estudo.

O desempenho dos modelos foi avaliado por meio das métricas de acurácia, precisão, *recall* e *F1-Score*, calculadas como a média dos valores obtidos em todos os *folds*. Essas métricas foram calculadas conforme apresentado nas equações abaixo,

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

$$\text{Precisão} = \frac{VP}{VP + FP} \quad \text{(b)}$$

$$\text{Recall} = \frac{VP}{VP + FN} \quad \text{(c)}$$

$$F1\text{-Score} = \frac{2 \cdot VP}{2 \cdot VP + FP + FN} \quad \text{(d)}$$

em que VP representa os verdadeiros positivos, VN os verdadeiros negativos, FP os falsos positivos e FN os falsos negativos. O código foi desenvolvido em Python e foi utilizada a biblioteca Scikit-Learn. Para cada cenário e técnica de seleção, foi reportado o resultado do classificador com melhor desempenho.

3 RESULTADOS

As Tabelas 2, 3 e 4 apresentam os melhores resultados obtidos para cada cenário de classificação investigado neste estudo, considerando diferentes estratégias de seleção de características: seleção manual, *RFE* e *Tsfresh Select*. Para cada cenário, são apresentados os melhores desempenhos entre os classificadores avaliados, considerando as métricas de acurácia, precisão, *recall*

Tabela 2. Melhores resultados obtidos com seleção manual

Cenário	Modelo	*Características*	Acurácia	Precisão	Recall	F1-Score
ELA vs. CO	XGBoost	220	92,00	92,85	91,33	91,79
ELA vs. DP	MLP	220	87,88	88,00	87,65	87,77
ELA vs. DH	LightGBM	220	89,18	89,94	87,42	88,34
ELA vs. (DP + DH)	Decision Tree	220	89,88	87,23	87,10	87,17
ELA vs. (CO + DP + DH)	SGD	220	91,18	87,59	84,23	85,76

Fonte: Elaborado pelos autores (2026).

Tabela 3. Melhores resultados obtidos com RFE

Cenário	Modelo	*Características*	Acurácia	Precisão	Recall	F1-Score
ELA vs. CO	SVM	60	96,06	95,91	96,25	96,03
ELA vs. DP	MLP	60	84,82	84,90	85,06	84,81
ELA vs. DH	XGBoost	60	93,51	93,13	93,30	93,21
ELA vs. (DP + DH)	Random Forest	60	88,32	86,23	83,36	84,62
ELA vs. (CO + DP + DH)	XGBoost	60	88,00	82,45	78,76	80,38

Fonte: Elaborado pelos autores (2026).

Tabela 4. Melhores resultados obtidos com Tsfresh Select

Cenário	Modelo	*Características*	Acurácia	Precisão	Recall	F1-Score
ELA vs. CO	Extra Trees	100	87,32	87,74	86,70	87,03
ELA vs. DP	SVM	100	87,12	87,85	87,66	87,11
ELA vs. DH	XGBoost	100	95,13	94,64	95,31	94,94
ELA vs. (DP + DH)	LightGBM	100	88,24	85,35	84,60	84,96
ELA vs. (CO + DP + DH)	SGD	100	87,44	80,34	82,09	81,16

Fonte: Elaborado pelos autores (2026).

e *F1-Score*.

Os resultados demonstram que os modelos foram capazes de distinguir indivíduos com ELA tanto de controles saudáveis quanto de indivíduos com outras doenças neurodegenerativas associadas a alterações motoras e de marcha. Além disso, o desempenho variou conforme o método de seleção de características e o cenário clínico analisado. Na seleção manual, com 220 características, os resultados apresentaram desempenho consistente em todos os cenários avaliados. O melhor resultado foi observado em ELA vs. CO, com acurácia de 92,00% utilizando XGBoost, seguido do cenário ELA vs. (CO + DP + DH), que alcançou 91,18% com SGD. Os cenários envolvendo doenças neurodegenerativas apresentaram desempenho ligeiramente inferior, com 89,18% para ELA vs. DH e 87,88% para ELA vs. DP.

Com a aplicação do RFE, utilizando apenas 60 características, obteve-se o melhor resultado do estudo no cenário ELA vs. CO, alcançando 96,06% de acurácia e *F1-Score* de 96,03% com SVM. O cenário ELA vs. DH também apresentou desempenho elevado, atingindo 93,51% com XGBoost. Já o cenário ELA vs. DP obteve 84,82% com MLP, o que configura o menor desempenho entre os cenários binários avaliados. Nos cenários mais complexos, envolvendo múltiplas classes agrupadas, os modelos mantiveram desempenho consistente, com acurácia de 88,32% em ELA vs. (DP + DH) e 88,00% em ELA vs. (CO + DP + DH).

Os resultados obtidos com Tsfresh Select, utilizando 100 características, também demonstraram desempenho competitivo. O melhor resultado foi observado em ELA vs. DH, com 95,13% de acurácia e *F1-Score* de 94,94% utilizando XGBoost. Os demais cenários apresentaram acurácias variando entre 87,12% e 88,24%, indicando comportamento mais homogêneo entre os classificadores avaliados. Esses achados indicam que o método RFE apresentou a melhor relação entre redução de dimensionalidade e desempenho preditivo, alcançando valores de acurácia e *F1-Score* elevados com o menor número de características selecionadas. Além disso, os cenários envolvendo ELA versus DH apresentaram desempenho superior aos cenários envolvendo Parkinson, sugerindo maior similaridade entre os padrões de marcha da ELA e da Doença de Parkinson.

4 DISCUSSÃO

Os resultados obtidos demonstram o potencial da análise de marcha, associada a técnicas de aprendizado de máquina, para auxiliar no diagnóstico da ELA. No

cenário ELA vs. CO, o melhor desempenho foi de 96,06% de acurácia com RFE e SVM, resultado comparável ao reportado por Felix *et al.* (2020) [9], que alcançaram 96,6% utilizando Árvore de Decisão com características estatísticas extraídas das fases temporais da marcha, e por Prabhu *et al.* (2020) [7], que obtiveram 96,15% com SVM a partir de características de RQA. Valores ligeiramente inferiores foram reportados por Elden *et al.* (2018) [8], com 86,21% no mesmo cenário, e por Bucci *et al.* (2025) [10], com 92,47% utilizando um modelo *transformer*. Esses resultados indicam que a abordagem proposta é competitiva em relação ao estado da arte para a tarefa de distinguir indivíduos com ELA de controles saudáveis, mesmo operando diretamente sobre o sinal bruto de marcha, sem depender da segmentação das fases temporais do ciclo. Vale considerar que, embora a base de dados GaitNDD seja amplamente utilizada na literatura para avaliação de métodos de classificação de doenças neurodegenerativas, seu número reduzido de participantes (64 indivíduos) constitui uma limitação do estudo, restringindo a plena generalização dos resultados para populações mais amplas e heterogêneas.

Este estudo também amplia a análise presente na literatura ao explorar cenários clínicos além do tradicional ELA vs. CO, comparando indivíduos com ELA a pacientes com Parkinson e Huntington, doenças que também afetam a mobilidade e compartilham alterações motoras com a ELA, tornando o diagnóstico diferencial mais complexo na prática clínica. Os resultados aqui obtidos nos cenários ELA vs. DH (até 95,13%) e ELA vs. DP (até 87,88%) indicam que padrões extraídos do sinal bruto da marcha possuem capacidade discriminativa relevante também nesses contextos. A maior dificuldade observada no cenário ELA vs. DP sugere maior similaridade entre os padrões de marcha dessas duas doenças em comparação com Huntington.

Nos cenários multiclasse, os modelos mantiveram desempenho elevado mesmo diante de maior heterogeneidade clínica, com acurácias entre 87,44% e 91,18%. Além disso, a exploração de diferentes métodos de seleção de características demonstrou que o RFE apresentou melhor equilíbrio entre desempenho e redução de dimensionalidade, alcançando resultados elevados com apenas 60 características e contribuindo para a capacidade de generalização dos modelos.

Dessa forma, os achados deste estudo contribuem para a literatura ao demonstrar que características extraídas diretamente do sinal bruto de marcha, aliadas a técnicas adequadas de seleção e aprendizado de máquina, podem auxiliar na identificação de ELA frente a controles saudáveis, e em cenários de diagnóstico diferencial envolvendo outras doenças neurodegenerativas com manifestações motoras similares.

