



APLICAÇÃO DE MACHINE LEARNING NA DETECÇÃO DA DOENÇA DE PARKINSON A PARTIR DE SINAIS DE VOZ

Jorge Antonio Félix Da Silva¹
Ivina Lorena Oliveira Moura²
Antonio Alisson Pessoa Guimaraes³

RESUMO

A doença de Parkinson (DP) é uma doença neurodegenerativa crônica que afeta o sistema nervoso central, em particular, as áreas do cérebro responsáveis pelo controle do movimento. Os principais sintomas da doença de Parkinson incluem: Tremores, rigidez muscular e bradicinesia. Além desses sintomas motores, a DP pode causar uma série de outros sintomas não motores, como depressão, ansiedade, distúrbios do sono e problemas cognitivos. A DP é uma condição crônica que progride ao longo do tempo, e o tratamento visa melhorar a qualidade de vida dos pacientes e controlar os sintomas da melhor maneira possível. Diante disso, é notório que o diagnóstico precoce é de suma importância para fazer um tratamento eficaz e retardar a progressão da DP. Neste sentido, objetiva-se desenvolver um classificador computacional baseado na Regressão Logística Regularizada para auxiliar os médicos neurologistas no diagnóstico da Doença de Parkinson. O modelo será treinado com base em uma ampla base de dados pública, contendo características extraídas de 40 amostras de voz de pacientes normais e parkinsonianos. Promissoramente, O classificador proposto pode servir como uma ferramenta para o diagnóstico da DP, cujos resultados tiveram desempenhos satisfatórios.

Palavras-chave: Machine Learning;; Diagnóstico Médico; Classificação;.

Universidade da Integração Internacional da Lusofonia Afro-Brasileira, INSTITUTO DE ENGENHARIAS E DESENVOLVIMENTO SUSTENTÁVEL, Discente, jorgefelix@aluno.unilab.edu.br¹

Universidade da Integração Internacional da Lusofonia Afro-Brasileira, INSTITUTO DE ENGENHARIAS E DESENVOLVIMENTO SUSTENTÁVEL, Discente, ivinalorena@aluno.unilab.edu.br²

Universidade da Integração Internacional da Lusofonia Afro-Brasileira, INSTITUTO DE ENGENHARIAS E DESENVOLVIMENTO SUSTENTÁVEL, Docente, alisson@unilab.edu.br³

INTRODUÇÃO

A doença de Parkinson (DP) é uma condição neurodegenerativa crônica que afeta o sistema nervoso central, notadamente as áreas do cérebro responsáveis pelo controle do movimento. Caracterizada por sintomas como tremores, rigidez muscular e bradicinesia, a DP também pode manifestar sintomas não motores, como depressão, ansiedade, distúrbios do sono e problemas cognitivos. Devido à natureza progressiva da doença, o diagnóstico precoce desempenha um papel crucial na gestão eficaz e na desaceleração de sua progressão.

Este trabalho se propõe a desenvolver um classificador computacional baseado na Regressão Logística Regularizada para auxiliar médicos neurologistas no diagnóstico da Doença de Parkinson. A abordagem se concentra na análise de características vocais extraídas de amostras de voz de pacientes com e sem Parkinson, utilizando um conjunto de dados públicos contendo gravações de voz de 40 indivíduos. A intenção é criar uma ferramenta que possa auxiliar na identificação da doença com base nessas características vocais, simplificando o processo de diagnóstico clínico.

O presente estudo envolveu diversas etapas, desde o tratamento e seleção das características vocais mais relevantes até o treinamento e avaliação do modelo resultante. Utilizou-se a Regressão Logística Regularizada como algoritmo de classificação binária, treinando o modelo com base nos dados de voz coletados dos pacientes. A metodologia adotada incluiu a análise das métricas de desempenho do modelo, como precisão, recall e F1-score, além da construção de uma matriz de confusão para avaliação.

