



**UNIVERSIDADE DA INTEGRAÇÃO INTERNACIONAL DA
LUSOFONIA AFRO-BRASILEIRA
INSTITUTO DE ENGENHARIAS E DESENVOLVIMENTO SUSTENTÁVEL
CURSO DE ENGENHARIA DE COMPUTAÇÃO**

JORGE ANTÔNIO FÉLIX DA SILVA

**ANÁLISE COMPARATIVA DE ALGORITMOS DE APRENDIZAGEM DE
MÁQUINA PARA DIAGNÓSTICO DA DOENÇA DE PARKINSON COM BASE EM
CARACTERÍSTICAS VOCAIS**

ACARAPE – CE

2024

JORGE ANTÔNIO FÉLIX DA SILVA

**ANÁLISE COMPARATIVA DE ALGORITMOS DE APRENDIZAGEM DE
MÁQUINA PARA DIAGNÓSTICO DA DOENÇA DE PARKINSON COM BASE EM
CARACTERÍSTICAS VOCAIS**

Trabalho de conclusão de curso apresentado ao curso de Engenharia de Computação da Universidade da Integração Internacional da Lusofonia Afro-Brasileira como requisito parcial à obtenção do título de Engenheiro de Computação.

Orientador: Prof. Dr. Antonio Alisson Pessoa Guimaraes.

Universidade da Integração Internacional da Lusofonia Afro-Brasileira
Sistema de Bibliotecas da UNILAB
Catalogação de Publicação na Fonte.

Silva, Jorge Antônio Félix da.

S586a

Análise comparativa de algoritmos de aprendizagem de máquina para diagnóstico da doença de Parkinson com base em características vocais / Jorge Antônio Félix da Silva. - Redenção, 2025.
46f: il.

Monografia - Curso de Engenharia De Computação, Instituto De Engenharias E Desenvolvimento Sustentável, Universidade da Integração Internacional da Lusofonia Afro-Brasileira, Redenção, 2025.

Orientador: Prof. Dr. Antônio Alisson Pessoa Guimarães.

1. Aprendizado de máquina. 2. Doença de Parkinson. 3. Métricas de avaliação. I. Título

CE/UF/BSCA

CDD 006.31

JORGE ANTÔNIO FÉLIX DA SILVA

**ANÁLISE COMPARATIVA DE ALGORITMOS DE APRENDIZAGEM DE MÁQUINA
PARA DIAGNÓSTICO DA DOENÇA DE PARKINSON COM BASE EM
CARACTERÍSTICAS VOCAIS**

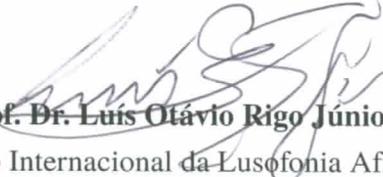
Trabalho de Conclusão de Curso (TCC) apresentado como parte integrante dos requisitos para obtenção do título de Bacharel em Engenharia de Computação, na Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB) – Campus das Auroras.

Data de aprovação: 26 de novembro de 2024.

BANCA EXAMINADORA


Prof. Dr. Antônio Alisson Pessoa Guimarães (Orientador)

Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB)


Prof. Dr. Luis Otávio Rigo Júnior

Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB)


Prof. Dr. Vandilberto Pereira Pinto

Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB)

Dedico este trabalho a todas as pessoas que contribuíram direta ou indiretamente com a sua realização. Em especial, aos meus pais Eldail e Luzinete e ao meu irmão Marcelo por todo apoio e carinho.

AGRADECIMENTOS

Primeiramente, agradeço a Deus, cuja presença e força me sustentaram em cada passo dessa jornada. Sem Ele, nada disso seria possível.

Aos meus pais, Eldail e Luzinete, por seu amor, sacrifício e apoio incondicional. Vocês sempre batalharam para que eu pudesse ter as oportunidades que me trouxeram até aqui, e é por vocês que busco me tornar uma pessoa melhor a cada dia.

Aos meus irmãos, Leandro, Romário e Marcelo, que, como homens tementes a Deus, sempre me incentivaram a ser batalhador e seguir os caminhos da justiça. Vocês são inspiração e exemplo para mim.

Com carinho e saudade, agradeço a duas mulheres de fibra que, mesmo em sua partida, deixaram uma marca profunda na minha vida. Minha Tia Salete (in memoriam) e minha Vovó Neuza (in memoriam), que me incentivaram e se esforçaram para que eu pudesse ingressar na universidade. Carrego seus ensinamentos e força em cada conquista.

À Tia Lucinete, que sempre guiou a mim e aos meus irmãos pelo caminho dos estudos e do bem. Obrigado pelo amor e pelo exemplo de dedicação.

Ao meu amigo e irmão de coração, Luzinel, pelos conselhos, pela alegria contagiante e por estar sempre ao meu lado, arrancando sorrisos mesmo nos momentos mais difíceis.

Aos amigos Álvaro e Alcides, que desde o primeiro semestre se mostraram dispostos a me ajudar. Vocês tornaram a vida acadêmica mais leve e os desafios muito mais divertidos.

Aos amigos que encontrei ao longo do caminho – Carlos Jardel, José Augusto, Calebe, Misael e Ivina – que também deixaram essa jornada mais especial. Agradeço especialmente a Ivina, que me indicou para atuar como bolsista com o Professor Alisson.

Ao Professor Alisson, um profissional exemplar, que ensina com prazer e dedicação, sempre buscando que seus alunos aprendam e cresçam. Agradeço especialmente pela confiança e paciência ao longo dos dois projetos em que trabalhamos juntos. Aos professores do curso de Engenharia da Computação, que contribuíram para minha formação, e a todos os profissionais da instituição, terceirizados e efetivos, que sempre foram prestativos e ajudaram a tornar essa conquista possível.

Gostaria de expressar minha gratidão ao Programa Institucional de Bolsas de Iniciação Científica (PIBIC-UNILAB) pela oportunidade de participar como bolsista. A experiência adquirida durante a iniciação científica foi essencial para o desenvolvimento deste trabalho. Agradeço também ao meu orientador de pesquisa, Prof. Dr. Alisson Guimarães, pela excelente condução do projeto, assim como por todo o suporte e apoio fornecidos ao longo do processo.

Agradeço, também, a todos os familiares que não mencionei diretamente, mas que sempre me apoiaram com carinho e incentivo ao longo do caminho. E aos colegas de curso que também fizeram parte dessa trajetória, tornando a experiência universitária mais rica, leve e motivadora.

Por fim, agradeço aos motoristas e cobradores dos transportes públicos que fizeram parte da minha rotina e foram essenciais para o meu trajeto diário até a faculdade.

A todos, minha eterna gratidão.

“Entrega o teu caminho ao Senhor; confia nele, e
ele tudo fará.”

Salmos 37:5

RESUMO

Este trabalho apresenta um estudo sobre a aplicação de algoritmos de Aprendizado de Máquina (AM) no diagnóstico da Doença de Parkinson (DP). O aprendizado de máquina é uma área da inteligência artificial que permite que sistemas computacionais aprendam a partir de dados sem programação explícita. São explorados os conceitos fundamentais, as aplicações práticas e as métricas de avaliação para AM, destacando os algoritmos K-Nearest Neighbors (KNN), Regressão Logística, Máquinas de Vetores de Suporte (SVM) e Random Forest. Na metodologia, foram utilizadas amostras de voz de 20 pacientes com DP e 20 indivíduos saudáveis. A seleção das variáveis relevantes para o diagnóstico foi feita com base na correlação de Pearson, e os dados foram divididos em conjuntos de treinamento e teste (80/20). Para evitar problemas de indeterminação nos resultados, um ajuste foi realizado, reduzindo as amostras de voz para um número ímpar. Cada algoritmo foi avaliado com as métricas de acurácia, precisão, recall e F1-score. Os resultados indicaram que o KNN apresentou o melhor desempenho para a metodologia e variáveis selecionadas, sendo a técnica mais eficaz para esta aplicação específica. Futuros estudos são sugeridos com a inclusão de outras variáveis correlacionadas e a exploração de algoritmos adicionais. Este trabalho fornece uma contribuição inicial para a análise comparativa de algoritmos no auxílio ao diagnóstico da Doença de Parkinson.

Palavras-chave: Aprendizado de Máquina, Doença de Parkinson, Métricas de avaliação.

ABSTRACT

This work presents a study on the application of Learning algorithms Machine (AM) in the diagnosis of Parkinson's Disease (PD). Machine learning is an area of artificial intelligence that allows computer systems to learn from of data without explicit programming. Fundamental concepts are explored, applications practices and evaluation metrics for ML, highlighting K-Nearest Neighbors algorithms (KNN), Logistic Regression, Support Vector Machines (SVM) and Random Forest. In methodology, voice samples from 20 PD patients and 20 individuals healthy. The selection of relevant variables for the diagnosis was made based on the Pearson correlation, and the data was divided into training and testing sets (80/20). To avoid problems of indeterminacy in the results, an adjustment was made, reducing the voice samples to an odd number. Each algorithm was evaluated with the accuracy, precision, recall and F1-score metrics. The results indicated that KNN presented the best performance for the methodology and selected variables, with the technique most effective for this specific application. Future studies are suggested with the inclusion of other correlated variables and the exploration of additional algorithms. This work provides an initial contribution to the comparative analysis of algorithms to aid diagnosis of Parkinson's disease.

Keywords: Machine Learning, Parkinson's Disease, evaluation metrics.

