

DIAGNÓSTICO DA DOENÇA DE PARKINSON UTILIZANDO APRENDIZADO POR TRANSFERÊNCIA

Lucas Gabriel Falcade Nunes, Marcelo de Souza

INTRODUÇÃO

A doença de Parkinson (DP) é uma doença progressiva neurológica que afeta funções motoras e cognitivas, comprometendo principalmente os movimentos, o equilíbrio, a direção e a força do corpo humano. O diagnóstico é um processo complexo e longo, uma vez não existe um teste específico para confirmar a doença, impactando diretamente na qualidade de vida dos pacientes. Uma solução tecnológica é a aplicação de modelos de aprendizado de máquina para assistir e orientar processos clínicos. O presente estudo tem como objetivo apresentar a aplicação e desenvolvimento de uma ferramenta para auxiliar a avaliação da DP usando processos de identificação de tremores em desenhos. Para isso, são avaliados três modelos de aprendizado de máquina, comparando-os com uma alternativa mais simples explorando *random forest*. A avaliação de eficiência para os conjuntos de dados foi baseada na aplicação de métricas no grupo de validação dos dados.

DESENVOLVIMENTO

O *fine-tuning* é uma técnica de ajuste dos modelos de aprendizado de máquina com redes neurais treinadas previamente com um grande conjunto de dados, comumente com alto poder computacional. Tal processo consiste na aplicação de um novo conjunto de dados adaptado à nova rede para uma tarefa específica, geralmente com modificações nas camadas finais. Tal procedimento é apresentado na Figura 1B e intitula-se *transfer learning*.

A Figura 1A representa o conjunto de dados de Zham et al. (2017), composto por 102 imagens de desenhos em *spiral* e *wave*, respectivamente. O presente estudo adota como estratégia de separação do conjunto de dados uma proporção de 70% destinado para treinamento dos modelos e 30% para validação dos testes. Dessa forma, os modelos de aprendizado de máquina são capazes de mapear as características das imagens como textura, profundidade e ruído, atribuindo, pesos estatísticos para predizer novos dados. Para os dados de entrada foram aplicadas etapas de pré-processamento como normalização dos pixels em formato binário, necessárias para a rede neural.

Foram exploradas as arquiteturas MobileNetV2 proposta por Sandler et al. (2018), ResNet50V2 proposta por He et al. (2016) e InceptionV3 proposta por Szegedy et al. (2015). Para cada uma, é aplicado redimensionamento dos dados de entrada com 3 canais de cores RGB de 244, 224 e 224 pixels, respectivamente. Além disso, aplicou-se modificações nas camadas finais das redes a fim de adaptar às demandas de reconhecimento da doença de Parkinson. Desse modo, a adaptação consistiu na aplicação de um *GlobalAveragePooling* para reduzir a dimensionalidade de altura e largura das saídas, uma função *sigmoidal* e ativação *Rectified Linear Unit* (ReLU) para a camada totalmente conectada. Com o modelo final completo, o otimizador do

algoritmo Adam foi aplicado para ajustar os parâmetros da rede durante o treinamento.

Além disso, aplicou-se regularizadores como *Regularizers L2* e *Dropout* para controlar as taxas de aprendizado ao decorrer das épocas. Ainda sim, aplicou-se o classificador *random forest* como algoritmo de aprendizado supervisionado baseado em árvore de decisões. Técnicas aplicadas como o Histograma Orientado a Gradientes analisam a distribuição de características em imagens para representar as estruturas das características extraídas. O classificador, por sua vez, foi treinado com 100 árvores de decisão que se combinam para melhorar o desempenho do modelo e determinar a classe dominante com o voto majoritário.

Por fim, aplicou-se métricas de acurácia, sensibilidade e especificidade para avaliar o desempenho dos resultados obtidos. A acurácia foi adotada para medir a taxa total de acertos na classificação. Já a sensibilidade verifica a capacidade dos modelos em identificar corretamente os casos positivos (verdadeiros positivos), enquanto a especificidade avalia a capacidade em reconhecer corretamente os casos negativos (verdadeiros negativos). Tais métricas indicam o desempenho dos modelos em evitar erros, como falsos negativos e falsos positivos, durante a classificação.

