



## ANÁLISE E PREDIÇÃO DA DOENÇA DE PARKINSON: UMA ABORDAGEM DE MACHINE LEARNING VIA REDES NEURAS ARTIFICIAIS

Alexandre Lima De Oliveira<sup>1</sup>  
Jorge Antônio Félix Da Silva<sup>2</sup>  
Ivina Lorena Oliveira Moura<sup>3</sup>  
Antonio Alisson Pessoa Guimarães<sup>4</sup>

### RESUMO

A doença de Parkinson é um distúrbio neurológico crônico e progressivo que afeta principalmente o sistema motor e atualmente não tem cura. Caracteriza-se pela degeneração progressiva de células nervosas no cérebro, especialmente na região conhecida como substância negra, que é responsável pela produção de dopamina. A dopamina é um neurotransmissor crucial para o controle dos movimentos musculares e outras funções cognitivas. Os principais sintomas da doença de Parkinson incluem tremores em repouso, rigidez muscular, bradicinesia, instabilidade postural e alterações na marcha e fala, além dos sintomas não motores. Devido à natureza progressiva da doença, há necessidade clínica de um contínuo monitoramento dos sintomas motores. No entanto, para realização desta tarefa, o médico, normalmente, não detém informações precisas sobre os sintomas que afetam a qualidade de vida do paciente, principalmente quando este ainda não está diagnosticado ou até mesmo quando está em um nível severo da doença. Neste contexto, alguns métodos de inteligência computacional baseados em Machine Learning têm sido aplicados como ferramenta auxiliar no diagnóstico da DP e, paralelamente, na quantificação da intensidade da doença. Assim, este projeto de pesquisa objetiva desenvolver e implementar um classificador computacional para o auxílio no diagnóstico de Doença de Parkinson com especificação do estágio da doença na escala de Hoehn & Yahr, usando Redes Neurais Artificiais para essa classificação.

**Palavras-chave:** Doença de Parkinson; Machine learning; Classificação.

Universidade da Integração Internacional da Lusofonia Afro-Brasileira, Campus do Palmares, Discente,  
alexandre.computacao@aluno.unilab.edu.br<sup>1</sup>

Universidade da Integração Internacional da Lusofonia Afro-Brasileira, Campus do Palmares, Discente,  
jorgefelix@aluno.unilab.edu.br<sup>2</sup>

Universidade da Integração Internacional da Lusofonia Afro-Brasileira, Campus do Palmares, Discente,  
ivinalorena@aluno.unilab.edu.br<sup>3</sup>

Universidade da Integração Internacional da Lusofonia Afro-Brasileira, Campus do Palmares, Docente, alisson@unilab.edu.br<sup>4</sup>



## INTRODUÇÃO

Descrita pela primeira vez pelo médico britânico James Parkinson em 1817,

a Doença de Parkinson (DP) é considerada uma enfermidade neurodegenerativa, progressiva, caracterizada pela presença de disfunção monoaminérgica múltipla, incluindo o déficit de sistemas dopaminérgicos, colinérgicos, serotoninérgicos e noradrenérgicos (TEIVE, 2005).

Os principais sintomas motores incluem tremores (geralmente em repouso), rigidez muscular, bradicinesia (lentidão nos movimentos) e instabilidade postural (problemas de equilíbrio). Outros sinais da DP são os chamados não-motores, como os distúrbios do sono, a disfunção cognitiva e depressão.

Um paciente com Doença de Parkinson enfrenta diversos desafios, tanto físicos quanto emocionais, que impactam profundamente sua qualidade de vida. Esses desafios são amplificados pela natureza progressiva e multifacetada da doença, e a dificuldade em lidar com os sintomas decorre tanto das limitações físicas quanto dos aspectos psicológicos e sociais associados.