LISTA DE FIGURAS

Figura 1. Exemplo de funcionamento do algoritmo KNN.	19
Figura 2. Exemplo de predição da regressão logística.	20
Figura 3. Exemplo de funcionamento do algoritmo SVM.	21
Figura 4. Exemplo de funcionamento do algoritmo Random Forest.	22
Figura 5. Logo do vscode.	24
Figura 6. Logo da biblioteca Scikit-learn.	24
Figura 7. Logo da biblioteca Numpy.	25
Figura 8. Logo da biblioteca Pandas.	25
Figura 9. Localização da substancia negra no encéfalo humano.	28
Figura 10. Imagem mostrando um resumo de quais são os sintomas que os portadores da Doença de Parkinson apresentam.	29
Figura 11. Estruturas químicas da dopamina e da levodopa.	30
Figura 12. Treino de força em pacientes com DP.	31

LISTA DE QUADROS

Quadro 1. Exemplo genérico de uma matriz de confusão.	26
Quadro 2. Recursos baseados em frequência extraídos de amostras de voz.	33

LISTA DE TABELAS

Tabela 1. Métricas do KNN no treinamento.	36
Tabela 2. Métricas do SVM no treinamento.	36
Tabela 3. Métricas do RFC no treinamento.	36
Tabela 4. Métricas do LR no treinamento.	36
Tabela 5. Métricas do KNN no teste.	37
Tabela 6. Métricas do SVM no teste.	37
Tabela 7. Métricas do RFC no teste.	37
Tabela 8. Métricas do LR no teste.	37
Tabela 9. Matriz confusão do KNN.	38
Tabela 10. Matriz confusão do SVM.	38
Tabela 11. Matriz confusão do RFC.	38
Tabela 12. Matriz confusão do LR.	38

LISTA DE ABREVIATURAS E SIGLAS

DP	Doença de Parkinson
IA	Inteligência Artificial
PWP	<i>Patients with Parkinson's disease</i>
AM	Aprendizagem de máquina
KNN	<i>K-Nearest Neighbors</i>
SVM	<i>Support Vector Machine</i>
RFC	<i>Random Forest Classifier</i>
LR	<i>Logistic Regression</i>
TP	<i>True positives</i>
TN	<i>True negatives</i>
FP	<i>False positives</i>
FN	<i>False negatives</i>
PIBIC	Programa Institucional de Bolsas de Iniciação Científica
UNILAB	Universidade da Integração Internacional da Lusofonia Afro-Brasileira

SUMÁRIO

1. INTRODUÇÃO.	15
2. APRENDIZADO DE MAQUINA.	17
2.1 Definição.	17
2.2 Aplicações de Aprendizado de Máquina.	17
2.3 Funcionamento de um algoritmo de Aprendizado de Máquina.	18
2.4 Recursos e Utilitários usados nesta Pesquisa.	23
2.5 Métricas de avaliação em Aprendizado de Máquina.	25
3. DOENÇA DE PARKINSON.	28
4. METODOLOGIA.	33
5. RESULTADOS E DISCUSSÕES.	36
6. CONCLUSÃO.	41
REFERÊNCIAS	43

1. INTRODUÇÃO

A Doença de Parkinson (DP) é uma das condições neurodegenerativas mais prevalentes em todo o mundo, afetando principalmente a população idosa. Estima-se que cerca de 1% da população mundial com mais de 60 anos conviva com a DP, o que representa milhões de indivíduos afetados e uma significativa carga para sistemas de saúde pública (Poewe *et al.*, 2017). A DP é caracterizada pela perda progressiva de neurônios dopaminérgicos na substância negra do cérebro, resultando em uma série de sintomas motores, como tremores, rigidez muscular, bradicinesia e instabilidade postural (Lee *et al.*, 2016). Além disso, a doença frequentemente impacta as funções cognitivas e emocionais dos pacientes, acarretando prejuízos significativos na qualidade de vida (Van Den Eeden *et al.*, 2003).

Embora os sintomas motores sejam a característica principal da DP, o diagnóstico ainda ocorre em estágios relativamente tardios, quando a perda neuronal já está avançada (Brasil, 2017). Esse cenário impulsiona a busca por métodos diagnósticos que possibilitem a detecção precoce da doença e um monitoramento mais preciso de sua progressão. Nesse contexto, a inteligência artificial (IA) surge como uma ferramenta promissora, especialmente por meio de algoritmos de aprendizado de máquina, capazes de identificar padrões complexos em grandes volumes de dados biomédicos (Litjens *et al.*, 2017).

O aprendizado de máquina tem ganhado destaque na medicina, particularmente na análise de dados biomédicos, permitindo uma nova abordagem para o diagnóstico e a predição de progressão de doenças como a DP (Altham *et al.*, 2024). Entre os métodos de aprendizado de máquina, os algoritmos de aprendizado supervisionado têm sido amplamente utilizados em pesquisas sobre diagnóstico e prognóstico da DP, devido à sua capacidade de aprender padrões a partir de dados rotulados. Esses algoritmos, como Máquinas de Vetores de Suporte (SVM), Random Forest e Redes Neurais Artificiais, permitem o treinamento de modelos que podem classificar e prever com alta precisão a presença e a progressão de sintomas (Lai *et al.*, 2023).

Este trabalho utiliza um conjunto de dados de voz, capturados de um grupo de 20 pacientes com Parkinson (PWP) e 20 indivíduos saudáveis, que recorreram ao Departamento de Neurologia da Faculdade de Medicina de Cerrahpasa, da Universidade de Istambul. Foram obtidas várias gravações de cada sujeito, incluindo 26 amostras de voz compostas por vogais sustentadas, números, palavras e frases curtas. A partir dessas gravações, foram extraídas 26 características lineares e baseadas em frequência, fundamentais para a detecção dos sintomas vocais associados à DP. Tais características de voz têm sido reconhecidas como indicativas de

alterações neurológicas e, portanto, possuem potencial diagnóstico significativo (Hecker *et al.*, 2022).

O objetivo do presente trabalho consiste em comparar o desempenho de diferentes algoritmos de aprendizado supervisionado na tarefa de classificação e predição da DP, usando características de voz como variáveis principais. A metodologia envolve a aplicação de diversos classificadores supervisionados ao conjunto de dados de voz, permitindo a análise de métricas de desempenho, como acurácia, sensibilidade e especificidade. A avaliação comparativa entre os algoritmos poderá revelar qual abordagem é mais eficiente para detecção precoce da DP, auxiliando no desenvolvimento de ferramentas que possam futuramente ser aplicadas na prática clínica.

Assim, o estudo busca contribuir para o campo da bioinformática e medicina diagnóstica, fornecendo evidências sobre o desempenho de algoritmos de aprendizado de máquina na detecção de padrões associados à DP. Essa abordagem é essencial para o avanço de tecnologias de apoio ao diagnóstico, com o potencial de melhorar o tratamento e a qualidade de vida de pacientes com a doença.

2. APRENDIZADO DE MÁQUINA

2.1. DEFINIÇÃO

Aprendizagem de Máquina (AM) é classificado por Bishop (2006) sendo, um campo da inteligência artificial que se concentra no desenvolvimento de algoritmos e modelos que permitem que os sistemas computacionais aprendam a partir de dados e façam previsões ou decisões sem serem explicitamente programados. Essa área se dedica à pesquisa e ao desenvolvimento de algoritmos que têm a capacidade de aprender com seus erros ao processar dados, permitindo, assim, a realização de previsões sobre informações inéditas.

Embora a AM seja uma área complexa, segundo Samuel (1959) ela pode ser entendida de forma mais ampla como o ramo que permite que os computadores adquiram conhecimento sem a necessidade de programação direta. Uma perspectiva mais voltada para a engenharia é apresentada por Mitchell (1997), que afirma que um programa de computador é considerado capaz de aprender quando, a partir da experiência E , seu desempenho em uma tarefa T , medido por uma métrica P , melhora com o tempo.

2.2 APLICAÇÕES DE APRENDIZADO DE MÁQUINA

Segundo He et al. (2016), a aprendizagem de máquina possui diversas aplicações em diferentes setores. No campo da saúde, por exemplo, algoritmos são usados para prever doenças e auxiliar no diagnóstico médico, como em sistemas que analisam imagens de radiografias para detectar câncer.

Além da área médica, o aprendizado de máquina também desempenha um papel crucial em sistemas de recomendação, como os utilizados por plataformas de streaming e e-commerce. Esses sistemas analisam o comportamento dos usuários, como histórico de compras ou visualizações, para oferecer sugestões personalizadas. De acordo com o estudo de Smith et al. (2017), algoritmos de recomendação baseados em aprendizado de máquina aumentam significativamente a retenção de usuários e a receita, pois conseguem identificar com maior precisão produtos que atendem aos interesses individuais.

No contexto da agricultura de precisão, o aprendizado de máquina é utilizado para prever safras, identificar deficiências nutricionais e otimizar o manejo do solo. Sensores e drones equipados com câmeras permitem a coleta de grandes volumes de dados sobre o estado

das plantações, que são analisados por modelos de aprendizado de máquina para detectar padrões de crescimento e saúde das plantas. Segundo Liakos et al. (2018), o uso dessas técnicas melhora a eficiência agrícola, permitindo a antecipação de problemas como doenças e estresses hídricos, resultando em aumento de produtividade e uso sustentável de recursos.

Além disso, em marketing, segundo Kotler et al. (2016) modelos preditivos são utilizados para personalizar recomendações de produtos e segmentar clientes com base em seu comportamento.

2.3 FUNCIONAMENTO DE UM ALGORITMO DE APRENDIZADO DE MÁQUINA

Cada algoritmo apresenta particularidades no seu modo de operação. Em sua forma mais simples, esses algoritmos recebem dados de entrada, que são processados por um modelo preditivo previamente estabelecido. A partir daí, o sistema gera um resultado com base nas previsões realizadas a partir dos dados inseridos. Existem diversos métodos e técnicas para validar a eficiência desses algoritmos, como a definição de uma porcentagem específica para medir a precisão de seus resultados. Isso permite verificar se a predição fornecida pelo algoritmo está próxima do resultado esperado ou previsto. Tais aspectos são discutidos em maior profundidade neste capítulo.

Além disso, segundo Hastie *et al.* (2009), o aprendizado de máquina, com sua ênfase na criação de algoritmos capazes de se adaptar e aprender a partir de seus erros, está fortemente ligado à otimização matemática. Uma de suas principais características é a aplicação de métodos estatísticos para garantir a validade e o desempenho dos algoritmos.

Na literatura, há uma grande variedade de métodos de classificação, dentre os quais, neste trabalho focaremos nos seguintes algoritmos:

K-Nearest Neighbors (KNN): classifica um dado com base nos rótulos das amostras mais próximas, comparando suas distâncias a outros pontos no espaço de dados (Mitchell, 1997).

Como o *KNeighborsClassifier* Funciona:

Parâmetro k (*n_neighbors*):

Esse parâmetro é o número de vizinhos mais próximos que o modelo considera ao classificar um novo ponto. Por exemplo, se $k=3$, ele examinará os três vizinhos mais próximos do novo dado. Em geral, valores ímpares de k são usados para evitar empates.