RESULTADOS

Os resultados mostram o desempenho de cada rede neural aos conjuntos de dados *wave* e *spiral*. A Tabela 1 apresenta, em porcentagem, os valores referentes a cada métrica. De acordo com a Tabela 1, observa-se que os modelos de redes neurais baseados em *transfer learning* superam o modelo tradicional *random forest*. Para amostras *wave*, o modelo MobileNetV2 se destaca com maior acurácia (89,9%), indicando sua robustez na classificação geral. Em contrapartida, o modelo ResNet50V2 atingiu maior sensibilidade (93,3%) para essas amostras, indicando ser mais eficaz em identificar corretamente a doença de Parkinson.

O modelo InceptionV3 no conjunto *wave* não registrou erros na métrica de especificidade (100% de acertos), demonstrando a capacidade de identificar pacientes saudáveis. Já o modelo ResNet50V2 em casos *spiral* obteve resultados superiores ao analisar pacientes com a doença, com uma taxa de acurácia de 86,6%, sensibilidade de 80,0% e especificidade de 93,3%. Embora os modelos apresentem capacidade superior do tradicional *random forest*, nota-se uma queda de desempenho geral entre as amostras *spiral* em relação ao conjunto *wave*.

CONSIDERAÇÕES FINAIS

O estudo apresentou o desempenho dos modelos de predizer casos da DP. Os resultados evidenciaram a capacidade que os modelos de aprendizado por transferência possuem em identificar padrões e extrair características em dados de imagens. Embora seja evidente que a abordagem apropriada para o diagnóstico é dependente do objetivo clínico, conclui-se que o desenvolvimento de sistemas baseados em aprendizado de máquina são fontes promissoras para suporte ao diagnóstico de Parkinson.

Palavras-chave: Aprendizado de máquina; Redes neurais convolucionais; Aprendizado por transferência; Diagnóstico de Parkinson; Inteligência artificial;

ILUSTRAÇÕES

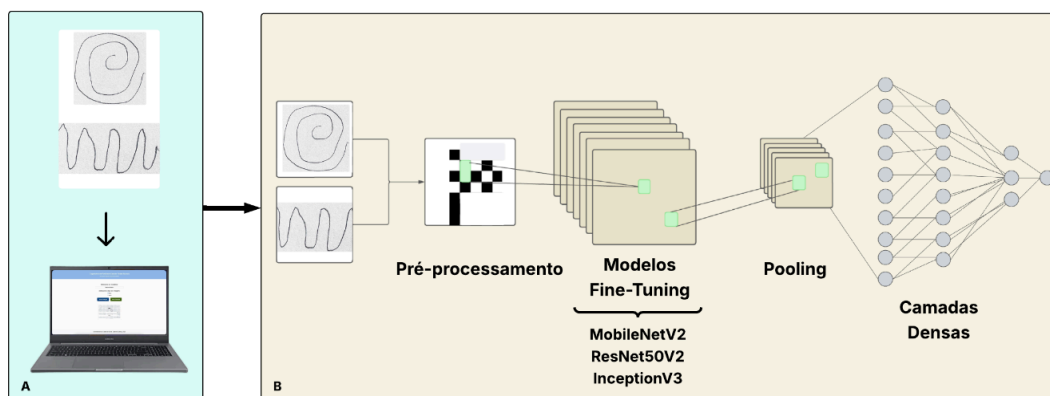


Figura 1: Ideia geral da construção dos modelos preditivos usando *transfer learning*. A) Representa os dois tipos do conjunto de dados, *wave* e *spiral*; B) Processos de *fine-tuning* de redes neurais pré-treinadas.

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	INSTÂNCIAS	ACURÁCIA	SENSIBILIDADE	ESPECIFICIDADE
MobileNetV2	Wave	89,9	86,7	93,3
ResNet50V2	Wave	83,3	93,3	73,3
InceptionV3	Wave	83,6	73,3	100,0
RandomForest	Wave	70,6	72,0	69,3
MobileNetV2	Spiral	83,3	73,3	93,3
ResNet50V2	Spiral	86,6	80,0	93,3
InceptionV3	Spiral	76,6	80,0	73,3
RandomForest	Spiral	80,6	72,0	89,3

REFERÊNCIAS BIBLIOGRÁFICAS

ZHAM, Peter et al. Distinguishing different stages of Parkinson's disease using composite index of speed and pen-pressure of sketching a spiral. *Frontiers in Neurology*, v. 8, p. 435, 2017. DOI: <https://doi.org/10.3389/fneur.2017.00435>.

SANDLER, