

# Análise Inteligente de Espirais de Arquimedes para Identificação de Indícios de Parkinson

Thiago Vítor Gomes Pereira<sup>1</sup>, Hygo Sousa de Oliveira<sup>1</sup>,  
Eulanda Miranda dos Santos<sup>1</sup>, Lígia Reis Nóbrega<sup>2</sup>,  
Adriano Andrade de Oliveira<sup>2</sup>, Rafael Giusti<sup>1</sup>

<sup>1</sup>Instituto de Computação – Universidade Federal do Amazonas (UFAM)  
Av. General Rodrigo Octávio, 6200 – Coroado I – 69080-900 – Manaus – AM – Brasil

<sup>2</sup>Núcleo de Inovação e Avaliação Tecnológica em Saúde  
Universidade Federal de Uberlândia (UFU) – Uberlândia – MG – Brasil

{thiago.pereira,hygo.sousa,emsantos,rgiusti}@icompu.ufam.edu.br,

{adriano,ligia.nobrega}@ufu.br

**Abstract.** *Parkinson's disease is a neurological condition that impairs movement, often associated with reduced dopamine levels in the brain. The Archimedean spiral drawing, a sophisticated motor task requiring coordination, provides an accurate assessment of motor function. This research presents an innovative methodology that preprocesses images by dividing them into segments, stacking them, and summing the pixels of each to generate another image. With promising results, achieving 95.4% accuracy and an F1-Score of 97%, this approach could be a valuable tool to support specialists in diagnosing the disease.*

**Resumo.** *A doença de Parkinson é uma condição neurológica que compromete os movimentos, frequentemente associada à redução da dopamina no cérebro. O desenho da espiral de Arquimedes, uma tarefa motora sofisticada que exige coordenação, oferece uma avaliação precisa da função motora. Esta pesquisa apresenta uma metodologia inovadora que utiliza o pré-processamento das imagens, dividindo-as em segmentos, empilhando-os e somando os pixels de cada um para gerar uma imagem final. Com resultados promissores, alcançando 95,4% de acurácia e um F1-Score de 97%, esta abordagem pode ser uma ferramenta valiosa para apoiar especialistas no diagnóstico da doença.*


## 1. Introdução

A doença de Parkinson (DP) é um distúrbio neurológico degenerativo e a segunda condição neurodegenerativa mais comum no mundo [Soni and Shah 2025]. Os principais sintomas da DP incluem tremores, bradicinesia (um tipo de lentidão dos movimentos), rigidez e instabilidade postural [Kalia and Lang 2015]. A DP geralmente afeta a população mais idosa, especialmente em faixas etárias acima dos 50 anos, devido à diminuição da produção de dopamina. Estima-se que mais de 10 milhões de pessoas no mundo sofram de DP e estima-se o Brasil tenha cerca de 536 mil pacientes de DP, sendo que esse número pode subir para até 2 milhões nas próximas décadas [Schlickmann et al. 2025].

Nos últimos anos, pesquisadores têm buscado formas de aprimorar o diagnóstico e o monitoramento de doenças neurológicas como a DP, utilizando técnicas computacionais

avanzadas. Métodos baseados em inteligência artificial, especialmente *Deep Learning* (DL), têm-se mostrado propícios na análise de imagens clínicas, oferecendo uma maneira mais precisa e eficiente de detectar padrões complexos que podem passar despercebidos por métodos tradicionais.

A espiral de Arquimedes é uma forma geométrica que demanda coordenação motora para ser desenhada. Dois exemplos extraídos de duas bases de dados distintas são apresentados na Figura 1. Os sintomas da DP comprometem a execução desse tipo de traçado e, por isso, a análise desses desenhos por médicos especialistas pode contribuir para o diagnóstico da doença.



**Figura 1. Exemplos de espirais de Arquimedes extraídos de duas bases. Na base Parkinson's Drawings (esquerda), as imagens são obtidas de desenho livre. Já na base HandPD (direita), os(as) pacientes desenharam sobre uma espiral pré-desenhada.**

Neste estudo, utilizamos imagens de desenhos de espirais de Arquimedes, aplicando modelos de DL como *ResNet-50V2*, *MobileNet-V1*, *EfficientNet-B2* e *EfficientNet-B4* para a extração de características e classificação. Além disso, realizaremos um pré-processamento nas imagens para otimizar a identificação de indícios de Parkinson.

A finalidade central desta pesquisa é explorar uma nova metodologia que se diferencia das abordagens encontradas em estudos semelhantes. Além disso, buscamos utilizar modelos de baixo custo computacional, como *MobileNet-V1* e *EfficientNet-B2*, para possibilitar o desenvolvimento de uma ferramenta de apoio clínico para médicos. A utilização de desenhos de espirais de Arquimedes, combinada com a aplicação de modelos de DL, traz uma solução não invasiva e eficaz para a detecção precoce de indícios de Parkinson, contribuindo para uma avaliação mais precisa e acessível no ambiente clínico.

O restante deste artigo está organizado da seguinte forma. Na Seção 2 são apresentados estudos relacionados. Na Seção 3 é apresentado o método desta pesquisa. Na Seção 4 são discutidos os resultados e, por fim, as conclusões são apresentadas na Seção 5.

## 2. Trabalhos Relacionados

No recente estudo de [Farhah 2024] foi utilizada uma versão da base de dados *Parkinson's Drawings*<sup>1</sup>. Os autores classificaram as imagens entre indivíduos saudáveis e pacientes utilizando diferentes redes neurais convolucionais (CNN) para extração de características, seguida de diferentes redes densas para a realização da classificação em si. As redes de convolução testadas foram *VGG-19*, *InceptionV3*, *DenseNet169* e *ResNet-50V2*; já a rede densa variou de duas a três camadas ocultas. Os autores também propuseram uma metodologia de aumento de dados, devido ao pequeno tamanho da base, que contém

<sup>1</sup><https://www.kaggle.com/datasets/kmader/parkinsons-drawings>

apenas 102 imagens. O conjunto foi dividido em 80% de exemplos para treinamento e 20% para teste. O melhor desempenho foi alcançado com o modelo *InceptionV3*, que obteve uma acurácia de 89%, um resultado próximo ao obtido neste trabalho.

[Mitra et al. 2024] utilizam uma metodologia moderna com *Vision Transformers* para a detecção da DP em dados da base *New HandPD*. Os autores empregaram o modelo *ViT-16*, pré-treinado na base *ImageNet*. Esse modelo converte segmentos de  $16 \times 16$  pixels da imagem em *tokens* e classifica a imagem inteira como uma sequência desses *tokens*. Nos experimentos, os autores usaram o particionamento original de dados de treino e teste da *New HandPD*, separando 20% dos dados de teste para validação; isto resultou em 244 imagens para treino, 76 imagens de teste e 12 de validação. Após aplicar operações de aumento de dados simples como espelhamento horizontal, os autores fizeram ajuste fino do modelo por 20 épocas e obtiveram acurácia de 94,79% nos dados de teste.

[Abdullah et al. 2023] propuseram uma abordagem de pré-processamento de imagens utilizando a técnica de histograma de gradientes orientados, que consiste na extração de características baseadas na distribuição de gradientes de intensidade dentro de regiões específicas da imagem. Para a tarefa de classificação, foi empregado um modelo de florestas aleatórias, que é um *ensemble* de árvores de decisão. A base de dados foi dividida em 30% para teste e 70% para treinamento. Os resultados obtidos indicaram uma acurácia de 83,33%, uma sensibilidade de 73,33% e uma especificidade de 93,33%.

No estudo realizado em [Kamran et al. 2021] é apresentada uma combinação de quatro bases de dados. Dessas, três foram coletadas por métodos tradicionais (papel e caneta) e uma, *PaHaW*, transforma os sinais em representações de imagens. Além das imagens de espirais, a base de dados inclui outros desenhos, como meandros, ondas e círculos, resultando em um conjunto de 1.534 imagens. Os pesquisadores alcançaram uma acurácia de 99,22% após aplicar técnicas de aumento de dados no parâmetro de iluminação e remover a base *PaHaW*. Adicionalmente, os experimentos realizados com a base *NewHandPD* demonstraram uma acurácia de 88,46%, com os modelos *VGG16* e *VGG19*, na base de dados original.

[Huang et al. 2024] adotaram uma metodologia de aumento de dados que inclui duas técnicas: *PixMix* e *AugMix*. O *PixMix* é um método de aumento de dados que mistura a imagem original com outra imagem auxiliar, como uma textura, e aplica uma série de transformações para gerar uma nova imagem, enquanto o *AugMix* gera uma imagem por meio de uma soma ponderada de várias imagens aumentadas e pré-processadas. No entanto, os experimentos revelaram que abordagens mais simples de aumento de dados, como rotação e inversão das imagens horizontal ou vertical, obtiveram melhores resultados. Essa metodologia alcançou uma acurácia de 90% utilizando o modelo *VGG19* pré-treinado no *ImageNet*.

Dos trabalhos relacionados apontados, verifica-se que a abordagem mais comum na literatura é baseada na imagem inteira da espiral, com aumentos de dados simples (e.g., rotação e translação da imagem). Também é comum o uso de outros desenhos, como círculos e linhas onduladas. No que diz respeito à divisão de dados em conjuntos de treinamento e teste, observa-se a importância de realizar experimentos inter-pacientes, garantindo que imagens do mesmo indivíduo não apareçam simultaneamente nos conjuntos de treino e teste, evitando o enviesamento do modelo.

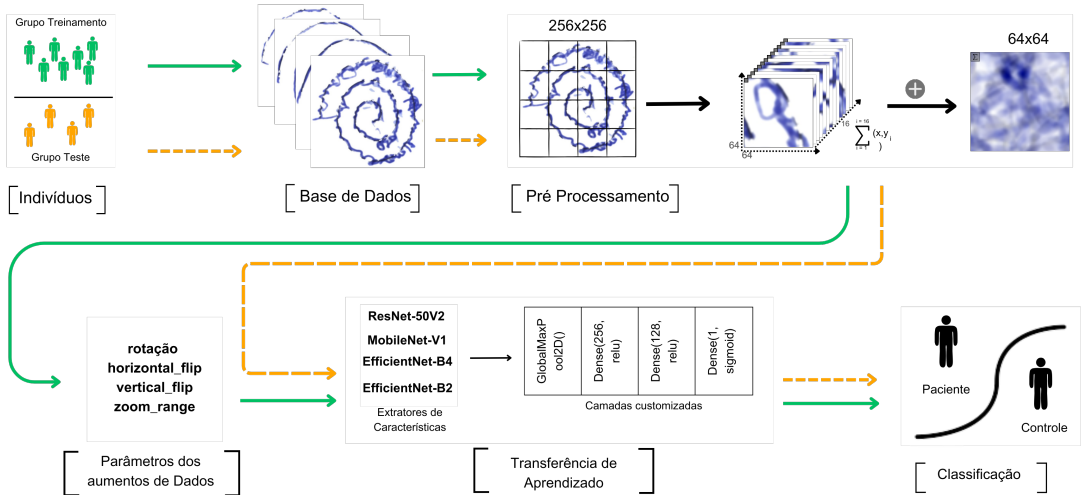
Além disso, muitos estudos empregam modelos que exigem grandes quantidades de dados, como o *ViT-16*, cuja necessidade de conjuntos de dados extensas pode ser um obstáculo. Nesse contexto, a abordagem proposta neste artigo se diferencia por utilizar um pré-processamento inovador que reduz o custo computacional e condensa a informação dos dados em um pequeno segmento, permitindo o uso de modelos mais leves. Um resumo dos resultados encontrados na literatura é apresentado na Tabela 1. Os resultados obtidos neste trabalho, que são detalhados na Seção 4, são incluídos na tabela para comparação.

**Tabela 1. Comparação de arquiteturas e bases de dados em estudos sobre DP**

Pesquisadores	Base de Dados	Arquitetura	Acurácia
Farhah 2024	Parkinson Drawings	InceptionV3	89%
Huang et al. 2024	Parkinson Drawings	VGG19	90%
Abdullah et al. 2023	Parkinson Drawings	Random Forest Classifier	83,33%
<b>Este trabalho</b>	<b>Parkinson Drawings</b>	<b>MobileNet-V1</b>	<b>85,6%</b>
Mitra et al. 2024	HandPD	VIT-16	94,79%
Kamran et al. 2021	Parkinson Drawings + HandPD	AlexNet	99,22%
Kamran et al. 2021	HandPD	VGG19	88,46%
<b>Este trabalho</b>	<b>HandPD</b>	<b>MobileNet-V1</b>	<b>95,4%</b>

### 3. Método

Esta seção descreve o método adotado nesta pesquisa. A Figura 2 apresenta uma visão geral dos passos de separação dos exemplos, pré-processamento dos dados, treinamento e aplicação do modelo.



**Figura 2. Fluxograma do Trabalho Proposto**

#### 3.1. Base de Dados

O método proposto neste trabalho foi avaliado com duas bases de dados, ambas disponíveis publicamente e consolidadas na literatura.

A base *Parkinson's Drawings* está acessível na plataforma *Kaggle*<sup>2</sup> e contém 102 imagens de espirais de Arquimedes [Mader 2019]. As imagens foram coletadas de indivíduos de idades e gêneros variados, sendo divididas igualmente em 51 imagens do

<sup>2</sup><https://www.kaggle.com/datasets/kmader/parkinsons-drawings>

grupo Paciente e 51 do grupo Controle (Figura 1-*esq.*). Em ambos os casos, o indivíduo faz um desenho livre da espiral, de dentro para fora, de maneira que o tamanho da espiral, as proporções e a quantidade de ciclos contidos na imagem podem variar.