5 CONCLUSÕES

Este estudo apresentou uma abordagem de auxílio ao diagnóstico da Esclerose Lateral Amiotrófica, utilizando características extraídas automaticamente a partir de sinais brutos de marcha, associadas a técnicas de aprendizado de máquina. Diferentemente de abordagens dependentes da segmentação do ciclo da marcha, o método proposto opera diretamente sobre o sinal bruto, permitindo a extração automática de padrões discriminativos.

Os resultados demonstraram que os modelos foram capazes de distinguir indivíduos com ELA tanto de controles saudáveis quanto de pacientes com Doença de Parkinson e Doença de Huntington, alcançando desempenhos competitivos nos diferentes cenários avaliados. Entre as estratégias de seleção de características analisadas, o RFE apresentou o melhor equilíbrio entre a redução da dimensionalidade e o desempenho preditivo.

Além disso, a utilização de validação baseada em grupos contribuiu para uma avaliação mais justa e clinicamente coerente, reduzindo os riscos de vazamento de dados e de sobreajuste. Dessa forma, os achados indicam que a análise automática de sinais de marcha possui potencial para auxiliar no diagnóstico da ELA e em cenários de diagnóstico diferencial envolvendo outras doenças neurodegenerativas, podendo futuramente contribuir como ferramenta de apoio à decisão clínica, inclusive no contexto do Sistema Único de Saúde (SUS), em que o diagnóstico precoce pode favorecer o encaminhamento mais oportuno para avaliação especializada. Como trabalhos futuros, pretende-se investigar estratégias de otimização de hiperparâmetros e métodos de interpretabilidade de modelos.

Contribuição dos autores. Breno Yuri Chaves da Silva contribuiu para a concepção e delineamento do estudo, desenvolvimento de software, elaboração de figuras e redação da versão inicial do manuscrito. Ana Luísa de Bastos Chagas contribuiu para a validação, análise e interpretação dos dados e redação da versão inicial do manuscrito. Solange da Silva contribuiu para supervisão da pesquisa e revisão crítica do manuscrito. Marcos Lajovic Carneiro contribuiu para a análise e interpretação dos resultados e revisão crítica do manuscrito. Fabrizzio Soares contribuiu para a análise e interpretação dos resultados e revisão crítica do manuscrito. Juliana Paula Felix contribuiu para a concepção e o delineamento do estudo, definição da metodologia, análise formal, supervisão da pesquisa e revisão crítica do manuscrito. Todos os autores leram e aprovaram a versão final do manuscrito.

Agradecimentos. Este 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. Esta pesquisa não recebeu financiamento externo.

Disponibilidade de dados e materiais. Este estudo utilizou um conjunto de dados público, denominado Gait in Neurodegenerative Disease Database, disponibilizado no repositório PhysioNet. O conjunto de dados está disponível em: https://physionet.org/content/gaitndd/1.0.0/.

Conflitos de interesse. Os autores declaram não possuir conflitos de interesse.

Declaração de uso de IA. A ferramenta OpenAI ChatGPT foi utilizada unicamente para auxiliar na revisão e otimização dos scripts de código desenvolvidos para este trabalho. O uso da tecnologia restringiu-se à verificação da sintaxe computacional, não influenciando a escrita do texto, a análise dos dados ou a formulação dos resultados e conclusões apresentados.