Este trabalho é de suma importância no contexto médico, pois busca fornecer aos profissionais de saúde uma ferramenta adicional para apoiar o diagnóstico da DP. Ao analisar as características vocais, o modelo proposto pode contribuir para identificar a doença em estágios iniciais, permitindo uma intervenção médica mais eficaz e melhorando a qualidade de vida dos pacientes afetados pela DP.

METODOLOGIA

Para desenvolver um sistema auxiliar para a detecção de distúrbios de Parkinson através da análise da voz dos pacientes, adotamos uma metodologia que envolveu várias etapas, desde a seleção e processamento das características vocais mais relevantes até o treinamento e a avaliação do desempenho do modelo resultante. Para abordar essa questão, escolhemos utilizar um algoritmo de Regressão Logística Regularizada, que é uma técnica supervisionada de classificação binária.

De acordo com Castro e Ferrari (2016), a mineração de dados envolve a análise de conjuntos de dados para descobrir padrões e informações úteis. Nossa metodologia de detecção de distúrbios de Parkinson por meio da análise da voz dos pacientes se baseia em conceitos de mineração de dados, incluindo a seleção de características relevantes e a aplicação de algoritmos de classificação.

O algoritmo de classificação proposto aprende com um conjunto de dados previamente rotulados, adquirindo a capacidade de prever o resultado para novos dados com base no conhecimento adquirido. Inicialmente, realizamos o tratamento dos dados públicos disponíveis no conjunto de dados "Parkinson Speech Dataset with Multiple Types of Sound Recordings" da UCI Machine Learning Repository. Esses dados incluíam gravações de voz de 20 pacientes diagnosticados com Parkinson (6 mulheres e 14 homens) e 20 pessoas saudáveis (10 homens e 10 mulheres) que foram atendidos no Departamento de Neurologia da Faculdade de Medicina de Cerrahpasa, na Universidade de Istambul.

Basicamente, o conjunto de dados é composto por uma matriz de valores onde cada paciente pronunciou as 26 letras do alfabeto, e cada letra possui 26 características que são elas por exemplo: jitter, shimmer, Passo mediano, passo médio e entre outras. Diante dos 26 atributos, considerou-se apenas 6 tipos de sinais de voz, sendo estes os mais correlacionados com a classificação diagnóstica do paciente.

Para identificar distúrbios de Parkinson, começamos selecionando cuidadosamente as características de voz mais relevantes, levando em consideração sua associação com o diagnóstico da doença. Essas características

foram escolhidas com base em informações de pacientes previamente diagnosticados com Parkinson.

Isenkul et al. (2014) propuseram um teste aprimorado usando uma tablet gráfica digitalizada para monitorar a doença de Parkinson. Embora nossa metodologia se concentre na análise da voz, inspiramo-nos em abordagens anteriores para melhorar a detecção e o acompanhamento dessa condição médica.

Na etapa de treinamento do modelo, utilizamos os dados de voz de um total de 40 pacientes, analisando detalhadamente a pronúncia de cada letra do alfabeto. Durante o treinamento, geramos avaliações parciais para cada letra, nas quais classificamos binariamente o paciente como tendo Parkinson (1) ou não tendo Parkinson (0). A avaliação parcial de cada letra envolveu a análise de métricas de desempenho do modelo, como precisão, recall e F1-score, além da construção de uma matriz de confusão. Após concluir a fase anterior, estabelecemos um critério de diagnóstico que foi posteriormente incorporado a um banco de dados genérico, concebido sob a orientação do supervisor, com o objetivo de aprimorar nossa compreensão da estrutura que estávamos construindo e organizando. Este banco de dados genérico incluía as classificações parciais das 26 letras para os 40 pacientes, resultando na soma das ocorrências de "um" e "zero" para determinar a classificação definitiva de cada paciente.