A segunda base de dados utilizada é a *HandPD*<sup>3</sup>. Diferentemente da base anterior, os indivíduos traçaram espirais por cima de um padrão pré-definido, tentando desenhar uma espiral com tamanho, proporção e número de ciclos o mais próximo possível de um padrão ideal (Figura 1-*dir.*). Para o uso das imagens desta base nos experimentos, foi aplicado um pré-processamento para remover o padrão de espiral fixo, mantendo apenas os desenhos realizados pelos indivíduos. Após o pré-processamento, a base final passou a conter 99 imagens do grupo Controle e 294 do grupo Paciente [Pereira et al. 2016a, Pereira et al. 2016b].


### 3.2. Pré-processamento das Imagens

As imagens das duas bases são inicialmente redimensionadas para o formato  $256 \times 256 \times 3$ —*i.e.*, resolução espacial de  $256 \times 256$  pixels e 3 canais de cores. Em seguida, as imagens são segmentadas em blocos sem sobreposição de tamanho  $64 \times 64 \times 3$ , como representado na Figura 2-*Pré processamento*.

O próximo passo é realizar o “empilhamento” dos segmentos. Para uma imagem qualquer, as sub-imagens são representadas como tensores, que são somados pixel a pixel em cada canal isoladamente. O resultado é uma imagem composta, conforme ilustrado na Figura 3. Após essa soma, os pixels são normalizados pela transformação *min-max* segundo a Equação 1,

$$p'_{x,y,c} = \frac{p_{x,y,c} - \min(p_{x,y,c})}{\max(p_{x,y,c}) - \min(p_{x,y,c})}, \quad (1)$$

na qual  $p'_{x,y,c}$  corresponde ao valor normalizado do pixel  $(x, y)$  no canal de cor  $c$ ,  $p_{x,y,c}$  é o valor original, e as funções *min* e *max* representam a agregação do valor máximo e mínimo do pixel  $(x, y)$  no canal de cor  $c$  ao longo dos 16 segmentos.



**Figura 3. Exemplos de imagens “empilhadas”. Esquerda: desenho produzido por um indivíduo do grupo “Controle”. Direita: desenho produzido por um indivíduo do grupo “Paciente”.**

Após a preparação das imagens, os exemplos são separados em conjuntos de treinamento e teste, de acordo com o procedimento experimental que será adotado (*e.g.*,

<sup>3</sup><https://www.fc.unesp.br/~papa/pub/datasets/Handpd/>

validação cruzada). Em seguida, os exemplos de treinamento são submetidos a aumento de dados, uma vez que as CNNs são particularmente sensíveis ao treinamento com quantidades reduzidas de dados [Poojary et al. 2021]. Foram avaliadas diferentes técnicas de aumento de dados e as consideradas mais promissoras foram rotação, inversão horizontal, inversão vertical e variação de zoom.

A rotação envolve girar a imagem em torno de seu centro em diferentes ângulos, o que ajuda o modelo a se tornar mais robusto a mudanças de orientação nas imagens de entrada. A inversão horizontal cria uma versão espelhada da imagem ao inverter os pixels horizontalmente, o que é útil para capturar simetrias e variações horizontais no conjunto de dados. A inversão vertical inverte os pixels verticalmente, proporcionando ao modelo a capacidade de aprender variações de orientação vertical. Por fim, a variação de zoom altera a escala da imagem, simulando diferentes distâncias focais, o que ajuda o modelo a lidar com objetos de tamanhos variados dentro das imagens.

### 3.3. Modelos

Visando avaliar o equilíbrio entre custo computacional e qualidade dos resultados, foram testados quatro modelos CNNs neste trabalho. Com base na quantidade de parâmetros treináveis dos modelos, dois foram considerados de baixo custo e dois de alto custo, conforme mostrado na Tabela 2. A escolha das redes de baixo custo levou em consideração arquiteturas mais simples, com menor número de camadas e parâmetros, enquanto as redes de alto custo foram selecionadas por sua maior profundidade e complexidade, permitindo uma maior capacidade de aprendizado. Todos os modelos foram treinados com os seguintes critérios: otimizador *Adam*, *batch size* de 8 e critério de parada por *early stopping*.