Pensando na saúde e qualidade de vida dos pacientes, o ideal é ter diagnósticos assertivos e melhor tê-los nos estágios iniciais da doença. Isso se torna um grande desafio porque o diagnóstico é primariamente clínico, ou seja, não há testes definitivos para a detecção da doença. Os sintomas são variáveis e similares a outras condições neurodegenerativas e, nos casos em que o progresso da DP é lento, podem ocorrer diagnósticos tardios.

Como a DP não tem cura atualmente, é de extrema importância o monitoramento contínuo dos doentes. A monitoria contínua permite ajustar o tratamento conforme a necessidade, garantindo melhor qualidade de vida. Os medicamentos usados no tratamento, como a levodopa, podem perder eficácia com o tempo, e é preciso identificar essas mudanças e ajustar as dosagens ou terapias. Problemas não motores, como depressão, demência ou distúrbios do sono, podem se desenvolver e afetar significativamente a qualidade de vida. O acompanhamento frequente facilita a identificação precoce e o tratamento dessas complicações. No entanto, para a realização desta tarefa, o médico normalmente não detém informações precisas sobre os sintomas (por não existir testes definitivos ou marcadores biológicos confiáveis), restando ao profissional apenas dados subjetivos e incompletos dos pacientes.

Neste contexto, alguns métodos de inteligência computacional baseados em Machine Learning (ML) têm sido aplicados como ferramenta auxiliar no diagnóstico da DP e, paralelamente, na quantificação da intensidade da doença utilizando, por exemplo, a escala de Hoehn & Yahr.

As tecnologias emergentes na medicina, especialmente os métodos de ML, têm desempenhado um papel crucial na melhoria do diagnóstico de doenças complexas, como a Doença de Parkinson (DP). O ML é altamente adequado para enfrentar as lacunas no diagnóstico da DP, pois processa grandes volumes de dados clínicos e sinais biométricos de forma eficiente. Ao identificar padrões complexos e sutis que podem não ser detectáveis pelo olhar clínico tradicional, esses algoritmos servem como um classificador computacional, baseado em Redes Neurais Artificiais, que é utilizado como ferramenta auxiliar no diagnóstico da DP e na quantificação da intensidade da doença.

## METODOLOGIA

Para desenvolver um sistema auxiliar na detecção de distúrbios de Parkinson por meio da análise da voz dos


pacientes, a metodologia empregada abrangeu desde a seleção e processamento de características vocais até a implementação de um modelo de Redes Neurais Artificiais (RNA). O conjunto de dados utilizado foi o Parkinson Speech Dataset with Multiple Types of Sound Recordings, disponível no UCI Machine Learning Repository. Esses dados pertencem a 20 pacientes diagnosticados com Parkinson (6 mulheres e 14 homens) e 20 pessoas saudáveis (10 homens e 10 mulheres), que recorreram ao Departamento de Neurologia da Faculdade de Medicina de Cerrahpasa, da Universidade de Istanbul. O conjunto de dados contém gravações de 26 amostras de voz, incluindo vogais sustentadas, números, palavras e frases curtas, das quais se extraíram 26 características lineares de cada amostra.

A implementação da RNA foi realizada utilizando a biblioteca Keras, escrita em Python, que opera sobre o TensorFlow, uma biblioteca de aprendizado de máquina. Inicialmente, dividiu-se a base de dados aleatoriamente, utilizando 67% para treinamento da RNA e 33% para teste e validação. O objetivo foi realizar a classificação binária dos pacientes (com Parkinson ou saudáveis).

O otimizador Adam foi escolhido por sua capacidade de convergir rapidamente e de forma confiável, enquanto a função de perda escolhida foi a Mean Squared Error (MSE), que quantifica a diferença entre as previsões do modelo e os valores reais esperados. O objetivo era minimizar essa diferença. A função de ativação utilizada nas camadas foi ReLU nas primeiras camadas e sigmoid na camada final.