Após cada avaliação por letra, realizamos uma soma dos valores "zero" e "um", em que a prevalência determinava o diagnóstico definitivo do paciente. Com 26 letras envolvidas, havia a possibilidade de uma divisão equitativa de 13/13, o que caracterizaria uma situação de indeterminação. Para abordar essa probabilidade, foi pensando em uma função que visava minimizar tais indeterminações. Essa função operava excluindo as três variáveis com a menor correlação em relação ao diagnóstico final, a partir do conjunto das de um número N das variáveis mais fortemente correlacionadas com o diagnóstico. Em outras palavras, eliminaremos a última coluna da base de dados, identificada como a de menor correlação.

Vale ressaltar que quando falamos das N variáveis mais correlacionadas, tivemos duas experiências, no primeiro momento a ideia inicial era de usar a 5 variáveis mais correlacionadas com o diagnóstico, mas durante a etapa do treinamento do algoritmo de regressão regularizada, as métricas de desempenho, tanto no teste quanto no treinamento não eram satisfatórias, pois almejava-se que tanto no treinamento quanto no teste as métricas de assertividade fossem superior a 80%, no entanto isso só ocorreu em 5 vezes dentro de um universo de 26 dados. Com isso, foi alterado o número de variáveis mais correlacionadas para 6, com o objetivo de que na fase do treinamento do algoritmo as métricas de desempenho fossem superior a 80%, em um número maior de ocorrências, tanto no treinamento quanto no teste, e de fato ocorreu visto que com esse novo parâmetro, 13 letras ficaram com essa assertividade num universo de 26.

Na fase inicial, durante o treinamento do algoritmo, as ações foram conduzidas no ambiente OCTAVE. Posteriormente, para aplicar e executar os resultados obtidos no treinamento, migramos para a linguagem Python, utilizando a biblioteca Pandas para a manipulação de estruturas de dados em formato de dataframe e a biblioteca Numpy para trabalhar com matrizes e realizar diversas operações matemáticas. Neste ponto, passamos da teoria para a prática após o treinamento.

No código desenvolvido, depois de treinarmos os algoritmos com os dados no OCTAVE, realizamos todo o teste e validação do algoritmo em Python. No código elaborado, extraímos os dados individuais de cada um dos 40 pacientes a partir de arquivos Excel. Em seguida, importamos os parâmetros obtidos durante a fase de teste e realizamos uma multiplicação matricial. O resultado dessa multiplicação foi armazenado em uma variável denominada "resultados". É importante destacar que nos concentramos na diagonal dessa matriz resultante, que resultou da multiplicação entre os conjuntos de dados de todos os pacientes e os parâmetros exportados do OCTAVE. O resultado foi armazenado na variável "resultados".

Nesta variável, aplicamos a função sigmoide, uma função amplamente utilizada em algoritmos de



classificação binária. A ideia é que, após a aplicação da função sigmoide, se o valor resultante for maior que 0.5, o modelo classifica a entrada como 1, caso contrário, ela é classificada como 0.

Depois de transformar os dados usando a função sigmoide, simplificamos os cálculos subsequentes usando a biblioteca SciPy em Python. Em seguida, criamos um terceiro conjunto de dados para tornar a apresentação dos resultados da função sigmoide mais clara. Este novo conjunto de dados possui duas colunas: "Sigmoide" e "Classificação". A função de classificação atribui o valor "1" para "Parkinson" e "0" para "Não-Parkinson" de acordo com a situação.

Como mencionado anteriormente, quando ocorre uma classificação igual de 13/13, identificamos uma situação de indeterminação. Nesse caso, removemos as três colunas menos correlacionadas e reiniciamos o cálculo original do código. Em seguida, o algoritmo toma uma decisão com base na contagem dos valores zero e um. O diagnóstico definitivo é, então, exibido no console.

Berus et al. (2019) conduziram uma pesquisa importante sobre a classificação da doença de Parkinson com base em medidas acústicas. Suas descobertas foram valiosas para nossa metodologia, que também utiliza características acústicas da voz para a detecção precoce dessa doença neurodegenerativa.

RESULTADOS E DISCUSSÃO

No decorrer da fase de planejamento e desenvolvimento do projeto, empregamos o algoritmo de Regressão Logística Regularizada, uma técnica de aprendizado supervisionado. Essa abordagem é utilizada para examinar os dados disponíveis, identificando informações essenciais que possibilitam a realização de previsões quando novos dados são inseridos.