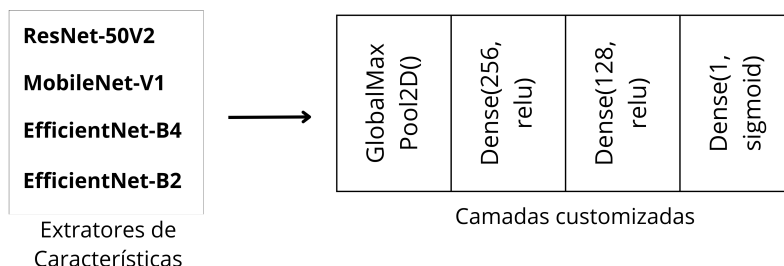
Dentre as arquiteturas consideradas de baixo custo, a família de redes *EfficientNet* destacou-se por sua eficiência em termos de consumo de recursos computacionais [Tan and Le 2019]. A *MobileNet*, por sua vez, é uma arquitetura projetada especificamente para aplicações de baixo custo, sendo ideal para construir redes neurais profundas e leves, com baixa latência, adequadas a dispositivos móveis e sistemas embarcados [Howard et al. 2017]. Além disso, a *ResNet-50* pertence à classe das redes neurais residuais, amplamente reconhecidas por sua eficiência e alta precisão na tarefa de classificação de imagens [He et al. 2016].

**Tabela 2. Quantidade de parâmetros dos modelos**

<b>Modelo</b>	<b>Parâmetros</b>
MobileNet	4.253.864
EfficientNet-B2	9.177.569
EfficientNet-B4	19.466.823
ResNet-50V2	25.613.800

Ainda, empregou-se a aprendizagem por transferência. A aprendizagem por transferência é uma técnica em aprendizado de máquina que utiliza o conhecimento adquirido em uma tarefa anterior (domínio de origem) para aprimorar o desempenho em uma nova tarefa (domínio de destino), mesmo que os dados de treinamento e teste apresentem diferenças nos espaços de características ou nas distribuições [Pan and Yang 2009].

As camadas de convolução, responsáveis pela extração de características, foram mantidas congeladas, utilizando os pesos pré-treinados de um modelo previamente treinado em uma grande base de dados. As camadas totalmente conectadas foram personalizadas para o problema específico, com ajustes finos nos parâmetros para adaptar o modelo ao nosso conjunto de dados. Essa abordagem não apenas economiza tempo de treinamento, mas também aproveita a capacidade do modelo pré-treinado de generalizar bem para novas tarefas. A Figura 4 ilustra a arquitetura do modelo, detalhando seus parâmetros e configurações de adição das camadas totalmente conectadas.



**Figura 4. Esquema da Transferência de aprendizado**


### 3.4. Validação Cruzada Estratificada

Para avaliação experimental, foi empregada uma estratégia de validação cruzada em cinco vias. A validação cruzada é uma estratégia na qual a amostra é dividida em subconjuntos que são usados sistematicamente para treinamento e teste, de modo que todos os exemplos da amostra são usados para testar uma única vez e não há sobreposição entre os dados de treinamento e de teste. A escolha por cinco vias deve-se ao equilíbrio entre viés e variância, além de sua capacidade de gerar estimativas confiáveis, mesmo em conjuntos de dados reduzidos [Kohavi 1995].

Antes de realizar a divisão dos dados em subconjuntos, eles foram estratificados por indivíduos. Esse procedimento, denominado avaliação inter-paciente, é um mecanismo de avaliação mais realista, que garante que os dados coletados de um indivíduo jamais sejam usados ao mesmo tempo para treinar e testar um classificador. É uma abordagem importante para evitar que o modelo aprenda características específicas de cada indivíduo, uma vez que os desenhos podem ser semelhantes nas imagens de um mesmo participante [Passo et al. 2021].

Além disso, os subconjuntos foram definidos de modo que cada via incluísse pelo menos dois indivíduos de cada grupo (Paciente e Controle) no conjunto de teste e treinamento. O procedimento completo é ilustrado na Figura 5.

Os resultados de cada conjunto de teste foram avaliados a partir da matriz de confusão (MC). Como existem dois grupos de classificação (Paciente e Controle), a MC é binária, ou seja, contém 4 valores possíveis: Verdadeiro Positivo (VP), Falso Positivo (FP), Verdadeiro Negativo (VN) e Falso Negativo (FN). O VP ocorre quando o modelo acerta a predição do rótulo positivo, ou seja, quando classifica corretamente o Paciente. Em contrapartida, o VN ocorre quando o modelo acerta a predição do rótulo negativo, ou seja, quando classifica corretamente o Controle. O FP ocorre quando o modelo erra a predição, classificando como positivo (Paciente), enquanto o valor verdadeiro é negativo



**Figura 5. Distribuição de dados de indivíduos em validação cruzada estratificada em cinco vias inter-paciente.**

(Controle). Por fim, o FN ocorre quando o modelo realiza a predição negativa (Controle), mas o valor verdadeiro é positivo (Paciente).

Os modelos foram avaliados de acordo com as seguintes métricas: acurácia, valor preditivo para os grupos Paciente e Controle, sensibilidade, especificidade e F1-Score. As fórmulas (que podem ser consultadas na Tabela 3) são aplicadas para cada grupo e, ao final, é calculada a média aritmética de cada métrica.

**Tabela 3. Métricas de Avaliação para Classificação**

Métrica	Fórmula
Acurácia	$\frac{VP+VN}{VP+VN+FP+FN}$
Sensibilidade	$\frac{VP}{VP+FN}$
Especificidade	$\frac{VN}{VN+FP}$
F1-Score	$2 \times \frac{VPP \times Sensibilidade}{VPP + Sensibilidade}$
Valor Predito Positivo	$\frac{VP}{VP+FP}$
Valor Preditivo Negativo	$\frac{VN}{VN+FN}$

A acurácia mede a proporção de classificações corretas em relação ao total de exemplos. O valor preditivo positivo (VPP) mede a proporção de predições positivas que estão corretas. Já o valor preditivo negativo (VPN) mede a proporção de casos preditos como negativos que realmente são negativos. A sensibilidade (também conhecida como revocação) mede a capacidade do modelo de identificar corretamente os casos positivos, ou seja, a proporção de positivos reais que foram corretamente classificados. A especi-



ficidade avalia a capacidade do modelo de identificar corretamente os casos negativos, ou seja, a proporção de negativos reais que foram corretamente classificados. Por fim, o F1-Score é uma média harmônica entre a VPP e a sensibilidade, fornecendo uma métrica equilibrada, especialmente quando há desbalanceamento entre VPP e sensibilidade.

## 4. Resultados

Nesta seção, são apresentados os resultados obtidos nos experimentos realizados com as bases de dados *HandPD* e *Parkinson's Drawings*, utilizando validação cruzada. São exibidas as métricas de desempenho dos modelos analisados, incluindo acurácia, sensibilidade, especificidade e F1-Score, permitindo uma avaliação detalhada da eficácia da abordagem proposta.

### 4.1. Classificação

Para o treinamento dos modelos e a classificação dos dados, foi utilizada validação cruzada com 5 grupos. Os experimentos foram conduzidos em duas bases de dados: *HandPD* e *Parkinson Drawings*. O desempenho dos modelos na tarefa de classificação binária foi avaliado utilizando as métricas de acurácia, valor preditivo positivo, valor preditivo negativo, sensibilidade, especificidade e F1-Score. As tabelas 4 e 5 apresentam os resultados dessas métricas para os quatro modelos analisados em cada base de dados.

**Tabela 4. Resultados dos experimentos na base de dados HandPD**

Arquitetura	Acurácia	Valor Preditivo Positivo	Valor Preditivo Negativo	Sensibilidade	Especificidade	F1-Score
<b>MobileNet-V1</b>	<b>95,4%</b>	<b>96,1%</b>	<b>93,8%</b>	<b>97,9%</b>	<b>87,7%</b>	<b>97%</b>
EfficientNet-B2	92,4%	95,4%	91,6%	97%	78,6%	95%
EfficientNet-B4	93,2%	92,2%	97,4%	99,2%	73%	97,4%
ResNet-50V2	90%	91,4%	88,2%	96,2%	79,8%	96%

A Tabela 4 apresenta resultados relevantes, com os quatro modelos alcançando acurácia superior a 90%. Os resultados obtidos pelos modelos *MobileNet-V1* e *EfficientNet-B4* demonstraram um excelente desempenho na classificação da DP a partir das imagens de espirais desenhadas pelos indivíduos. Destaca-se a *MobileNet-V1*, que apresentou a maior especificidade (87,7%) entre os modelos, além de uma acurácia de 95,4% e F1-Score de 97%.

**Tabela 5. Resultados dos experimentos na base de dados Parkinson Drawings**

Arquitetura	Acurácia	Valor Preditivo Positivo	Valor Preditivo Negativo	Sensibilidade	Especificidade	F1-Score
<b>MobileNet-V1</b>	<b>85,6%</b>	<b>84,8%</b>	<b>91,8%</b>	<b>83,6%</b>	<b>78,2%</b>	<b>83%</b>
EfficientNet-B2	79,6%	78,4%	85,5%	80,0%	69,2%	77,2%
EfficientNet-B4	80,2%	76,4%	89,5%	91,2%	62,8%	82,8%
ResNet-50V2	80,2%	80,8%	80,8%	76,0%	78,0%	76,2%

A Tabela 5 apresenta os resultados para a base de dados *Parkinson Drawings*. A arquitetura *MobileNet-V1* obteve o melhor desempenho entre os modelos avaliados, alcançando 85,6% de acurácia, 83,6% de sensibilidade e 83% de F1-Score. Embora esses valores sejam inferiores aos da tabela anterior, o desempenho se mantém comparável ao encontrado na literatura. Vale destacar que o modelo proposto opera com entradas de apenas  $64 \times 64$  pixels.

### 4.2. Análise de Resultados por Grupo na Validação Cruzada

Os resultados de cada divisão da validação cruzada mostram que o modelo *MobileNet-V1* tendia a classificar corretamente as amostras do grupo Paciente, conforme a Tabela 6. Isso é relevante em contextos clínicos. Além disso, o *MobileNet-V1* atingiu resultados bastante elevados no k-grupo, com métricas de acurácia de 97,5%, sensibilidade de 98,3%, especificidade de 95% e F1-Score de 98,3%, demonstrando desempenho robusto em imagens de indivíduos que o modelo ainda não conhecia.

**Tabela 6. Resultados por K-Grupo na base HandPD**

K-grupo	Acurácia	Valor Preditivo Positivo	Valor Preditivo Negativo	Sensibilidade	Especificidade	F1-Score
1	97,5%	100%	90,9%	96,7%	100%	98,3%
2	97,5%	98,3%	95,0%	98,3%	95,0%	98,3%
3	94,9%	93,7%	100%	100%	80,0%	96,7%
4	92,4%	92,2%	93,3%	98,3%	73,7%	95,2%
5	94,7%	96,4%	90,0%	96,4%	90,0%	96,4%

Com a base de dados *Parkinson Drawings*, observando a Tabela 7, percebe-se que o modelo *MobileNet-V1* teve dificuldades ao analisar os dados dos indivíduos pertencentes ao grupo de teste no terceiro grupo do k-grupo. No entanto, o modelo apresentou resultados interessantes no primeiro grupo, com uma acurácia de 92%, sensibilidade de 93%, especificidade de 89% e F1-Score de 93%.

**Tabela 7. Resultados por K-Grupo na base Parkinson Drawings**

K-grupo	Acurácia	Valor Preditivo Positivo	Valor Preditivo Negativo	Sensibilidade	Especificidade	F1-Score
1	92%	93%	89%	93%	89%	93%
2	89%	89%	89%	89%	89%	89%
3	80%	80%	80%	44%	95%	57%
4	80%	75%	100%	100%	50%	86%
5	87%	82%	100%	100%	67%	90%

## 5. Conclusão

O reconhecimento precoce da DP é fundamental para o início de tratamentos médicos eficazes. Nesse contexto, experimentos realizados com desenhos de espirais de Arquimedes têm-se mostrado promissores para estudos de detecção precoce da DP. Por utilizar apenas papel e caneta, o método é de baixo custo e totalmente não invasivo.

Neste trabalho, foi apresentada uma abordagem inovadora para classificação de imagens produzidas por pacientes de Parkinson. Ao segmentar uma imagem em sub-imagens de pequena dimensionalidade, foi possível classificar adequadamente os exemplos produzidos por indivíduos dos grupos Controle e Paciente, por meio de modelos de CNNs. Os resultados são comparáveis e, em alguns cenários, superiores aos encontrados na literatura. Na base de dados *HandPD*, a arquitetura do modelo *MobileNet-V1* alcançou 95,4% de acurácia, superando abordagens que utilizam modelos como *ViT-16* em [Mitra et al. 2024], que obteve 94,79%, e a *VGG19* em [Kamran et al. 2021], que atingiu 88,46%.

Enquanto os autores [Mitra et al. 2024] e [Kamran et al. 2021] separam indiscriminadamente as bases utilizadas em seus experimentos — particionando-as em subconjuntos de treino, teste e validação sem esclarecer adequadamente os critérios para evitar

o vazamento de dados entre esses conjuntos — nossa metodologia propõe a fusão das bases *HandPD* e *NewHandPD*, combinada com uma estratégia de validação cruzada na qual os subconjuntos são separados por usuário. Dessa forma, assegura-se que as imagens associadas a um mesmo indivíduo não sejam distribuídas entre subconjuntos distintos.

Além disso, diferentemente de outras abordagens que utilizam imagens completas das espirais, a estratégia aqui desenvolvida reduz a dimensionalidade das imagens ao segmentá-las e empilhá-las, otimizando a extração de padrões relevantes. Os resultados obtidos demonstram a eficácia desse método na tarefa de classificação, com um desempenho competitivo em relação a outras abordagens da literatura.

Como trabalhos futuros, pretende-se realizar novas coletas de dados para ampliar as bases atuais, que contam hoje com apenas algumas centenas de exemplos. Pretende-se também explorar novas arquiteturas de redes neurais para aprimorar o desempenho e a aplicabilidade dos modelos.