Os primeiros testes usaram uma RNA com três camadas (676, 676 e 1 neurônios, respectivamente) e o batch-size de 4, com 30 épocas. No entanto, o modelo não apresentou aprendizado adequado, com gráficos de perda e acurácia constantes. Entre os 14 pacientes da base de teste, o modelo previu que nenhum estava doente, quando 8 deles realmente estavam, resultando em apenas 6 predições corretas.

## GRÁFICO DE MÉTRICAS 1



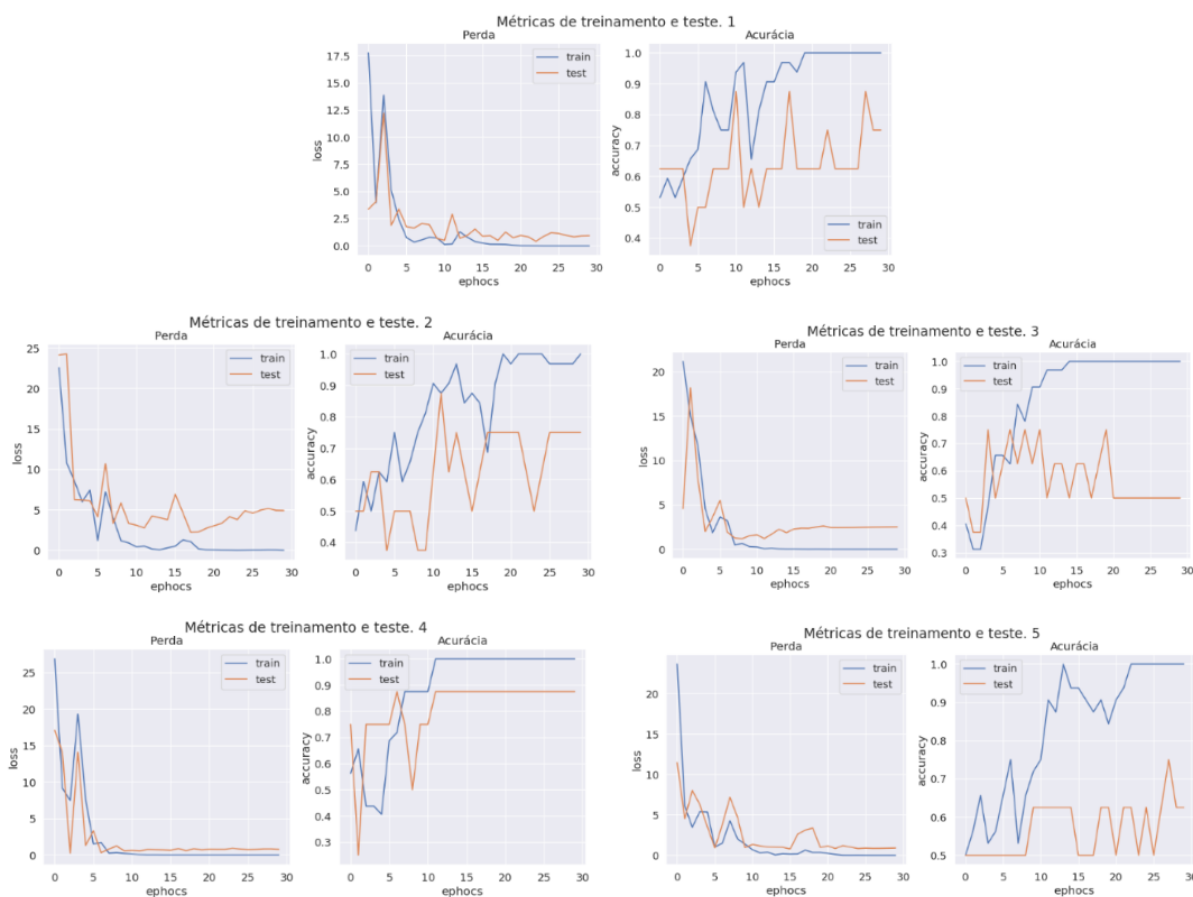
Diante disso, ajustou-se a função de perda para Binary Cross Entropy, mais adequada para classificações binárias, e aumentou-se o número de camadas para seis (com 676, 676, 256, 128, 64 e 1 neurônios,



