



VISÃO COMPUTACIONAL A SERVIÇO DO DIAGNÓSTICO DA DOENÇA DE PARKINSON

COMPUTATIONAL VISION IN THE SERVICE OF DIAGNOSING PARKINSON'S DISEASE

VISION COMPUTACIONAL AL SERVICIO DEL DIAGNÓSTICO DE LA ENFERMEDAD DE PARKINSON



10.56238/edimpecto2025.091-008

Lucas Gabriel Falcade Nunes

Estudante do curso de Bacharelado em Engenharia de Software

Instituição: Universidade do Estado de Santa Catarina

E-mail: lucas.nunes@edu.udesc.br

Orcid: <https://orcid.org/0009-0004-6885-0842>

Lattes: <http://lattes.cnpq.br/0260076133275707>

Marcelo de Souza

Doutor em Ciência da Computação

Instituição: Universidade do Estado de Santa Catarina

E-mail: marcelo.desouza@udesc.br

Orcid: <https://orcid.org/0000-0002-0786-2127>

Lattes: <http://lattes.cnpq.br/3816635191504545>

RESUMO

Este capítulo investiga a aplicação de modelos de aprendizado profundo para o diagnóstico da doença de Parkinson (DP) a partir de imagens de testes motores. O estudo explora técnicas de transfer learning em redes neurais convolucionais e compara seu desempenho com um modelo clássico de random forest. Foram exploradas três arquiteturas de redes neurais convolucionais pré-treinadas, ajustadas para a classificação binária indicando presença ou ausência da DP. Como comparação, foi implementado um modelo de random forest com extração de características por histograma de gradientes orientados. O conjunto de dados possui 204 imagens com testes dos tipos onda e espiral, os quais foram divididos em 70% para treinamento e 30% para teste. As métricas de avaliação adotadas incluem acurácia, sensibilidade e especificidade. Para desenhos do tipo onda, o MobileNetV2 obteve a maior acurácia (89,9%), enquanto o ResNet50V2 alcançou a melhor sensibilidade (93,3%). O InceptionV3 destacou-se em especificidade (100%). Para desenhos em espiral, o ResNet50V2 apresentou o melhor desempenho geral (acurácia de 86,6%). O random forest obteve acurácia máxima de 80,6%, inferior às redes neurais. Os resultados demonstram que modelos de aprendizado profundo com transfer learning são eficazes no diagnóstico auxiliado da DP. A escolha do modelo pode variar conforme a prioridade clínica. O modelo MobileNetV2 maximiza a acurácia, enquanto o ResNet50V2 maximiza a sensibilidade e o InceptionV3 minimiza casos de falsos positivos. A aplicação desenvolvida ilustra o potencial de integração dessas técnicas em ferramentas de apoio médico.



Palavras-chave: Inteligência Artificial. Aprendizagem de Máquina. Redes Neurais Artificiais. Diagnóstico Médico. Doença de Parkinson.

ABSTRACT

This chapter investigates the application of deep learning models for the diagnosis of Parkinson's disease (PD) from motor test images. The study explores transfer learning techniques in convolutional neural networks and compares their performance with a classic random forest model. Three pre-trained convolutional neural network architectures were explored, fine-tuned for binary classification indicating the presence or absence of PD. For comparison, a random forest model with feature extraction using a histogram of oriented gradients was implemented. The dataset contains 204 images with wave and spiral test images, which were divided into 70% for training and 30% for testing. The evaluation metrics adopted include accuracy, sensitivity, and specificity. For wave-type drawings, MobileNetV2 achieved the highest accuracy (89.9%), while ResNet50V2 achieved the best sensitivity (93.3%). InceptionV3 excelled in specificity (100%). For spiral drawings, ResNet50V2 showed the best overall performance (86.6% accuracy). The random forest achieved a maximum accuracy of 80.6%, lower than the neural networks. The results demonstrate that deep learning models with transfer learning are effective in aided diagnosis of PD. The choice of model may vary depending on clinical priority. The MobileNetV2 model maximizes accuracy, while ResNet50V2 maximizes sensitivity, and InceptionV3 minimizes false positives. The developed application illustrates the potential for integrating these techniques into clinical support tools.

Keywords: Artificial Intelligence. Machine Learning. Artificial Neural Networks. Medical Diagnosis. Parkinson's Disease.