Medida de Distância:

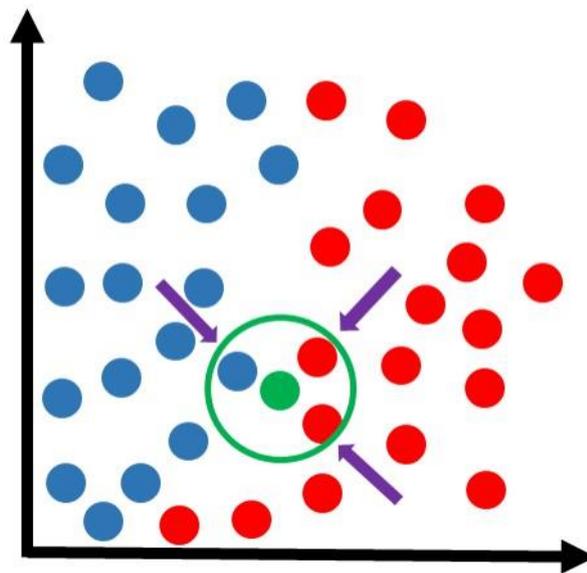
O *KNeighborsClassifier* calcula a distância entre o ponto novo e os pontos de treinamento existentes para encontrar quais são os mais próximos. O método padrão é a distância Euclidiana, mas outras métricas (como Manhattan ou Minkowski) podem ser usadas.

Decisão da Classe:

O novo ponto recebe a mesma classe que a maioria dos k vizinhos. Por exemplo, se entre os 3 vizinhos mais próximos, 2 são da classe “A” e 1 da classe “B”, o ponto será classificado como “A”.

A figura 1, que pode ser vista a seguir, é um exemplo de classificação utilizando o KNN:

Figura 1 – Exemplo de funcionamento do algoritmo KNN.



Fonte: DIDÁTICA TECH, 2024.

Na imagem acima é possível visualizar um exemplo de classificação do KNN, onde K=3, e então ocorre a classificação do dado que está na cor verde, este dado será classificado como pertencente da classe vermelha, visto que dentre os 3 vizinhos mais próximos, dois são da classe vermelha e apenas 1 é da classe azul.

Regressão Logística: um algoritmo de classificação que modela a probabilidade de um determinado evento com base em uma função logística, útil para resolver problemas de classificação binária (Hosmer; Lemeshow, 2000).

Como o *LogisticRegression* Funciona:

Função Sigmoid (ou logística):

A regressão logística utiliza a função sigmoide, que mapeia valores reais para uma faixa entre 0 e 1. A fórmula da função sigmoide é:

$$\sigma(z) = \frac{1}{1 + e^{(-z)}} b \quad (2.1)$$

Onde z é uma combinação linear dos atributos do dado de entrada. Essa função permite interpretar o resultado como uma probabilidade.

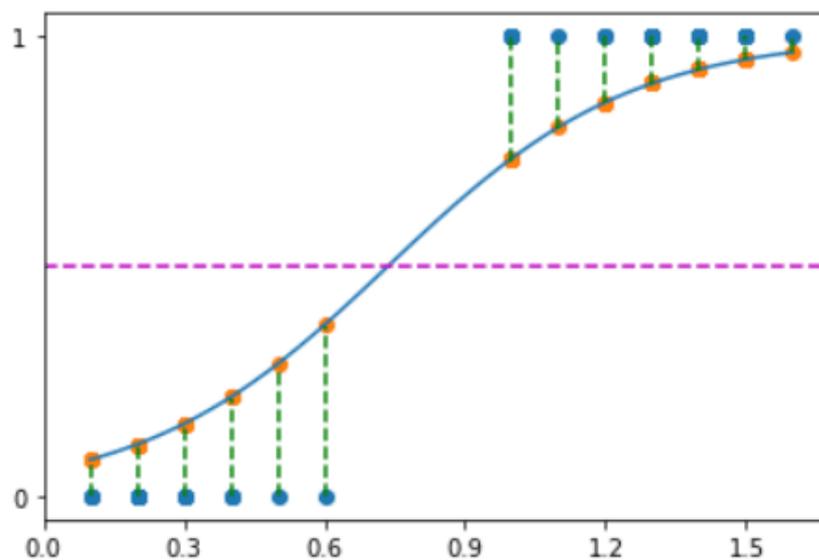
Classificação Binária:

A regressão logística é usada para problemas de classificação binária. Ela prevê a probabilidade de uma instância pertencer a uma classe (ex.: 0 ou 1).

Se a probabilidade é maior que 0,5, o modelo classifica a instância como uma classe (1); caso contrário, classifica como a outra (0).

A seguir é possível visualizar a figura 2, esta figura serve pra exemplificar de como a função logística faz a predição das classes:

Figura 2 – Exemplo de predição da regressão logística.



Fonte: HASHTAG TREINAMENTOS, 2024.

Na imagem acima é possível entender o comportamento que foi descrito anteriormente, para pontos que estão acima 0,5 no eixo vertical, o modelo classifica como 1 e para pontos que estão abaixo de 0,5 no eixo vertical, o modelo classifica como 0.

Máquinas de Vetores de Suporte (SVM): podem ser lineares ou não lineares, separando dados de um conjunto maior em classes distintas, utilizando uma função de kernel para maximizar a margem entre as classes (Burges, 1998).

Como o SVM Funciona:

Hiperplano Separador:

Para classificar dados, o SVM tenta encontrar o hiperplano que divide as classes de maneira mais eficaz. Em problemas bidimensionais, esse hiperplano é uma linha; em três dimensões, é um plano; e em dimensões superiores, é um hiperplano.

O ideal é que esse hiperplano maximize a margem entre os pontos mais próximos de cada classe (os vetores de suporte).

Vetores de Suporte:

Os vetores de suporte são os pontos de dados que estão mais próximos do hiperplano separador e que determinam a posição desse hiperplano. Esses pontos são essenciais para o modelo e ajudam a maximizar a margem.

Funções Kernel:

O SVM usa funções de kernel para lidar com dados que não são linearmente separáveis. O kernel mapeia os dados para uma dimensão superior onde é possível encontrar um hiperplano linear que os separe. Alguns tipos de kernel populares são:

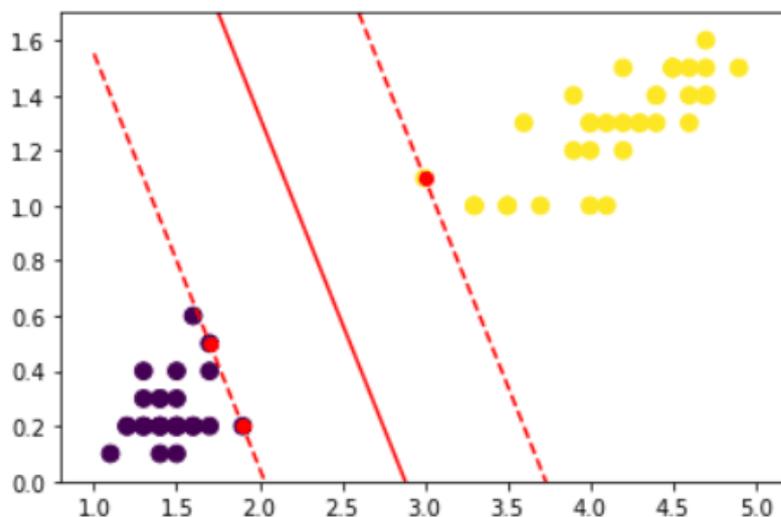
Linear: Adequado para dados que são linearmente separáveis.

RBF (*Radial Basis Function*): Mapeia os dados para uma dimensão mais alta para criar uma fronteira não linear.

Polinomial e Sigmoid: Outras opções para diferentes tipos de separação.

A seguir a figura 3 ilustra como o SVM faz essa separação de classes em um cenário onde as classes são linearmente separáveis.

Figura 3 – Exemplo de funcionamento do algoritmo SVM.



Fonte: HASHTAG TREINAMENTOS, 2024.

Na figura acima é possível ver a linha vermelha contínua que simboliza o hiperplano separador, e as linhas vermelhas tracejadas representam os vetores de suporte.

Random Forest: método de aprendizado em conjunto que utiliza múltiplas árvores de decisão para realizar tarefas de classificação e regressão. A classe final é determinada pela maioria das previsões feitas pelas árvores individuais (Breiman, 2001).

Como o *RandomForestClassifier* Funciona:

Árvores de Decisão Individuais:

O Random Forest constrói várias árvores de decisão. Cada árvore é ajustada com um subconjunto diferente dos dados e variáveis, usando amostragem aleatória. Isso significa que cada árvore “vê” uma parte diferente do conjunto de dados, tornando o modelo final mais robusto e menos propenso a se adaptar excessivamente aos dados de treinamento.

Bagging (Amostragem Aleatória):

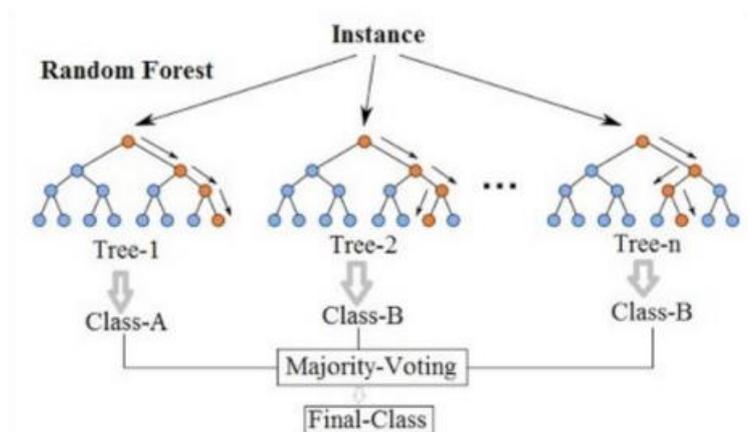
Esse método usa *Bagging (Bootstrap Aggregating)*, que envolve amostrar com reposição. Cada árvore é construída a partir de uma amostra aleatória dos dados originais, permitindo que alguns dados apareçam em mais de uma árvore, enquanto outros podem ser omitidos. Isso melhora a generalização do modelo.

Votação das Árvores:

No caso de classificação, cada árvore “vota” para decidir a classe de um novo ponto de dados. A classe final é determinada pela maioria dos votos (votação majoritária). Esse processo reduz a variabilidade das previsões individuais das árvores e melhora a precisão geral do modelo.

A seguir a figura 4 exemplifica um caso simples de como o algoritmo floresta aleatória se comporta:

Figura 4 – Exemplo de funcionamento do algoritmo Random Forest.



Fonte: KOEHRSEN, 2024.

Observando a ilustração acima é possível visualizar o comportamento que foi descrito anteriormente, a classe final é definida de acordo com a votação majoritária, ou seja, como no exemplo acima, é possível ver que a classe-B teve mais votos do que a classe-A, então a classificação final do modelo para este exemplo seria a classe-B.

2.4 RECURSOS E UTILITÁRIOS USADOS NESTA PESQUISA

Existem várias ferramentas que auxiliam no desenvolvimento de projetos de aprendizado de máquina (AM), linguagem de programação Python se destaca como uma das linguagens mais utilizadas nesse campo e por isso, foi a linguagem adotada para ser usada neste projeto. De acordo com Raschka *et al.* (2019), essa popularidade se deve ao vasto conjunto de bibliotecas disponíveis, ao fato de ser uma linguagem de código aberto e à facilidade que oferece na criação de gráficos e visualizações, além da simplicidade na depuração de erros. Esses fatores tornam o Python uma excelente escolha para trabalhar com AM.

Além da linguagem de programação mencionada anteriormente, podemos destacar o uso dos seguintes recursos no andamento deste projeto:

VSCode (Visual Studio Code): um dos principais Ambiente de Desenvolvimento Integrado utilizadas por programadores em AM. Desenvolvida pela Microsoft, essa ferramenta possui suporte para várias linguagens, incluindo Python, e é altamente customizável com uma ampla gama de extensões, facilitando a integração com bibliotecas de aprendizado de máquina e ambientes como Jupyter Notebook. Seu suporte à depuração e controle de versão também faz dela uma excelente escolha para projetos de AM. Logo abaixo é possível visualizar a figura 5, em que mostra a logo desta ferramenta.

Figura 5 – Logo do vscode.



Fonte: Visual Studio Code, 2024.

Scikit-learn: uma biblioteca essencial para o aprendizado de máquina em Python, com suporte para uma vasta gama de algoritmos de classificação, regressão, agrupamento e redução de dimensionalidade. Sua simplicidade de uso e integração com outras bibliotecas, como Numpy e Pandas, torna o desenvolvimento de soluções de AM mais rápido e eficiente. Logo abaixo é possível visualizar a figura 6, em que mostra a logo desta biblioteca.

Figura 6 – Logo da biblioteca Scikit-learn.



Fonte: Scikit-learn, 2024.

Algumas outras ferramentas amplamente utilizadas no aprendizado de máquina são:

Numpy: biblioteca essencial para a realização de operações matemáticas avançadas, como multiplicação de matrizes e outras funções numéricas. Logo abaixo é possível visualizar a figura 7, em que mostra a logo desta biblioteca.

Figura 7 – Logo da biblioteca Numpy.



Fonte: NumPy, 2024.

Pandas: facilita o trabalho com dados estruturados e rotulados, tornando o processo de manipulação e análise de grandes conjuntos de dados mais intuitivo. Logo abaixo é possível visualizar a figura 8, em que mostra a logo desta biblioteca.

Figura 8 – Logo da biblioteca Pandas.



Fonte: Pandas: Python Data Analysis Library, 2024.

2.5 MÉTRICAS DE AVALIAÇÃO EM APRENDIZADO DE MÁQUINA

A matriz de confusão é uma ferramenta fundamental na avaliação de modelos de classificação em aprendizado de máquina, fornecendo uma visão detalhada do desempenho do modelo ao comparar as classificações previstas com as reais. A matriz é composta por quatro elementos principais que permitem analisar a quantidade de erros e acertos do modelo em relação às classes previstas.

Ela é particularmente útil em problemas de classificação binária, mas pode ser estendida para problemas multiclasse. A matriz de confusão organiza as previsões em categorias que permitem calcular métricas de avaliação como acurácia, precisão, recall e F1-score.

Para um problema de classificação binária (com duas classes: positiva e negativa), a matriz de confusão é representada conforme o quadro 1, que pode ser visto a seguir:

Quadro 1 – Exemplo genérico de uma matriz de confusão.

	PREVISTO POSITIVO	PREVISTO NEGATIVO
REAL POSITIVO	TP	FN
REAL NEGATIVO	FP	TN

Fonte: Autor, 2024.

Onde:

- **TP (Verdadeiros Positivos - *True Positives*, do inglês)**: refere-se ao número de casos em que a classe positiva foi corretamente identificada.
- **TN (Verdadeiros Negativos - *True Negatives*, do inglês)**: indica a quantidade de casos em que a classe negativa foi corretamente reconhecida.
- **FP (Falsos Positivos - *False Positives*, do inglês)**: representa os casos em que a classe negativa foi incorretamente prevista como positiva.
- **FN (Falsos Negativos - *False Negatives*, do inglês)**: refere-se aos casos em que a classe positiva foi erroneamente classificada como negativa.

Ao desenvolver e treinar modelos de aprendizado de máquina, é essencial avaliar seu desempenho por meio de métricas que permitam medir a eficácia e a precisão das previsões. Neste projeto foram utilizadas as seguintes métricas, a **acurácia**, a **precisão**, o **recall** e o **F1-score**. Cada uma dessas métricas tem características específicas que fornecem diferentes perspectivas sobre o desempenho do modelo, especialmente em cenários de classificação.

A acurácia é uma das métricas mais comuns para avaliar modelos de classificação. Ela mede a proporção de previsões corretas entre o total de previsões feitas pelo modelo. A acurácia é útil em problemas onde as classes estão equilibradas, ou seja, o número de exemplos de cada classe é similar.

A fórmula para acurácia é dada por:

$$Acurácia = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.2)$$

A precisão é uma métrica que avalia quantas das previsões positivas feitas pelo modelo estão realmente corretas. Ou seja, ela mede a proporção de verdadeiros positivos em relação ao total de positivos previstos (incluindo os falsos positivos). A precisão é especialmente importante quando as consequências de um falso positivo são graves.

A fórmula para precisão é dada por:

$$Precisão = \frac{TP}{TP + FP} \quad (2.3)$$

O *recall*, também conhecido como sensibilidade ou taxa de verdadeiros positivos, mede a capacidade do modelo em identificar corretamente todos os exemplos positivos. Ele calcula a proporção de verdadeiros positivos em relação ao total de exemplos que realmente pertencem à classe positiva (verdadeiros positivos e falsos negativos). O *recall* é crucial quando o objetivo é minimizar falsos negativos.

A fórmula para *recall* é:

$$Recall = \frac{TP}{TP+FN} \quad (2.4)$$

O *F1-score* é a métrica que harmoniza a precisão e o *recall* em uma única medida. É a média harmônica dessas duas métricas, proporcionando um equilíbrio entre elas, especialmente útil quando há um desbalanceamento entre as classes.

A fórmula do *F1-score* é:

$$F1 = 2 \times \frac{Precisão \times Recall}{Precisão + Recall} \quad (2.5)$$

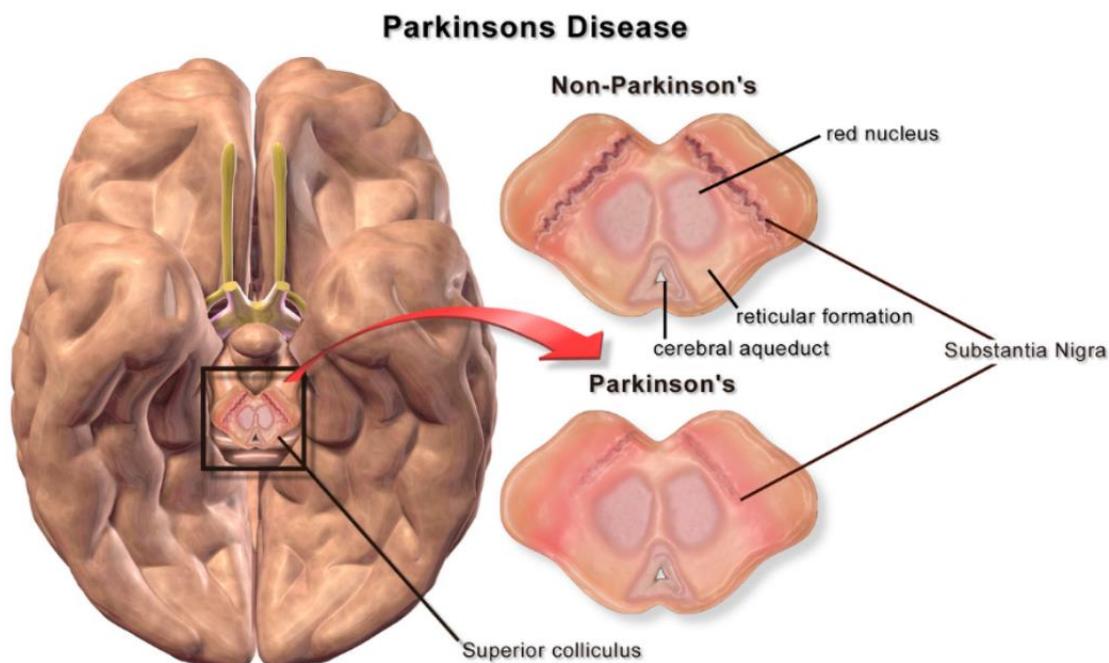
O *F1-score* varia de 0 a 1, onde 1 representa o melhor desempenho possível e 0 indica o pior. Essa métrica é útil em cenários onde é importante balancear falsos positivos e falsos negativos.

A escolha de qual métrica utilizar depende do contexto e dos objetivos do problema em questão. Em sistemas onde o custo de um falso negativo é alto, como no diagnóstico de doenças, o *recall* tende a ser mais valorizado. Já em sistemas como de detecção de fraudes, onde falsos positivos podem ser custosos em termos financeiros e de reputação, a precisão é mais importante.

3. DOENÇA DE PARKINSON

A Doença de Parkinson (DP) é uma condição neurodegenerativa crônica e progressiva que afeta principalmente o sistema motor. A DP é causada pela perda de neurônios dopaminérgicos na substância negra, uma região do cérebro responsável pela produção de dopamina, neurotransmissor essencial para o controle dos movimentos corporais. A deficiência de dopamina leva aos sintomas motores típicos da doença, como tremores em repouso, rigidez muscular, lentidão nos movimentos (bradicinesia) e instabilidade postural (Brasil, 2017).

Figura 9 – Localização da substancia negra no encéfalo humano.



Fonte: (Medical Gallery of Blausen Medical, 2014).

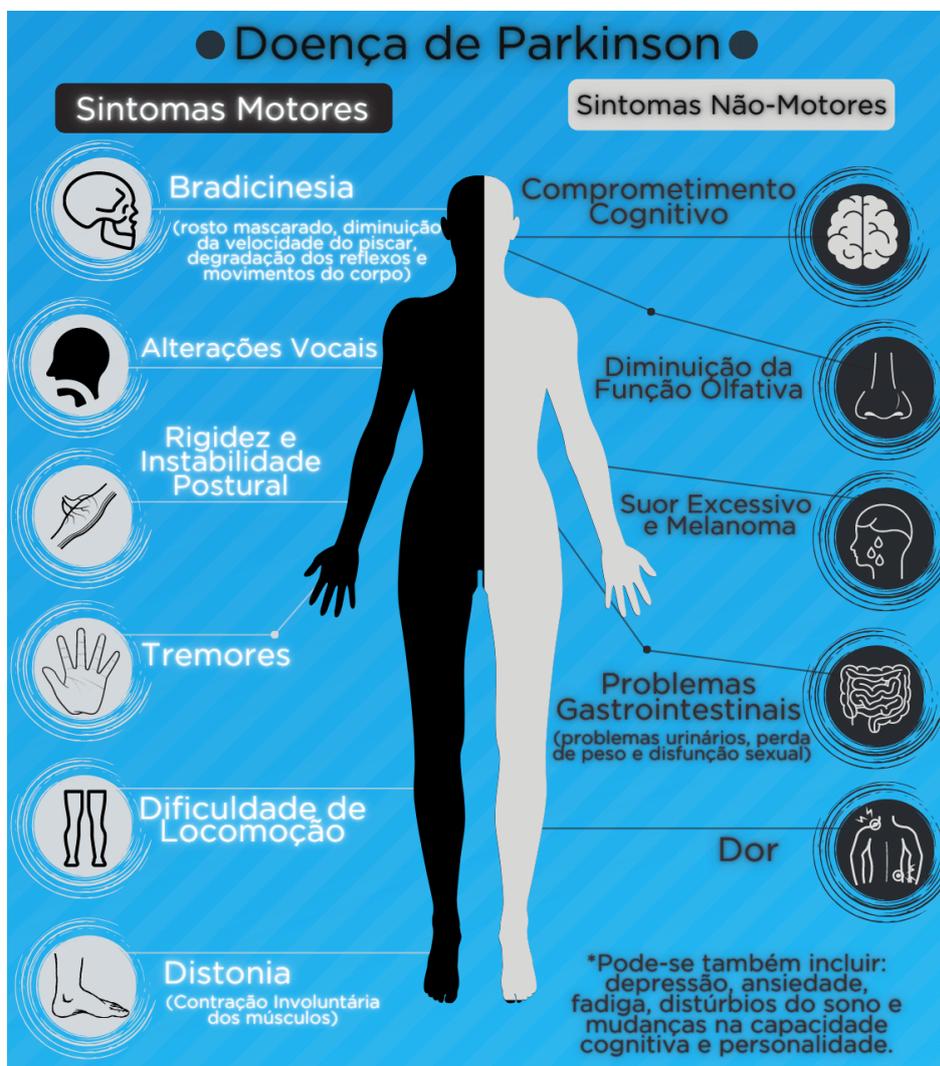
Na figura 9 que está logo acima é possível ver a diferença entre um cérebro de um parkinsoniano e uma pessoa saudável, nota-se que é quase imperceptível a área denominada substância *nigra* no cérebro do portador da doença.

De acordo com Barreto *et al.* (2015), a DP está associada à perda de neurônios na substância nigra, localizada no hipotálamo, os quais são responsáveis pela maior parte da produção de dopamina no organismo. Embora a dopamina também seja sintetizada nas áreas mesolímbica, mesocortical e túbero-infundibular, a diminuição dessa produção na substância nigra é um dos fatores centrais para o desenvolvimento da DP.

Além dos sintomas motores, a DP pode estar associada a uma variedade de sintomas não motores, incluindo disfunções cognitivas, distúrbios do sono, depressão e alterações no olfato, o que pode impactar a qualidade de vida dos pacientes. Embora seja mais comum em

peessoas com mais de 60 anos, a DP pode ocorrer em indivíduos mais jovens, um fenômeno conhecido como Parkinson de início precoce (Brasil, 2017). A seguir é possível visualizar a figura 10, em que apresenta alguns sintomas motores e alguns sintomas não motores da DP.

Figura 10 - Imagem mostrando um resumo de quais são os sintomas que os portadores da Doença de Parkinson apresentam.



Fonte: FONOFF, 2020.

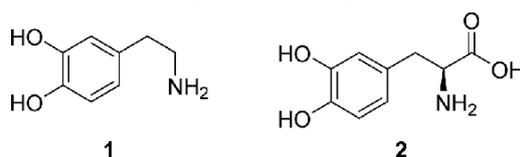
O diagnóstico da DP é predominantemente clínico, baseado na história do paciente e no exame físico, com ênfase nos sinais motores característicos. Não há um teste definitivo para a DP, embora a resposta positiva a medicamentos dopaminérgicos, como a levodopa, seja frequentemente usada como um critério diagnóstico auxiliar (Brasil, 2017).

O tratamento da DP é multifacetado, focando no alívio dos sintomas e na melhora da qualidade de vida dos pacientes, uma vez que a condição não tem cura. As abordagens terapêuticas incluem tanto intervenções farmacológicas quanto não farmacológicas.

De acordo com Blood (2016), devido a DP resultar de disfunções no sistema dopaminérgico, levando ao uso de medicamentos que introduzem precursores da dopamina para compensar a deficiência no cérebro. Entre as opções terapêuticas mais recomendadas está a levodopa, amplamente empregada desde os anos 1970. Embora eficaz, muitos pacientes experimentam uma queda de sua ação ao longo do tempo, o que requer aumento de dose, além do risco de perda de eficácia com o uso prolongado.

A levodopa por ter uma estrutura química diferenciada, ao ser administrada, consegue atravessar a barreira hematoencefálica, a camada que protege o Sistema Nervoso Central contra substâncias que possam ter algum efeito sobre ele (Castro, 2024). E então é convertida em dopamina pela enzima DOPA descarboxilase, o que ajuda a compensar a baixa produção desse neurotransmissor em pacientes com Parkinson. Logo abaixo através da figura 11, é possível ver a diferença da estrutura química da dopamina e da levodopa.

Figura 11 - Estruturas químicas da dopamina e da levodopa.

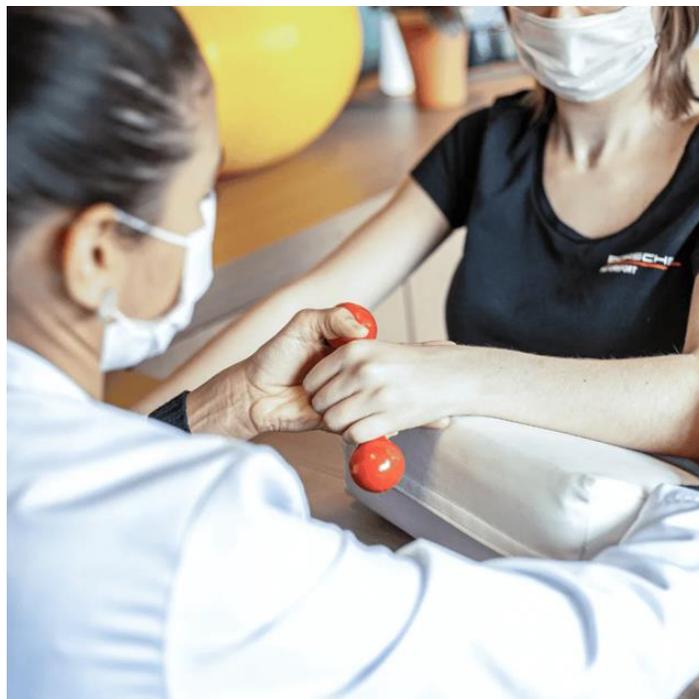


Fonte: RESEARCHGATE, 2024.

Na imagem acima a estrutura química da esquerda (1) é a estrutura da dopamina, e a levodopa está representada pela estrutura química da direita (2).

Além das intervenções farmacológicas atividades como exercícios físicos variados (incluindo treino de força, equilíbrio, resistência e práticas como dança e tai chi) são benéficas para a melhora de sintomas motores da Doença de Parkinson. Além disso, terapias ocupacionais, de fala e fisioterapia auxiliam no controle de dificuldades como hipofonia e disfagia. Essas intervenções terapêuticas e encaminhamentos interdisciplinares são essenciais para um atendimento de qualidade na doença de Parkinson (Armstrong, 2020). Na figura 12 que está logo a seguir é possível ver um dos tipos de tratamento da DP, a estimulação de exercícios físico.

Figura 12 – Treino de força em pacientes com DP.



Fonte: PROSENSE, 2024.

Estes tratamentos são focados no controle dos sintomas, uma vez que a condição é progressiva e não tem cura. Os objetivos principais incluem melhorar a qualidade de vida dos pacientes, aumentando sua autonomia e independência nas atividades diárias. É fundamental que o manejo da DP envolva uma equipe multiprofissional, capaz de atender às diversas necessidades dos pacientes, considerando a variedade de sintomas que podem se manifestar ao longo da evolução da doença. O Protocolo Clínico e Diretrizes Terapêuticas da Doença de Parkinson também ressalta a importância de intervenções individualizadas, que podem incluir o uso de medicamentos, terapias não farmacológicas e suporte psicológico, buscando sempre a melhor abordagem para cada caso (Brasil, 2021).