Figura 1 - Tabela com Diagnóstico dos Pacientes

PACIENTE	DIAGNÓSTICO	CLASSE - ALVO		PACIENTE	DIAGNÓSTICO	CLASSE - ALVO
1	0	1		21	0	0
2	0	1		22	0	0
3	0	1		23	1	0
4	0	1		24	1	0
5	0	1		25	0	0
6	0	1		26	0	0
7	0	1		27	0	0
8	0	1		28	0	0
9	0	1		29	1	0
10	0	1		30	0	0
11	0	1		31	0	0
12	0	1		32	0	0
13	0	1		33	0	0
14	0	1		34	0	0
15	0	1		35	0	0
16	0	1		36	0	0
17	0	1		37	0	0
18	0	1		38	0	0
19	0	1		39	0	0
20	0	1		40	1	0

Fonte: Elaboração Própria

Quando executado o algoritmo usando as 6 variáveis mais correlacionadas, e tirando a 3 letras menos importantes no diagnóstico, o resultado obtido foi:

- Verdadeiros positivos: 19



- Falsos negativos: 1
 - Verdadeiros negativos: 16
 - Falsos positivos: 4
- A acurácia do algoritmo foi de: 87,5%;
- O recall é aproximadamente 0.95;
- A precisão é aproximadamente 0.8261;
- O F1-Score é aproximadamente 0.8830.

CONCLUSÕES

Os resultados sugerem que o modelo de Regressão Logística Regularizada, quando aplicado às características vocais relevantes, pode ser uma ferramenta valiosa para auxiliar no diagnóstico da Doença de Parkinson. No entanto, é importante continuar aprimorando o modelo, considerando a otimização das características selecionadas e a expansão do conjunto de dados para aumentar sua robustez e confiabilidade clínica.

Esse trabalho representa um passo importante na direção de um auxílio mais eficaz para médicos neurologistas no diagnóstico precoce da DP, contribuindo para a melhoria da qualidade de vida dos pacientes afetados por essa condição neurodegenerativa.

AGRADECIMENTOS

Gostaria de expressar minha profunda gratidão ao Professor ANTONIO ALISSON PESSOA GUIMARÃES, que desempenhou um papel fundamental como meu orientador durante todo o desenvolvimento do meu projeto de pesquisa. Sua orientação, conhecimento e apoio foram inestimáveis ao longo dessa jornada. Durante o período de orientação, o Professor demonstrou uma dedicação incansável à minha formação acadêmica e ao sucesso do projeto. Suas orientações sábias contribuíram significativamente para a qualidade e o alcance dos resultados da pesquisa. Além disso, sua disponibilidade para esclarecer dúvidas, suas sugestões construtivas e seu encorajamento constante foram fundamentais para manter meu entusiasmo e motivação durante os desafios enfrentados. Quero expressar minha sincera gratidão pelo tempo e esforço dedicados à minha orientação, bem como pelo apoio contínuo oferecido ao longo deste processo. Sou imensamente grato por ter tido a oportunidade de trabalhar sob sua orientação e orientação.

Agradeço à Unilab pelo financiamento da pesquisa intitulada CLASSIFICAÇÃO DA AMPLITUDE DO SINAL DE TREMOR DE REPOUSO EM PACIENTES DIAGNOSTICADOS COM DOENÇA DE PARKINSON e executada entre 01/10/2022 e 30/09/2023, através do Programa Institucional de Bolsas de Iniciação Científica (Pibic).

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., FERRARI, D. G., Introdução à Mineração de Dados: Conceitos Básicos, Algoritmos e Aplicações. Editora Saraiva, 2016.
- ISENKUL, M. E.; SAKAR, B. E.; KURSUN, O. Improved spiral test using digitized graphics tablet for



monitoring Parkinson's disease. In: Proceedings International Conference on e-Health and Telemedicine, 2014. p. 171-175.