respectivamente). Esses ajustes resultaram em uma melhora considerável nos gráficos de métricas, embora a perda ainda fosse de 4.1013 e a acurácia de 42,86%. O modelo atingiu 100% de acurácia nos dados de treinamento, mas apenas 45% nos dados de teste, indicando um problema de overfitting. Para mitigar esse problema, foi implementado o método de treinamento k-fold, dividindo-se a base de dados em cinco folds, alternando entre treino e teste.

Com o modelo k-fold, o melhor fold atingiu 0.7913 de perda e 87,5% de acurácia. Em dois folds, a acurácia foi de 75%, e nos demais, valores abaixo disso. A RNA atingiu seu melhor desempenho com seis camadas (676, 676, 430, 350, 64 e 1 neurônios nas respectivas camadas).

## Gráfico de métricas do teste k-fold



Mantendo o método k-fold, foram realizados novos testes com variações no número de camadas e na quantidade de épocas. Contudo, o melhor resultado não ultrapassou 87,5% de acurácia. O número ideal de camadas foi encontrado com seis camadas (676, 676, 430, 350, 64 e 1 neurônios nas respectivas camadas).



## RESULTADOS E DISCUSSÃO


O último teste teve as melhores métricas, dois folders alcançaram 87,5% de acurácia, um deles com 0.3257 e outro com 0.6970 de perda.

Outros dois folders tiveram 75% de acurácia com perdas mais altas: 3.5450 e 2.5729.

O último fold teve a pior acurácia dos 5, alcançando apenas 50% e perda igual a 3.0329.

Os gráficos de treinamento desse modelo foram melhores que os dos testes anteriores e este foi o único a alcançar duas acurácias de 87,5%. A matriz de confusão foi feita avaliando o modelo com todos os 40 pacientes:

Matriz para o melhor modelo. Foi submetido ao melhor modelo a base de dados inteira.



Embora a melhor precisão ser 87,5% nos testes realizados por fold, a matriz de confusão apresenta uma precisão maior(95%) isso pode ser explicado pelo maior número de registros para validação, visto que foram avaliados os 40 pacientes para a confecção da matriz de confusão, e também pelo fato de os registros que estão sendo avaliados já serviram para treinar o modelo e pode ser que a rede neural tenha apenas “decorado” os dados de entrada.



## CONCLUSÕES

Os resultados ainda precisam ser melhorados 87,5% de acerto, neste caso, ainda não é muito confiável por se tratar de um assunto delicado que exige uma taxa de acertos mais alta.

O modelo provavelmente se tornaria mais confiável caso a base de dados fosse maior para que a rede neural possa treinar por mais tempo e com mais registros, isso diminuiria também o risco de o modelo se ajustar aos dados de treinamento.

## AGRADECIMENTOS

Gostaria de expressar meu agradecimento ao professor Alisson Guimarães pela orientação e suporte durante o desenvolvimento deste trabalho. Também agradeço aos colegas Ivina e Jorge pelo constante incentivo e às instituições UNILAB e FUNCAP pelo suporte técnico e financeiro.

## REFERÊNCIAS

- BERUS, L. et al. Classifying Parkinson's Disease Based on Acoustic Measures Using Artificial Neural Networks, *Sensors*, v. 19, n. 1, p. 1-15, 2019. CASTRO, A. N.
- BLOEM, Bastiaan R; OKUN, Michael S; KLEIN, Christine. Parkinson's disease. *The Lancet*, [s. l.], 12 jun. 2021.
- DOWNEY, Allen B. *Think Python*. 2. ed. atual. [S. l.]: O'Reilly Media., 2015.
- TEIVE, H. A. Etiopatogenia da Doença de Parkinson. *Revista Neurociências*, [S. l.], v. 13, n. 4, p. 201-214, 2005.