RESUMEN

Este capítulo investiga la aplicación de modelos de aprendizaje profundo para el diagnóstico de la enfermedad de Parkinson (EP) a partir de imágenes de pruebas motoras. El estudio explora técnicas de aprendizaje por transferencia en redes neuronales convolucionales y compara su rendimiento con un modelo clásico de bosque aleatorio. Se exploraron tres arquitecturas de redes neuronales convolucionales preentrenadas, optimizadas para la clasificación binaria que indica la presencia o ausencia de EP. A modo de comparación, se implementó un modelo de bosque aleatorio con extracción de características mediante un histograma de gradientes orientados. El conjunto de datos contiene 204 imágenes de prueba de ondas y espirales, divididas en un 70 % para el entrenamiento y un 30 % para la prueba. Las métricas de evaluación adoptadas incluyen precisión, sensibilidad y especificidad. Para los dibujos de tipo onda, MobileNetV2 alcanzó la mayor precisión (89,9 %), mientras que ResNet50V2 logró la mejor sensibilidad (93,3 %). InceptionV3 destacó en especificidad (100 %). Para los dibujos de tipo espiral, ResNet50V2 mostró el mejor rendimiento general (86,6 % de precisión). El bosque aleatorio alcanzó una precisión máxima del 80,6 %, inferior a la de las redes neuronales. Los resultados demuestran que los modelos de aprendizaje profundo con aprendizaje por transferencia son eficaces en el diagnóstico asistido de la EP. La elección del modelo puede variar según la prioridad clínica. El modelo MobileNetV2 maximiza la precisión, mientras que ResNet50V2 maximiza la sensibilidad y InceptionV3 minimiza los falsos positivos. La aplicación desarrollada ilustra el potencial de integrar estas técnicas en herramientas de apoyo clínico.

Palabras clave: Inteligencia Artificial. Aprendizaje Automático. Redes Neuronales Artificiales. Diagnóstico Médico. Enfermedad de Parkinson.

1 INTRODUÇÃO

A doença de Parkinson (DP) é uma doença progressiva neurológica que afeta as funções motoras e cognitivas, comprometendo movimentos físicos do corpo humano. A causa desse distúrbio neurológico é a degeneração da produção neural de dopamina na região chamada *substantia nigra*. Sendo a dopamina um neurotransmissor essencial responsável na regularização dos movimentos, a dificuldade motora é um sintoma característico da DP que costuma de intensificar com o passar do tempo¹.

O diagnóstico da DP é um processo longo e complexo, uma vez que não existe um teste específico para confirmar a doença. O tempo para a obtenção de resultados concretos torna-se um prejuízo à qualidade de vida dos pacientes. Nesses casos, a tecnologia se apresenta como uma ferramenta capaz de contribuir para a melhor condução possível de diagnósticos e tratamentos. Por exemplo, Shameer et al.² destacam que algoritmos têm o potencial de aprimorar a medicina cardiovascular por meio da previsão de riscos, da fenotipagem de doenças complexas e da assistência médica. Nesse contexto, tecnologias voltadas à saúde podem auxiliar processos clínicos como diagnósticos, análise clínicas, atendimentos remotos, coleta de dados e sistemas preditivos.

Uma solução tecnológica que tem se destacado nos últimos anos é a exploração de modelos de aprendizagem de máquina para assistir e orientar processos clínicos, a exemplo do diagnóstico da DP. Essas soluções são capazes de realizar previsões com base em dados tabulares, imagens ou textos. O uso adequado dessas tecnologias possibilita ampliar o atendimento e avaliação de pacientes com sintomas de tremores, em especial aqueles com baixa mobilidade ou acesso limitado à saúde básica.

Um exemplo de aplicação de modelos de aprendizagem de máquina na identificação de doenças neurológicas é apresentado por Pereira et al.³. Os autores exploram as dinâmicas de imagens de desenhos realizados manualmente por pacientes com Parkinson, para fazer o diagnóstico da doença. São exploradas redes neurais que analisam os padrões nos desenhos a fim de detectar sinais claros da doença. O autor utiliza desenhos de meandros, ondas e espirais, bem como uma base de dados de seis diferentes tipos de exames. São exploradas duas arquiteturas de redes neurais pré-treinadas nos conjuntos ImageNet e Cifar10. Eles também exploram três abordagens clássicas para comparação: *Support Vector Machines* (SVM), *Gray Level Co-occurrence Matrix* (GLCM) e *Local Binary Patterns* (LBP). As taxas de reconhecimento da doença a partir de espirais e meandros registraram acurácia global de 65,88% e 66,36%, respectivamente. No entanto, ao combinar a metodologia de voto majoritário dos seis exames e as características aprendidas por CNNs em imagens, obteve-se uma acurácia geral de 93,50%.