## Agradecimentos

Esta pesquisa, realizada no âmbito do Projeto Samsung-UFAM de Ensino e Pesquisa (SUPER), de acordo com o Artigo 39 do Decreto nº10.521/2020, foi financiada pela Samsung Eletrônica da Amazônia Ltda, nos termos da Lei Federal nº8.387/1991, através do convênio 001/2020 firmado com a UFAM e FAEPI, Brasil. O presente trabalho contou ainda com o apoio de outras instituições de fomento à pesquisa, como o Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) [CNPq 442150/2023-7, CNPq 405365/2023-3 e CNPq 131534/2024-6], da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) [CAPES/COFECUB-88881.370894/2019-01] e a Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG). Lígia Reis Nóbrega (153103/2024-8) é PDJ (Pós-Doutorado Júnior) do CNPq e Adriano de Oliveira Andrade (302942/2022-0) é parceiro do CNPq, Brasil.

## Referências

- Abdullah, M. I., Hao, S. K., Abdullah, I., and Faizah, S. (2023). Parkinson's disease symptom detection using hybrid feature extraction and classification model. In *2023 IEEE 14th Control and System Graduate Research Colloquium (ICSGRC)*, pages 93–98.
- Farhah, N. (2024). Utilizing deep learning models in an intelligent spiral drawing classification system for parkinson's disease classification. *Frontiers in Medicine (Lausanne)*, 11:1453743.
- He, K., Zhang, X., Ren, S., and Sun, J. (2016). Identity mappings in deep residual networks. In *Computer Vision—ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part IV 14*, pages 630–645. Springer.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., and Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.
- Huang, Y., Chaturvedi, K., Nayan, A.-A., Hesamian, M. H., Braytee, A., and Prasad, M. (2024). Early parkinson's disease diagnosis through hand-drawn spiral and wave analysis using deep learning techniques. *Information*, 15(4).

- Kalia, L. V. and Lang, A. E. (2015). Parkinson's disease. *The Lancet*, 386(9996):896–912.
- Kamran, I., Naz, S., Razzak, I., and Imran, M. (2021). Handwriting dynamics assessment using deep neural network for early identification of parkinson's disease. *Future Generation Computer Systems*, 117:234–244.
- Kohavi, R. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. In *Proceedings of the 14th International Joint Conference on Artificial Intelligence - Volume 2, IJCAI'95*, pages 1137–1143, San Francisco, CA, USA. Morgan Kaufmann Publishers Inc.
- Mader, K. S. (2019). Parkinson's Drawings Dataset. Acessado em 11 de janeiro de 2025.
- Mitra, S., Pandey, P. M., Pandey, V., and Mayuri, A. (2024). Vision transformer based approach for parkinson's disease diagnosis. In *2024 IEEE Region 10 Symposium (TENSYP)*, pages 1–6.
- Pan, S. J. and Yang, Q. (2009). A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10):1345–1359.
- Passo, S. J. G., Oliveira, H. S. d., Pinto, R. A., Quispe, K. G. M., Gusti, R., and Souto, E. J. P. (2021). Classificação de arritmias com paradigma inter e intra paciente utilizando aprendizagem profunda. *Journal of Health Informatics*, 12.
- Pereira, C. R., Pereira, D. R., Silva, F. A., Masieiro, J. P., Weber, S. A. T., Hook, C., and Papa, J. P. (2016a). A new computer vision-based approach to aid the diagnosis of parkinson's disease. *Computer Methods and Programs in Biomedicine*, 136:79–88.
- Pereira, C. R., Weber, S. A. T., Hook, C., Rosa, G. H., and Papa, J. P. (2016b). Deep learning-aided parkinson's disease diagnosis from handwritten dynamics. In *Proceedings of the SIBGRAPI 2016 - Conference on Graphics, Patterns and Images*, pages 340–346.
- Poojary, R., Raina, R., and Mondal, A. K. (2021). Effect of data-augmentation on fine-tuned cnn model performance. *IAES International Journal of Artificial Intelligence*, 10(1):84.
- Schlickmann, T. H., Tessari, M. S., Borelli, W. V., Marconi, G. A., Pereira, G. M., Zimmer, E., Noyce, A., Mata, I. F., de Mello Rieder, C. R., dos Santos, D. T., and Schumacher Schuh, A. F. (2025). Prevalence, distribution and future projections of parkinson disease in brazil: insights from the elsi-brazil cohort study. *The Lancet Regional Health - Americas*, 44:101046.
- Soni, R. and Shah, J. (2025). Unveiling the significance of synaptic proteins in parkinson's pathogenesis: A review. *International Journal of Biological Macromolecules*, page 140789.
- Tan, M. and Le, Q. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. In *International conference on machine learning*, pages 6105–6114. PMLR.