Estudos recentes têm investigado o uso de algoritmos de aprendizagem de máquina no diagnóstico da Doença de Parkinson (DP). Um trabalho realizado na UNIVERSIDADE FEDERAL DE PERNAMBUCO, destacou o uso de características radiômicas extraídas de imagens de ressonância magnética para desenvolver modelos preditivos baseados em algoritmos de aprendizado supervisionado. Essa pesquisa, conduzida com uma amostra de 70 indivíduos com DP precoce e 22 controles, empregou 108 características radiômicas do neostriado, analisadas com técnicas avançadas de pré-processamento e validação cruzada k-

fold. Entre os algoritmos testados, o modelo baseado em Floresta Aleatória obteve os melhores resultados, alcançando acurácia de 84,8%, sensibilidade de 76,4%, especificidade de 92,9% e uma área sob a curva ROC de 84,7%. Esses achados destacam a viabilidade do aprendizado de máquina no diagnóstico precoce da DP, especialmente por meio da integração de dados de imagem médica e técnicas avançadas de análise de dados (Accioly, 2022).

Em outro estudo, realizado pela UNIVERSIDADE DE BRASÍLIA com 113 participantes examinou a viabilidade do uso de classificadores supervisionados, como SVM e RUSBoost, aplicados a variáveis funcionais e clínicas para a classificação da progressão da DP. Os resultados indicaram que combinações específicas de variáveis funcionais e clínicas, especialmente aquelas baseadas na UPDRS III e na escala Hoehn e Yahr, podem fornecer uma base robusta para sistemas de predição automatizados, potencializando a atuação do aprendizado de máquina no auxílio ao diagnóstico e acompanhamento da DP (Vidal, 2021).

Esses estudos demonstram que, ao integrar dados biológicos e clínicos, os algoritmos de aprendizagem supervisionada podem proporcionar avanços significativos no diagnóstico e tratamento da DP.

4. METODOLOGIA

O projeto começou em uma coleta numa base dados, onde está base de dados contém arquivos de 20 Portadores de Parkinson (6 mulheres, 14 homens) e 20 indivíduos saudáveis (10 mulheres, 10 homens) que recorreram ao Departamento de Neurologia da Faculdade de Medicina de Cerrahpasa, Universidade de Istanbul. De todos os sujeitos, são obtidos vários tipos de gravações sonoras (26 amostras de voz, incluindo vogais sustentadas, números, palavras e frases curtas). Um grupo de 26 recursos lineares e baseados em frequência é extraído de cada amostra de voz. O banco de dados utilizado está disponível no repositório de aprendizagem de máquina da Universidade da Califórnia Irvine, com o título “*Parkinson's Speech with Multiple Types of Sound Recordings*”.

Estes recursos lineares podem ser vistos na imagem a seguir:

Quadro 2 - Recursos baseados em frequência extraídos de amostras de voz.

	Características	Grupo
1	Jitter (local)	frequency parameters
2	Jitter (local, absolute)	
3	Jitter (rap)	
4	Jitter (ppq5)	
5	Jitter (ddp)	
6	Number of pulses	Pulse Parameters
7	Number of periods	
8	Mean period	
9	Standard dev. Of period	
10	Shimmer (local)	Amplitude Parameters
11	Shimmer (local, dB)	
12	Shimmer (apq3)	
13	Shimmer (apq5)	
14	Shimmer (apq11)	
15	Shimmer (dda)	
16	Fraction of locally unvoiced frames	Voicing Parameters
17	Number of voices breaks	
18	Degree of voice breaks	
19	Median pitch	Pitch Parameters
20	Mean pitch	
21	Standard deviation	
22	Minimum pitch	
23	Maximum pitch	
24	Autocorrelation	Harmonicity Parameters
25	Noise-to-Harmonic	
26	Harmonic-to-Noise	

Fonte: Adaptado de Sakar *et al.* (2013)

Mas é válido ressaltar que neste projeto, não usamos todos esses 26 recursos, que durante a realização do projeto chamamos estes recursos de variáveis, das quais foram usadas

apenas 6 variáveis, e para escolher quais variáveis iríamos adotar, foi usado o método de correlação de Pearson, foi tomada essa decisão com a finalidade de evitar ruídos durante a predição, pois acreditamos que nem todos os recursos vistos acima atuaria de forma positiva no diagnóstico. E o número de variáveis a serem abordadas foi uma escolha arbitrária.

A correlação de Pearson é uma medida estatística que avalia a força e a direção de uma relação linear entre duas variáveis quantitativas.

$$r = \frac{\sum(X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum(X_i - \bar{X})^2 \sum(Y_i - \bar{Y})^2}} \quad (4.1)$$

Onde:

X_i e Y_i são valores individuais das variáveis X e Y.

\bar{X} e \bar{Y} são as medias de X e Y, respectivamente.

O coeficiente de correlação de Pearson, denotado por r , varia de -1 a 1, onde:

- $r = 1$ indica uma correlação linear positiva perfeita (quando uma variável aumenta, a outra também aumenta proporcionalmente).
- $r = -1$ indica uma correlação linear negativa perfeita (quando uma variável aumenta, a outra diminui proporcionalmente).
- $r = 0$ indica que não há correlação linear entre as variáveis.

O coeficiente de correlação de Pearson é amplamente utilizado em várias áreas para explorar relações entre variáveis. Na pesquisa em psicologia, ele auxilia na análise da relação entre variáveis como inteligência e desempenho acadêmico. Em economia, o coeficiente é usado para entender a associação entre diferentes indicadores econômicos, como a taxa de desemprego e o crescimento do PIB. Na área de ciências da saúde, ele é útil para investigar conexões entre variáveis biológicas, como os níveis de colesterol e o risco de doenças cardíacas. Além disso, no campo de ciência de dados, o coeficiente de Pearson é empregado para identificar correlações entre características em grandes conjuntos de dados, o que é valioso tanto em análises exploratórias quanto na construção de modelos preditivos (Data Geeks, 2024).

Com base na correlação de Pearson foram usadas as 6 variáveis mais correlacionados com o resultado, e esses atributos foram *Jitter (local, absolute)*, *Shimmer (local)*, *Median pitch*, *Harmonic-to-Noise*, *Autocorrelation*, *Number of voice breaks*.

A etapa seguinte foi realizar a divisão do conjunto de dados em treinamento e teste para que posteriormente fosse submetido aos algoritmos de classificação. A segregação consistiu

numa proporção de 80% para treinamento e 20% para teste, onde a porção de treinamento continha 16 pacientes saudáveis e 16 pacientes portadores de DP, e a porção de teste continha 4 pacientes saudáveis e 4 pacientes parkinsonianos, essa divisão foi feita de forma aleatória usando um algoritmo na linguagem de programação Python que sorteou e organizou os dados dessa forma.

Depois da etapa vista anteriormente, cada paciente tinha uma matriz com 26 linhas e 6 colunas, onde as 26 linhas correspondem a cada amostra de voz e as 6 colunas correspondem as variáveis mais correlacionadas.

Ao submeter essas matrizes aos algoritmos classificadores citados anteriormente, obteve-se um vetor binário, composto por 0's e 1's, o qual classifica um mesmo paciente através das 26 amostras de voz. Podendo cada paciente ser classificado como normal ao pronunciar a vogal 'a' e ser parkinsoniano ao pronunciar a vogal 'o'. Para determinar a predição final de um paciente, foi desenvolvido um algoritmo que somava a ocorrência de 0's e 1's. Ou seja, para um paciente com 26 gravações sonoras, cada linha possuía uma etiqueta: 0, se o classificador categorizava como saudável, ou 1, se o classificador o classificava como portador da doença. Se o paciente apresentasse mais 1's do que 0's, ele seria classificado como portador da doença de Parkinson; caso contrário, seria classificado como saudável. Contudo, como cada paciente possui 26 etiquetas binárias, poderia ocorrer, em alguns casos, uma quantidade igual de 0's e 1's. Esse problema de indeterminação, de fato, ocorreu em dois algoritmos diferentes. No KNN, a indeterminação surgiu tanto nos conjuntos de dados de treino quanto nos de teste. Já no SVM, o problema ocorreu apenas no conjunto de teste. Para contornar essa questão, foi analisada qual gravação sonora apresentava o maior número de erros de predição durante o treinamento nos algoritmos que apresentaram esta indeterminação, e a coluna correspondente a essa gravação foi removida, esta coluna retirada foi a coluna da 16ª amostra de voz que referia-se a uma pequena frase pronunciada, esta coluna tinha errado na classificação de 13 pacientes, portanto ela foi excluída dos algoritmos que apresentaram indeterminação para fins de votação. Com isso, o número de gravações passou a ser 25 (um número ímpar), eliminando o problema de indeterminação causado pela quantidade igual de etiquetas binárias. Após a submissão dos conjuntos de dados a estes algoritmos citados anteriormente, foi calculado as métricas de desempenho de cada algoritmo tanto no treinamento quanto no teste, e também foi elaborada uma matriz de confusão para cada treinamento e para cada teste para cada algoritmo.

5. RESULTADOS E DISCUSSÕES

Após a base dados ser submetida a metodologia explicitada anteriormente, foi apurada as métricas de avaliação dos classificadores usados, a seguir é possível visualizar estas métricas juntamente com a matriz de confusão de cada algoritmo em cada etapa (treino e teste). Para efeitos comparativos o agrupamento de métricas de treino vão ser colocadas juntas e logo após as métricas de teste. Através das métricas de cada algoritmo em cada etapa e em cada algoritmo foram construídas tabelas que podem ser vistas a seguir.

Tabela 1 – Métricas do KNN no treinamento.

Treinamento	
K-Nearest Neighbors (KNN)	
Acurácia	100%
Precisão	100%
Recall	100%
F-score	100%

Fonte: Autor, 2024.

Tabela 2 – Métricas do SVM no treinamento.

Treinamento	
Support Vector Machine (SVM)	
Acurácia	100%
Precisão	100%
Recall	100%
F-score	100%

Fonte: Autor, 2024.

Tabela 3 - Métricas do RFC no treinamento.