Shaban⁴ aplicou *fine-tuning* da rede pré-treinada VGG-19 com o objetivo de detectar a doença de Parkinson por meio de visão computacional. Tal como Pereira et al.³, o autor explora o mesmo conjunto de dados usado neste estudo, composto por 200 imagens rotuladas. Ele aplicou técnicas de

aumentação²⁰ de dados e validação cruzada para melhor aproveitamento dos dados. Shaban⁴ reporta acurácias médias de 87% e 88% para os desenhos do tipo *wave* e *spiral*, respectivamente. A identificação de verdadeiros positivos, avaliada pela métrica de sensibilidade, apresentou valores de 87% e 89% para esses mesmos conjuntos.

Modelos de visão computacional são amplamente explorados no diagnóstico de outros tipos de doenças a partir de imagens. Exemplos incluem o diagnóstico de malária¹², câncer de pele¹³, icterícia¹⁴, COVID-19¹⁵ e Síndrome de Cushing¹⁶. A literatura também apresenta aplicações para identificação de doenças em outros seres vivos, como em folhas de plantas¹⁷, aves¹⁸ e cães¹⁹. Essas aplicações demonstram o potencial de técnicas de aprendizagem de máquina e visão computacional no suporte ao diagnóstico de doenças, contribuindo para aumentar a eficiência e melhorar o atendimento básico de saúde. Tais técnicas podem ser incorporadas a ferramentas de auxílio a profissionais de saúde, agilizando processos de triagem e possibilitando a identificação precoce de condições de saúde variadas.

Este capítulo apresenta e discute a aplicação de modelos de visão computacional para diagnóstico da DP. É adotado um conjunto de dados com imagens de exames de desenhos feitos pelos pacientes. São selecionadas redes neurais convolucionais pré-treinadas e feito seu ajuste fino para o diagnóstico a partir dessas imagens. Esses modelos são avaliados e comparados com uma alternativa mais simples, que explora modelos de *random forest*.

2 DESENVOLVIMENTO

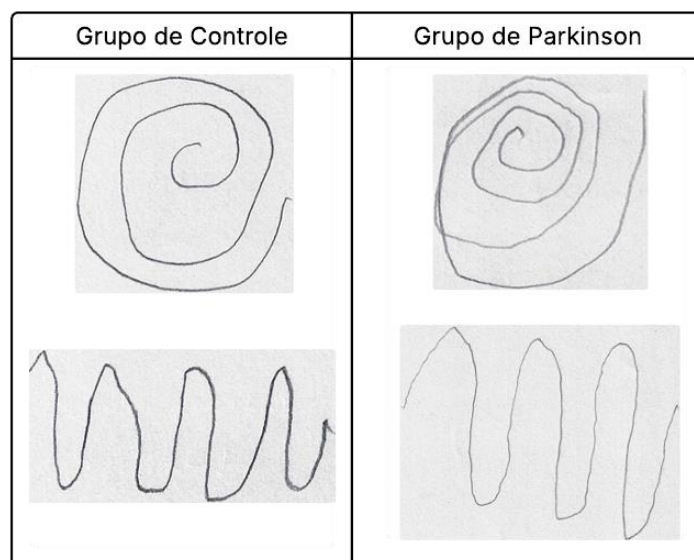
Segundo Jordan e Mitchell⁵, a aprendizagem de máquina é um dos campos da inteligência artificial de maior crescimento recente. Tais métodos transformam o processo de tomada de decisões através do uso de dados. Modelos de aprendizado supervisionado exploram os dados de entrada, extraíndo características que são usadas para construir modelos preditivos para uma ou mais variáveis de saída. Este estudo usa modelos de aprendizado supervisionado a classificação de pacientes a partir de exames de desenho, identificando a presença ou não da DP. Para todos os modelos, os dados foram separados em 70% para treinamento (ajuste dos modelos pré-treinados) e 30% para teste. Além disso, foi aplicada uma normalização de pixels para o formato binário como etapa de pré-processamento.

Conjunto de dados. O conjunto de dados é composto por 102 imagens de desenhos em espiral e 102 imagens de desenhos em ondas. Os dados são subdivididos em grupos de controle (que não apresentam a doença) e pacientes diagnosticados com Parkinson, com idade média de $71,32 \pm 7,21$ e $71,41 \pm 9,37$ anos, respectivamente. O conjunto de dados foi analisado por Zham et al.⁶ e publicado por Mader⁷. Seguindo o critério de diagnóstico no padrão *Unified Parkinson's Disease Rating Scale* (UPDRS). Os grupos analisados apresentam UPDRS iguais a 0 (grupo de controle) e 24 (pacientes

diagnosticados), que aponta DP em nível severo. A Figura 1 exemplifica desenhos dos grupos controle e DP, respectivamente.

***Fine-tuning* de modelos pré-treinados.** O *fine-tuning* é uma técnica de ajuste de modelos de aprendizagem de máquina. A técnica é aplicada a redes neurais treinadas previamente com um grande conjunto de dados e comumente com alto poder computacional. O processo de *fine-tuning* faz um novo treinamento em algumas camadas da rede neural, geralmente nas camadas finais, a fim de adaptá-la para a tarefa de interesse. Com isso, o conhecimento da rede em extrair características das imagens é aproveitado para a tarefa de classificação desejada. Esse aproveitamento é chamado de *transfer learning*. Neste estudo, os modelos selecionados foram pré-treinados no conjunto ImageNet. São refinadas as camadas finais da rede para a nova funcionalidade, ou seja, a identificação de pessoas com a DP. Em particular, foram usadas as redes MobileNetV2, ResNet50V2 e InceptionV3.

Figura 1. Amostras do tipo *spiral* (acima) e *wave* (abaixo) para pacientes com (esquerda) e sem (direita) a Doença de Parkinson.



Fonte: Mader (2017).

2.1 MOBILENETV2

A arquitetura da MobileNetV2, proposta por Sandler et al.⁸, opera redimensionando as imagens dos conjuntos de treinamento e teste para o formato 224×224 pixels, utilizando um canal de cores padrão RGB. Esse modelo, com aproximadamente 3,4 milhões de parâmetros, foi escolhido por seu alto desempenho e arquitetura adaptável a diversos problemas. A segunda versão da família MobileNet foi empregada com pesos pré-treinados no conjunto de dados ImageNet.

Para adaptar a rede ao problema específico de classificação (diagnóstico de Parkinson), as camadas finais foram refinadas. Inicialmente, um GlobalAveragePooling2D foi aplicado para reduzir a dimensionalidade da altura e largura das saídas. Em seguida, uma camada totalmente conectada com

256 neurônios e função de ativação ReLU (*Rectified Linear Unit*) foi adicionada. Por fim, a camada de saída utiliza uma função sigmoideal para produzir saídas binárias.

No treinamento do modelo final, o otimizador Adam com uma taxa de aprendizagem de 10^{-3} foi usado para ajustar os parâmetros da rede. Observou-se a presença de *overfitting* (superajuste dos dados), o que levou à inclusão de técnicas de regularização. Foram empregados regularizadores L2 com parâmetro de 10^{-2} e *dropout* com taxa de 0,5. Essas técnicas foram aplicadas ao longo de 200 épocas de treinamento para controlar a generalização do modelo e evitar que ele memorize os dados de treinamento em vez de aprender padrões.

2.2 RESNET50V2

A ResNet50V2 é uma variante da rede ResNet50, introduzida por He et al.⁹ para solucionar o problema do desvanecimento de gradientes. Essa arquitetura, construída com 50 camadas profundas e aproximadamente 25 milhões de parâmetros, foi pré-treinada utilizando o conjunto de dados ImageNet. Além do pré-processamento padrão, técnicas de *data augmentation* foram amplamente aplicadas. Isso incluiu rotações verticais e horizontais aleatórias de 20%. Adicionalmente, foram empregadas técnicas de espelhamento horizontal aleatório e cisalhamento, uma transformação geométrica que altera a direção da imagem proporcionalmente à sua distância de um eixo, conferindo maior variabilidade aos dados.

Os dados de entrada foram configurados para o padrão de 224×224 pixels, com canais de cores RGB. As camadas finais do modelo pré-treinado foram removidas e adaptadas para a tarefa de classificação específica. Para isso, aplicou-se um GlobalAveragePooling2D para reduzir as dimensões de saída, seguido por uma função de ativação ReLU. Para gerenciar o *overfitting* durante as 200 épocas de treinamento, regularizadores L2 com valores de 10^{-2} e *dropout* com taxa de 0,5 foram novamente aplicados.

2.3 INCEPTIONV3

A InceptionV3 é uma arquitetura de rede neural desenvolvida especificamente para análise de imagens, aprimorada com camadas convolucionais fatoradas e classificadores auxiliares. Essa terceira versão da família Inception foi proposta originalmente no estudo de Szegedy et al.¹⁰. Ela é composta por 48 camadas profundas e utiliza aproximadamente 23 milhões de parâmetros. O modelo foi configurado para receber imagens de entrada no formato $224 \times 224 \times 3$ pixels, seguindo o padrão de cores RGB. Assim como os outros modelos, ele se beneficiou do pré-treinamento no conjunto de dados ImageNet.

As camadas finais da InceptionV3 foram ajustadas para a tarefa de classificação com GlobalAveragePooling2D. Além disso, foram aplicados os mesmos regularizadores dos modelos

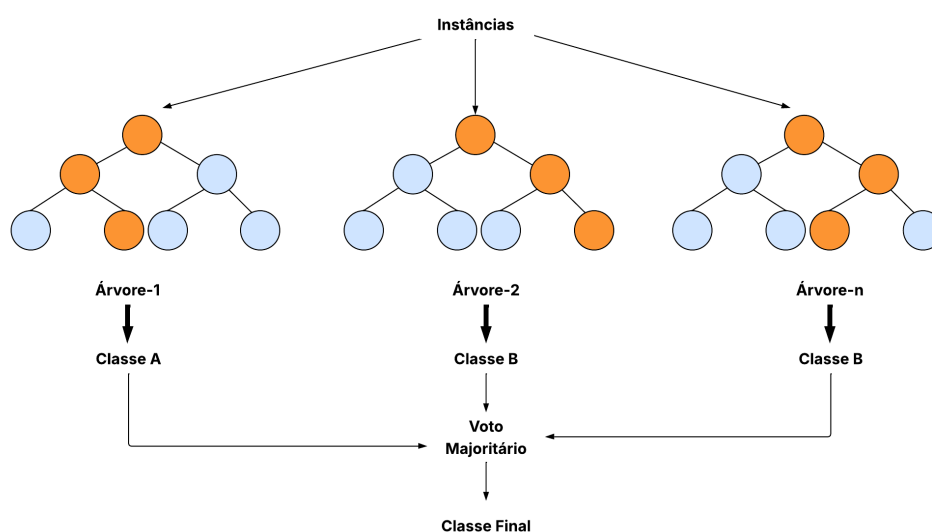
anteriores, bem como técnicas de suavização de rótulos e normalização em lote. As camadas densas, responsáveis pela predição, possuem 64 neurônios e função de ativação ReLU, seguidas por uma função sigmoidal com 1 neurônio.

2.4 RANDOM FOREST

Para fins de comparação, foi explorado ainda um modelo de *random forest*¹¹ para o diagnóstico de Parkinson, cujo funcionamento é ilustrado na Figura 3. Esses modelos criam um conjunto (floresta) de árvores de decisão individuais durante o treinamento. Para classificar uma nova amostra, cada árvore na floresta fornece uma predição, e a classificação final é determinada pela maioria dos votos. A aleatoriedade do modelo é obtida na construção do modelo. Cada árvore é construída usando um subconjunto aleatório dos dados de treinamento (processo chamado de *bagging*). Além disso, em cada etapa da construção de uma árvore apenas um subconjunto aleatório das características é considerado. Isso ajuda a reduzir o sobreajuste e melhora a generalização do modelo.

Para extração de características, foi adotada a técnica de Histograma Orientados a Gradientes (HOG), que analisa a distribuição de características em imagens e cria um vetor unidimensional para representar a estrutura de características extraídas. Tal função foi configurada com nove orientações, células de 10×10 pixels e blocos de 2×2, normalização por bloco L1 e transformação da raiz quadrada dos pixels. As imagens são redimensionadas para 200×200 pixels, convertendo-as do padrão RGB para escala de cinza. Além disso, o pré-processamento aplicado é responsável por destacar as bordas e converter as imagens para escala binária.