REFERÊNCIAS

1. Berman T, Bayati A. What are Neurodegenerative Diseases and How Do They Affect the Brain? Front. Young Minds. 2018;6:70. doi: https://doi.org/10.3389/frym.2018.00070
2. Richards D, Morren JA, Pioro EP. Time to diagnosis and factors affecting diagnostic delay in amyotrophic lateral sclerosis. J Neurol Sci. 2020;417:117054. doi: https://doi.org/10.1016/j.jns.2020.117054
3. Falcão de Campos C, Gromicho M, Uysal H, Grosskreutz J, Kuzma-Kozakiewicz M, Oliveira Santos M, et al. Trends in the diagnostic delay and pathway for amyotrophic lateral sclerosis patients across different countries. Front Neurol. 2022;13:1064619. doi: https://doi.org/10.3389/fneur.2022.1064619
4. Nam Nguyen QD, Liu AB, Lin CW. Development of a Neurodegenerative Disease Gait Classification Algorithm Using Multiscale Sample Entropy and Machine Learning Classifiers. Entropy (Basel). 2020;22(12):1340. doi: https://doi.org/10.3390/e22121340
5. Liu AB, Lin CW. Multiscale Approximate Entropy for Gait Analysis in Patients with Neurodegenerative Diseases. Entropy. 2019;21(10):934. doi: https://doi.org/10.3390/e21100934
6. Fernandes F, Barbalho I, Barros D, Valentim R, Teixeira C, Henriques J, et al. Biomedical signals and machine learning in amyotrophic lateral sclerosis: a systematic review. Biomed Eng Online. 2021;20(1):61. doi: https://doi.org/10.1186/s12938-021-00896-2
7. Prabhu P, Karunakar AK, Anitha H, Pradhan N. Classification of gait signals into different neurodegenerative diseases using statistical analysis and recurrence quantification analysis. Pattern Recognition Letters. 2020;139:10-6. doi: https://doi.org/10.1016/j.patrec.2018.05.006
8. Elden RH, Al-Atabany W, Ghoneim VF. Gait Variability Analysis in Neurodegenerative Diseases Using Nonlinear Dynamical Modelling. In: 2018 9th Cairo International Biomedical Engineering Conference (CIBEC). [s.l.]: IEEE; 2018. p. 41-4. doi: https://doi.org/10.1109/cibec.2018.8641835
9. Felix JP, Nascimento HAD, Guimaraes NN, Pires EO, Vieira GS, Alencar WS. An Effective and Automatic Method to Aid the Diagnosis of Amyotrophic Lateral Sclerosis Using One Minute of Gait Signal. In: 2020 IEEE International Conference on Bioinformatics and Biomedicine (BIBM). [s.l.]: IEEE; 2020. p. 2745-51. doi: https://doi.org/10.1109/bibm49941.2020.9313308
10. Bucci GFFB, Chagas ALB, Lobo PLS, Nascimento HAD, Soares F, Felix J. Modelo Baseado em Transformer para Auxiliar no Diagnóstico de Esclerose Lateral Amiotrófica a partir da Marcha. In: Anais da XIII Escola Regional de Informática de Goiás (ERI-GO 2025). [s.l.]: Sociedade Brasileira de Computação; 2025. p. 205-14. doi: https://doi.org/10.5753/erigo.2025.17124
11. Hausdorff JM, Lertratanakul A, Cudkowicz ME, Peterson AL, Kaliton D, Goldberger AL. Gait in Neurodegenerative Disease Database [Internet]. Versão 1.0.0. PhysioNet; 2000 [citado 18 out 2026]. Disponível em: https://physionet.org/content/gaitndd/1.0.0/
12. Goldberger AL, Amaral LA, Glass L, Hausdorff JM, Ivanov PC, Mark RG, et al. PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals. Circulation. 2000;101(23):E215-20. doi: https://doi.org/10.1161/01.cir.101.23.e215
13. Christ M, Braun N, Neuffer J, Kempa-Liehr AW. Time Series FeatuRe Extraction on basis of Scalable Hypothesis tests (tsfresh – A Python package). Neurocomputing. 2018;307:72-7. doi: https://doi.org/10.1016/j.neucom.2018.03.067
14. Verleysen M, François D. The Curse of Dimensionality in Data Mining and Time Series Prediction. In: Lecture Notes in Computer Science. Berlin, Heidelberg: Springer Berlin Heidelberg; 2005. p. 758-70. doi: https://doi.org/10.1007/11494669_93
15. Guyon I, Weston J, Barnhill S, Vapnik V. Gene Selection for Cancer Classification using Support Vector Machines. Machine Learning. 2002;46(1-3):389-422. doi: https://doi.org/10.1023/a:1012487302797

16. Kaufman S, Rosset S, Perlich C, Stitelman O. Leakage in data mining. ACM Trans. Knowl. Discov. Data. 2012;6(4):1-21. doi: https://doi.org/10.1145/2382577.2382579

17. Cawley GC, Talbot NLC. On over-fitting in model selection and subsequent selection bias in performance evaluation. J Mach Learn Res. 2010 Aug;11:2079-2107

18. Kunjan S, Grummett TS, Pope KJ, Powers DMW, Fitzgibbon SP, Bastiampillai T, et al. The Necessity of Leave One Subject Out (LOSO) Cross Validation for EEG Disease Diagnosis. In: Lecture Notes in Computer Science. Cham: Springer International Publishing; 2021. p. 558-67. doi: https://doi.org/10.1007/978-3-030-86993-9_50

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