Treinamento	
Random Forest Classification (RFC)	
Acurácia	100%
Precisão	100%
Recall	100%
F-score	100%

Fonte: Autor, 2024.

Tabela 4 – Métricas do LR no treinamento.

Treinamento	
Logistic regression (LR)	
Acurácia	59.38%
Precisão	58.82%
Recall	62.50%
F-score	60.61%

Fonte: Autor, 2024.

De acordo com as tabelas 1, 2, 3 e 4 vistas acima, é possível notar que os algoritmos tiveram métricas semelhantes, com exceção do algoritmo de regressão logística que teve valores bem baixo de desempenho durante a fase de treinamento, então a partir disto já se podia excluir os resultados desse algoritmo por que foram bem ruins, mas para efeitos de comparação, os trabalhos com o algoritmo de RL foi continuado. A seguir serão visualizadas as métricas dos respectivos algoritmos na fase de teste.

Tabela 5 – Métricas do KNN no teste.

Teste	
K-Nearest Neighbors (KNN)	
Acurácia	75%
Precisão	75%
Recall	75%
F-score	75%

Fonte: Autor, 2024.

Tabela 6 - Métricas do SVM no teste.

Teste	
Support Vector Machine (SVM)	
Acurácia	50%
Precisão	50%
Recall	25%
F-score	33.33%

Fonte: Autor, 2024.

Tabela 7 - Métricas do RFC no teste.

Teste	
Random Forest Classification (RFC)	
Acurácia	50%
Precisão	50%
Recall	50%
F-score	50%

Fonte: Autor, 2024.

Tabela 8 - Métricas do LR no teste.

Teste	
Logistic regression (LR)	
Acurácia	62.50%
Precisão	60%
Recall	75%
F-score	66.67%

Fonte: Autor, 2024.

Com os resultados das métricas obtidos no teste, visto acima nas tabelas 5, 6, 7 e 8, já se evidencia que alguns algoritmos se comportaram melhor do que outros, e através das

tabelas vista acima, é possível destacar o desempenho positivo do KNN em relação aos outros algoritmos de classificação.

Outro ponto que precisa ser mencionado é que como a DP é uma doença progressiva, o diagnóstico precoce é de suma importância, para que com ajuda do tratamento retarde os efeitos negativos da doença sobre o indivíduo portador, com isso percebe-se, que é importante destacar métricas que refletem a capacidade do algoritmo em identificar corretamente os pacientes com Parkinson (verdadeiros positivos), e através disso minimizar o risco de diagnósticos errôneos que poderiam resultar em tratamentos tardios ou inadequados. Diante disto uma métrica importante a ser considerada é o *recall* (sensibilidade).

A seguir as matrizes de confusão de cada algoritmo no treino e no teste para ter mais elementos que ajudem a entender o comportamento desses algoritmos.

Tabela 9 – Matriz confusão do KNN.

KNN				
Treino			Teste	
16	0		3	1
0	16		1	3

Fonte: Autor, 2024.

Tabela 10 - Matriz confusão do SVM.

SVM				
Treino			Teste	
16	0		1	3
0	16		1	3

Fonte: Autor, 2024.

Tabela 11 - Matriz confusão do RFC.

RFC				
Treino			Teste	
16	0		2	2
0	16		2	2

Fonte: Autor, 2024.

Tabela 12 - Matriz confusão do RL.

LR				
Treino			Teste	
10	6		3	1
7	9		2	2

Fonte: Autor, 2024.

Com a ajuda das matrizes de confusão vistas acima, é possível confirmar o desempenho positivo do KNN sobre os demais algoritmos envolvidos, destacando o fato do

KNN só ter classificado um falso negativo, que se tratando da DP, é o pior caso que é quando o paciente tem Parkinson, mas o classificador rotulou como saudável.

Outro fator importante da matriz de confusão é que através dela é possível chegar a outros tipos de conclusões e ver como o algoritmo funciona de outras formas, por exemplo olhando para a tabela 6 e para a tabela 8, é possível ver que os valores de acurácia nos dois algoritmos foram semelhantes no teste, mas olhando para a matriz de confusão desses mesmo algoritmos no teste é possível ver que os classificadores não rotularam as classes da mesma maneira, então a matriz de confusão é um elemento que pode ajudar a decidir qual algoritmo usar dependendo da prioridade do trabalho, por exemplo se você deseja trabalhar com um classificador que de prioridade a identificação da classe verdadeiro positivo, ou então se deseja trabalhar com um modelo que priorize a identificação de falso negativo, enfim, a matriz de confusão abre essa possibilidade de analisar os algoritmos com base no desempenho da identificação de classes desejadas.

É importante destacar que os resultados apresentados neste estudo foram obtidos com base na metodologia específica adotada ao longo do desenvolvimento deste projeto. Vale ressaltar que esses resultados não devem ser interpretados como uma afirmação de que um algoritmo de classificação seja, de maneira geral, superior a outro. A eficácia de um algoritmo pode variar conforme o contexto e as particularidades do problema a ser resolvido, o que implica que não se pode afirmar que um método será sempre mais eficiente ou eficaz que outro em todas as situações.

As métricas apresentadas têm como objetivo apenas denotar qual dos algoritmos avaliados obteve o melhor desempenho dentro do escopo da tarefa de predição proposta, utilizando a abordagem metodológica descrita anteriormente. Essas métricas são específicas para o conjunto de dados utilizado e para as variáveis consideradas, e não podem ser generalizadas sem levar em conta as particularidades do contexto de aplicação. Este trabalho se restringe à comparação entre os algoritmos escolhidos, focando na avaliação de sua performance em uma tarefa específica, que envolveu as seis variáveis mais correlacionadas com o resultado da predição.

Portanto, é necessário compreender que as conclusões extraídas deste estudo se referem exclusivamente ao cenário investigado, sendo imprudente extrapolar tais resultados para outras situações ou problemas sem uma análise cuidadosa. A proposta central deste trabalho é apresentar um panorama comparativo entre as diferentes abordagens de aprendizado de máquina, ressaltando suas forças e limitações dentro do contexto específico da Doença de

Parkinson, e não estabelecer uma conclusão universal sobre a superioridade de um algoritmo sobre os demais.

6. CONCLUSÃO

Com base nas análises realizadas neste estudo, que contemplaram os valores das métricas obtidas pelos algoritmos durante as fases de treinamento e teste, e com o apoio das tabelas que ilustram as matrizes de confusão de cada algoritmo em ambos os processos, foi possível tirar conclusões importantes sobre o desempenho dos modelos de aprendizado de máquina aplicados à predição do diagnóstico da Doença de Parkinson. A partir desses resultados, constatou-se que, dentro da metodologia proposta neste trabalho, e considerando o conjunto específico de variáveis correlacionadas analisadas, o algoritmo que apresentou o melhor desempenho na tarefa de prever o diagnóstico dos pacientes foi o KNN (K-Nearest Neighbors).

A acurácia, que mede a proporção de previsões corretas feitas por um modelo, mostrou-se uma métrica relevante para a avaliação inicial dos algoritmos. No entanto, para o diagnóstico da Doença de Parkinson, é importante destacar que a acurácia por si só pode não ser a métrica mais adequada, pois ela pode ser afetada por um desbalanceamento entre as classes de diagnóstico, como casos de falso positivo ou falso negativo. Nesse sentido, a sensibilidade (ou *recall*), é de extrema importância. A sensibilidade, por exemplo, reflete a capacidade do modelo em identificar corretamente os pacientes com Parkinson (verdadeiros positivos). Para o diagnóstico de Parkinson, a sensibilidade tende a ser a métrica mais crítica, pois é fundamental detectar o maior número possível de casos positivos, minimizando o risco de diagnósticos errôneos que poderiam resultar em tratamentos inadequados.

Embora a acurácia tenha sido útil para a avaliação geral do desempenho dos algoritmos neste estudo, o *recall* (sensibilidade), como métrica de desempenho, se destaca como a mais relevante na prática clínica, pois um modelo com alta sensibilidade reduz a probabilidade de diagnósticos falsos negativos, que podem ter um impacto significativo no prognóstico dos pacientes.

Uma sugestão importante para trabalhos futuros seria expandir a análise, utilizando um número maior de variáveis correlacionadas para melhorar a precisão da predição. Além disso, seria interessante avaliar o desempenho de outros algoritmos de aprendizado de máquina, considerando abordagens distintas, como redes neurais ou métodos baseados em ensembles, para verificar se esses modelos podem oferecer resultados mais robustos e precisos, especialmente em cenários com conjuntos de dados mais complexos. A comparação de diferentes métricas de avaliação também deve ser uma prioridade em futuras investigações, de

modo a garantir que o modelo escolhido seja o mais adequado para a aplicação clínica em questão, levando sempre em conta a criticidade de minimizar erros no diagnóstico da Doença de Parkinson.

REFERÊNCIAS

- ACCIOLY, Alicia Rafaela Martinez. **Aplicação do aprendizado de máquina em imagens de ressonância magnética do neostriado para o diagnóstico da doença de Parkinson em fase precoce**. 2022. Dissertação (Mestrado em Ciências da Saúde) – Universidade Federal de Pernambuco, Recife, 2022. Disponível em: <https://repositorio.ufpe.br/bitstream/123456789/46917/1/DISSERTA%C3%87%C3%83O%20Alicia%20Rafaela%20Martinez%20Accioly.pdf>. Acesso em: 7 nov. 2024.
- ABU-MOSTAFA, Yaser S.; MAGDON-ISMAIL, Malik; LIN, Hsuan-Tien. **Learning From Data**. 2. ed. Malabar: Citrus Hill Press, 2012.
- ALTHAM, C.; ZHANG, H.; PEREIRA, E. **Machine learning for the detection and diagnosis of cognitive impairment in Parkinson's Disease: A systematic review**. PLoS One, v. 19, n. 5, p. e0303644, 2024. doi: 10.1371/journal.pone.0303644. PMID: 38753740; PMCID: PMC11098383.
- ARMSTRONG, M. J.; OKUN, M. S. **Diagnosis and treatment of Parkinson disease: A review**. JAMA, v. 323, n. 6, p. 548–560, 2020.
- BARRETO, M. A. M.; FERMOSELI, A. F. de O.; MARINHO, A. A.; DE JESUS, C. L. P. F.; DA SILVA, K. K. M. **As consequências da diminuição de dopamina produzida na substância nigra: uma breve reflexão**. Interfaces Científicas - Saúde e Ambiente, [S. l.], v. 4, n. 1, p. 83–90, 2015.
- BISHOP, Christopher M. **Pattern Recognition and Machine Learning**. New York: Springer, 2006.
- BLOOD, Marcelo R. Y. **Avaliação clínica da dor no período de wearing off de pacientes com doença de Parkinson em tratamento com levodopa**. 2016. Dissertação (Mestrado em Biologia Celular e Molecular, Fisiologia e Fisiopatologia) – Universidade Estadual de Ponta Grossa, Ponta Grossa, 2016.
- BRASIL. **Protocolo Clínico e Diretrizes Terapêuticas da Doença de Parkinson**. Brasília: Ministério da Saúde, 2017. Disponível em: https://www.gov.br/conitec/pt-br/midias/protocolos/pcdt_doenca_de_parkinson_2017-1.pdf. Acesso em: 23 out. 2024.
- BREIMAN, Leo. **Random Forests**. Machine Learning, v. 45, n. 1, p. 5-32, 2001.
- BURGES, Christopher J. C. **A tutorial on support vector machines for pattern recognition**. Data Mining and Knowledge Discovery, v. 2, n. 2, p. 121-167, 1998.
- CASTRO, Diego. **Levodopa: O que é, para que serve, quais os riscos?** Disponível em: <https://drdiegodecastro.com/levodopa/#:~:text=Com%20uma%20estrutura%20qu%C3%ADmica%20diferenciada,a%20diminui%C3%A7%C3%A3o%20da%20dopamina%20end%C3%B3gena>. Acesso em: 7 nov. 2024.

DATA GEEKS. **Coeficiente de correlação de Pearson**. 2024. Disponível em: <https://www.datageeks.com.br/coeficiente-de-correlacao-de-pearson/#:~:text=O%20coeficiente%20de%20correla%C3%A7%C3%A3o%20de%20Pearson%20%C3%A9%20representado%20pela%20letra,tamb%C3%A9m%20aumenta%20de%20maneira%20consistente>. Acesso em: 7 nov. 2024.

DIDÁTICA TECH. **O que é e como funciona o algoritmo KNN**. Disponível em: <https://didatica.tech/o-que-e-e-como-funciona-o-algoritmo-knn/>. Acesso em: 07 nov. 2024.

FERNÁNDEZ, Alberto et al. **Learning from imbalanced data sets**. Springer, 2018.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep Learning**. Cambridge: MIT Press, 2016.

HARRIS, Charles R. et al. **Array programming with NumPy**. Nature, v. 585, n. 7825, p. 357-362, 2020. Disponível em: <https://numpy.org/>. Acesso em: 11 nov. 2024.

HASHTAG TREINAMENTOS. **Regressão logística em ciência de dados**. Disponível em: <https://www.hashtagtreinamentos.com/regressao-logistica-ciencias-dados>. Acesso em: 07 nov. 2024.

HASHTAG TREINAMENTOS. **Support Vector Machine em ciência de dados**. Disponível em: <https://www.hashtagtreinamentos.com/support-vector-machine-cd>. Acesso em: 07 nov. 2024.

HASTIE, Trevor; TIBSHIRANI, Robert; FRIEDMAN, Jerome. **The elements of statistical learning: data mining, inference, and prediction**. 2. ed. New York: Springer, 2009.

HECKER, P.; STECKHAN, N.; EYBEN, F.; SCHULLER, B. W.; ARNICH, B. **Voice Analysis for Neurological Disorder Recognition-A Systematic Review and Perspective on Emerging Trends**. Front Digit Health, v. 4, p. 842301, 2022. doi: 10.3389/fdgth.2022.842301. PMID: 35899034; PMCID: PMC9309252.

HE, K.; GAGNE, M.; ROTHER, C. **Deep residual learning for image recognition**. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016.

HOSMER, David W.; LEMESHOW, Stanley. **Applied Logistic Regression**. 2. ed. New York: Wiley, 2000.

KALIA, Lorraine V.; LANG, Anthony E. **Parkinson's disease**. The Lancet, v. 386, n. 9996, p. 896-912, 2015. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/28332488/>. Acesso em: 7 nov. 2024.

KOEHRSEN, William. **Random Forest: simple explanation**. Disponível em: <https://williamkoehrsen.medium.com/random-forest-simple-explanation-377895a60d2d>. Acesso em: 07 nov. 2024.

KOTLER, Philip; KELLER, Kevin Lane. **Marketing Management**. 15. ed. Upper Saddle River: Prentice Hall, 2016.

LAI, H.; LI, X. Y.; XU, F.; ZHU, J.; LI, X.; SONG, Y.; WANG, X.; WANG, Z.; WANG, C. **Applications of machine learning to diagnosis of Parkinson's Disease**. *Brain Sci.*, v. 13, n. 11, p. 1546, 2023. doi: 10.3390/brainsci13111546. PMID: 38002506; PMCID: PMC10670005.

LEE, A.; GILBERT, R. M. **Epidemiology of Parkinson Disease**. *Neurol Clin.*, v. 34, n. 4, p. 955-965, 2016. doi: 10.1016/j.ncl.2016.06.012. Epub 2016 Aug 18. PMID: 27720003.

LIAKOS, Konstantinos G. et al. **Machine learning in agriculture: a review**. *Sensors*, v. 18, n. 8, p. 2674, 2018.

LITJENS, G.; KOOL, T.; BEJNORDI, B. E.; SETIO, A. A. A.; CIOMPI, F.; GHAFORIAN, M.; VAN DER LAAK, J. A. W. M.; VAN GINNEKEN, B.; SÁNCHEZ, C. I. **A survey on deep learning in medical image analysis**. *Med Image Anal.*, v. 42, p. 60-88, 2017. doi: 10.1016/j.media.2017.07.005. PMID: 28778026.

MARRAS, C.; LANG, A. **What is Parkinson's disease? Parkinson's Disease**, 2013. Disponível em: <https://parkinsons.org.uk>. Acesso em: 2 out. 2024.

Microsoft Corporation. **Visual Studio Code [Software]**. Disponível em: <https://code.visualstudio.com/>. Acesso em: 11 nov. 2024.

MITCHELL, Tom M. **Machine Learning**. New York: McGraw-Hill, 1997.

MONTGOMERY, Douglas C.; RUNGER, George C. **Applied Statistics and Probability for Engineers**. 6. ed. New York: Wiley, 2014.

NATIONAL INSTITUTE OF NEUROLOGICAL DISORDERS AND STROKE (NINDS). **Parkinson's Disease Information Page**. 2021. Disponível em: <https://www.ninds.nih.gov/health-information/disorders/parkinsons-disease>. Acesso em: 2 out. 2024.

PEDREGOSA, Fabian et al. **Scikit-learn: Machine Learning in Python**. *Journal of Machine Learning Research*, v. 12, p. 2825–2830, 2011. Disponível em: <https://scikit-learn.org/>. Acesso em: 11 nov. 2024.

POEWE, W.; SEPPI, K.; TANNER, C. M.; HALLIDAY, G. M.; BRUNDIN, P.; VOLKMANN, J.; SCHRAG, A. E.; LANG, A. E. **Parkinson disease**. *Nat Rev Dis Primers*, v. 3, p. 17013, 2017. doi: 10.1038/nrdp.2017.13. PMID: 28332488.

PROSENSE. **Doença de Parkinson e atividade física**. Disponível em: <https://prosense.com.br/doenca-de-parkinson-e-atividade-fisica/>. Acesso em: 07 nov. 2024.

RASCHKA, Sebastian; HUA, Vahid; MISHRA, Shubham. *Python Machine Learning*. 3. ed. Birmingham: Packt Publishing, 2019.

RESEARCHGATE. **Estruturas de dopamina e levodopa**. Disponível em: https://www.researchgate.net/figure/Figura-4-Estruturas-de-dopamina-1-e-levodopa-2_fig2_364187377. Acesso em: 07 nov. 2024.

SAMUEL, A. L. **Some studies in machine learning using the game of checkers**. 1959.

SMITH, J.; LINDEN, G. **Two decades of recommender systems at Amazon.com.** *Amazon Science*, [s.l.], 2017. Disponível em: <https://www.amazon.science/publications/two-decades-of-recommender-systems-at-amazon-com>. Acesso em: 23 out. 2024.

STANFORD MEDICINE. **Parkinson's Disease Clinic: Diagnosis.** 2022. Disponível em: <https://med.stanford.edu/parkinsons.html>. Acesso em: 2 out. 2024.

The Pandas Development Team. Pandas: **Python Data Analysis Library [Software]**. Disponível em: <https://pandas.pydata.org/>. Acesso em: 11 nov. 2024.

VAN DEN EEDEN, S. K.; TANNER, C. M.; BERNSTEIN, A. L.; FDEN EEDEN, S. K.; TANNER, C. M.; BERNSTEIN, A. L.; FROSS, R. D.; LEIMPETER, A.; BLOCH, D. A.; NELSON, L. M. **Incidence of Parkinson's disease: variation by age, gender, and race/ethnicity.** *American Journal of Epidemiology*, v. 157, n. 11, p. 1015-1022, 2003. doi: 10.1093/aje/kwg068. PMID: 12777365.

VIDAL, Samuel Estevam. **O USO DE APRENDIZADO DE MÁQUINA NO AUXÍLIO DA CLASSIFICAÇÃO DA PROGRESSÃO DA DOENÇA DE PARKINSON POR MEIO DE TESTES FUNCIONAIS.** 2021. Dissertação (Mestrado em Ciências da Saúde) – Universidade de Brasília, Brasília, 2021. Disponível em: http://icts.unb.br/jspui/bitstream/10482/42968/1/2021_SamuelEstevamVidal.pdf. Acesso em: 7 nov. 2024.

WEINTRAUB, Daniel; COMELLA, Cynthia L.; HORI, James M. **Parkinson's Disease – Part 1: Pathophysiology, Symptoms, Burden, Diagnosis, and Assessment.** *American Journal of Managed Care*, 2008. Disponível em: <https://www.ajmc.com/view/mar08-3051ps40-s48>. Acesso em: 2 out. 2024.