Figura 3. Funcionamento de modelos de *random forest*.



Fonte: Elaborado pelos autores (2025).

3 RESULTADOS E DISCUSSÃO

Após a construção dos modelos, eles foram avaliados no conjunto de teste (que contém 30% das amostras originais). A avaliação se baseia em três métricas: acurácia, sensibilidade e especificidade. A acurácia é dada pela Equação 1 e mede a taxa de acerto do modelo, i.e. a quantidade de verdadeiros positivos (VP) e verdadeiros negativos (VN) em relação ao total de predições. Valores VP são casos positivos identificados corretamente como Parkinson, e valores VN são casos negativos identificados corretamente como sem Parkinson. Por outro lado, valores de falso positivo (FP) são casos sem Parkinson identificados incorretamente como Parkinson. Valor de falso negativo (FN) são casos de pessoas com Parkinson identificadas incorretamente como sem Parkinson.

A sensibilidade é a capacidade do modelo de identificar corretamente os casos positivos, i.e. de evitar falsos negativos. A sensibilidade está expressa na Equação 2 e consiste no total de verdadeiros positivos em relação ao total de amostras positivas. Por outro lado, a especificidade é a capacidade do modelo de identificar corretamente os casos negativos, i.e. de evitar falsos positivos. A especificidade é definida pela Equação 3 e consiste no total de verdadeiros negativos (VN) em relação ao total de amostras negativas.

$$\text{Acurácia} = \frac{\text{VP} + \text{VN}}{\text{VP} + \text{VN} + \text{FP} + \text{FN}} \quad (1)$$

$$\text{Sensibilidade} = \frac{\text{VP}}{\text{VP} + \text{FN}} \quad (2)$$

$$\text{Especificidade} = \frac{\text{VN}}{\text{VN} + \text{FP}} \quad (3)$$

Os resultados da avaliação dos modelos estão apresentados na Tabela 1. São apresentados resultados para os dois grupos de amostras: *wave* e *spiral*. São apresentados os valores de acurácia, sensibilidade e especificidade para cada modelo preditivo. Os melhores valores de cada métrica são apresentados em negrito.

Conforme os dados da Tabela 1, observa-se que os modelos baseados em redes neurais convolucionais, que empregam *transfer learning*, superam o modelo de *random forest*. Para as amostras *wave*, o modelo MobileNetV2 se destaca com a maior acurácia (89,9%), indicando sua robustez na classificação geral. O ResNet50V2, por sua vez, atinge a maior sensibilidade (93,3%) para essas amostras, o que mostra que é o modelo mais eficaz em identificar corretamente os casos positivos de Parkinson. Já o InceptionV3 alcança especificidade de 100% para amostras *wave*, demonstrando que ele não produziu nenhum falso positivo, ou seja, nenhum paciente saudável foi

erroneamente diagnosticado com Parkinson. Essa alta especificidade é particularmente valiosa em contextos médicos, onde um diagnóstico incorreto pode gerar ansiedade e procedimentos desnecessários. Em contraste, o modelo de *random forest* apresentou a menor acurácia (70,6%) para as amostras *wave*, que denota um desempenho inferior àquele observado nos modelos de *deep learning*.

No cenário das amostras *spiral*, o modelo ResNet50V2 apresenta o melhor desempenho geral, com acurácia de 86,6%, sensibilidade de 80,0% e especificidade de 93,3%. Embora os modelos de rede neural ainda mostrem desempenho superior ao *random forest*, nota-se uma leve queda no desempenho geral de todas as redes para as amostras *spiral* em comparação com as amostras *wave*. Essa diferença, que se reflete em todas as métricas avaliadas, sugere que as imagens de desenhos *wave* podem conter padrões mais distintivos para o diagnóstico. O *random forest*, embora ainda com desempenho inferior às redes neurais, apresentou acurácia ligeiramente melhor para as amostras *Spiral* (80,6%) do que para as amostras *wave*, superando o modelo InceptionV3 nesse conjunto de amostras.

Os resultados confirmam o potencial das abordagens de *transfer learning* com redes neurais convolucionais para o diagnóstico de Parkinson a partir de imagens de testes motores. A escolha do modelo pode depender do critério desejado. Se a prioridade é a acurácia, MobileNetV2 para *wave* e ResNet50V2 para *spiral* se destacam. Se a redução de falsos positivos (especificidade) é importante, pode-se optar pelo modelo InceptionV3 para amostras *wave*. Se o foco é minimizar falsos negativos (sensibilidade), o modelo ResNet50V2 para *wave* se mostra mais eficaz.

Tabela 1. Resultados obtidos pelos modelos preditivos nas amostras do tipo *wave* e *spiral*. Os valores são reportados em percentual e os melhores valores estão destacados em negrito.

Modelo	Amostras	Acurácia	Sensibilidade	Especificidade
MobileNetV2	<i>Wave</i>	89,9	86,7	93,3
ResNet50V2	<i>Wave</i>	83,3	93,3	73,3
InceptionV3	<i>Wave</i>	86,6	73,3	100,0
<i>Random forest</i>	<i>Wave</i>	70,6	72,0	69,3
MobileNetV2	<i>Spiral</i>	83,3	73,3	93,3
ResNet50V2	<i>Spiral</i>	86,6	80,0	93,3
InceptionV3	<i>Spiral</i>	76,6	80,0	73,3
<i>Random forest</i>	<i>Spiral</i>	80,6	72,0	89,3

Fonte: Elaborado pelos autores (2025).

Além do estudo apresentado, foi desenvolvida uma aplicação Web que usa os modelos construídos e permite o diagnóstico de Parkinson a partir de imagens. A Figura 4 apresenta interfaces gráficas dessa aplicação com seus principais recursos. A aplicação faz a leitura dos modelos

construídos e, dada uma imagem, apresenta a classificação resultante. Para isso, o usuário escolhe quais modelos ele deseja usar (a aplicação permite selecionar quantos modelos o usuário desejar). Em seguida, ele escolhe o tipo de imagem a ser fornecida (*wave* ou *spiral*). Finalmente, o usuário pode selecionar um arquivo a ser enviado com a imagem, ou então usa o recurso de desenho na própria aplicação. Uma vez enviada a imagem, ela passa pelo mesmo pré-processamento adotado no treinamento e os modelos selecionados são executados, fornecendo suas predições. A aplicação apresenta uma tela de resultados (lado direito da Figura 4), mostrando a imagem de entrada e a classificação de cada modelo.

A aplicação foi escrita na linguagem Python, usando o *framework* Flask. Para a construção das interfaces gráficas, foram usadas as tecnologias HTML5, CSS3, Javascript e Bootstrap. Os modelos baseados em redes neurais convolucionais foram construídos usando as bibliotecas TensorFlow e Keras. O modelo de *random forest* foi construído usando a biblioteca Scikit-learn.

Figura 4. Interfaces da aplicação: tela principal (esquerda) e resultado (direita).



Fonte: Elaborado pelos autores (2025).

4 CONSIDERAÇÕES FINAIS

Este capítulo investigou a aplicação de modelos de aprendizagem de máquina para o diagnóstico da Doença de Parkinson (DP), com base em imagens de testes motores. Foram exploradas



técnicas de *transfer learning*, ajustando redes neurais convolucionais pré-treinadas para essa tarefa de classificação. Para comparação, também foi avaliado um modelo clássico de *random forest*.

Os resultados demonstram o potencial das abordagens propostas. As redes neurais convolucionais superaram o modelo de *random forest* na maioria das métricas. O modelo MobileNetV2 se destacou em acurácia para as amostras *wave*, enquanto o ResNet50V2 mostrou melhor sensibilidade nas amostras *wave* e melhor acurácia geral nas amostras *spiral*. O modelo InceptionV3 se destacou com especificidade de 100% nas amostras *wave*, eliminando falsos positivos e reforçando sua utilidade em um cenário clínico. A variação de desempenho entre os diferentes conjuntos de amostras sugere que os padrões dos desenhos *wave* podem ser mais distintivos para o diagnóstico.

Os modelos preditivos oferecem uma ferramenta para apoiar profissionais de saúde no diagnóstico precoce da DP, especialmente em locais com recursos limitados. A aplicação Web proposta ilustra essa capacidade de uso em cenários reais. No futuro, deseja-se explorar outros conjuntos de dados, com diferentes tipos de exames e um número maior de amostras. Além disso, as abordagens propostas podem ser integradas com dados obtidos por sensores de dispositivos vestíveis e Internet das Coisas (IoT).



REFERÊNCIAS

1. Poewe, W., Seppi, K., Tanner, C. M., Halliday, G. M., Brundin, P., Volkman, J., Schrag, A. E., and Lang, A. E. (2017). Parkinson disease. *Nature reviews Disease primers*, 3(1):1–21.
2. Shameer, K. et al. (2018). Translational bioinformatics in the era of real-time biomedical, health care and wellness data streams. *Briefings in Bioinformatics*, 19(1):112–124.
3. Pereira, C. R., Pereira, D. R., Silva, F. A., Masieiro, J. P., Weber, S. A. T., Hook, C., and Papa, J. P. (2016). A new computer vision-based approach to aid the diagnosis of parkinson's disease. *Computer Methods and Programs in Biomedicine*, 136:79–88. Epub 2016 Aug 26.
4. Shaban, M. (2020). Deep convolutional neural network for parkinson's disease based handwriting screening. In 2020 IEEE 17th International Symposium on Biomedical Imaging Workshops (ISBI Workshops), pages 1–4, Iowa City, IA, USA. IEEE.
5. Jordan, M. I. and Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245):255–260.
6. Zham, P., Kumar, D. K., Dabnichki, P., Poosapadi Arjunan, S., and Raghav, S. (2017). Distinguishing different stages of parkinson's disease using composite index of speed and pen-pressure of sketching a spiral. *Frontiers in Neurology*, 8:435.
7. Mader, K. S. (2017). Parkinson's drawings. Available in the Kaggle platform. URL: <https://www.kaggle.com/datasets/kmader/parkinsons-drawings>. Acessado em 15 de maio de 2025.
8. Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., and Chen, L.-C. (2018). MobileNetV2: Inverted residuals and linear bottlenecks. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 4510–4520.
9. He, K., Zhang, X., Ren, S., & Sun, J. (2016). Identity mappings in deep residual networks. In *ECCV 2016: 14th European Conference in Computer Vision, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part IV 14* (pp. 630–645). Springer International Publishing.
10. Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the Inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2818–2826).
11. Breiman, L. (2001). Random forests. *Machine Learning*, 45, 5–32.
12. Tek, F. B., Dempster, A. G., & Kale, I. (2009). Computer vision for microscopy diagnosis of malaria. *Malaria journal*, 8(1), 153.
13. Saba, T. (2021). Computer vision for microscopic skin cancer diagnosis using handcrafted and non-handcrafted features. *Microscopy Research and Technique*, 84(6), 1272–1283.
14. Sreedha, B., Nair, P. R., & Maity, R. (2023). Non-invasive early diagnosis of jaundice with computer vision. *Procedia Computer Science*, 218, 1321–1334.
15. Bhargava, A., & Bansal, A. (2021). Novel coronavirus (COVID-19) diagnosis using computer vision and artificial intelligence techniques: a review. *Multimedia tools and applications*, 80(13), 19931–19946.



16. Popp, K. H., Kosilek, R. P., Frohner, R., Stalla, G. K., Athanasoulia-Kaspar, A., Berr, C., & Schneider, H. J. (2019). Computer vision technology in the differential diagnosis of Cushing's syndrome. *Experimental and Clinical Endocrinology & Diabetes*, 127(10), 685-690.
17. Bhargava, A., Shukla, A., Goswami, O. P., Alsharif, M. H., Uthansakul, P., & Uthansakul, M. (2024). Plant leaf disease detection, classification, and diagnosis using computer vision and artificial intelligence: A review. *IEEE access*, 12, 37443-37469.
18. Soni, D. K., Taneja, A., Kumar, K. S., Salami, Z. A., & Goel, M. K. (2025, March). Automated Detection of Poultry Diseases Using Deep Learning and Computer Vision. In *2025 International Conference on Emerging Smart Computing and Informatics (ESCI)* (pp. 1-7). IEEE.
19. Burić, M., & Ivašić-Kos, M. (2025). Next-Generation Computer Vision in Veterinary Medicine: A Study on Canine Ophthalmology. *IEEE Transactions on Artificial Intelligence*.
20. Mumuni, A., & Mumuni, F. (2022). Data augmentation: A comprehensive survey of modern approaches. *Array*, 16, 100258.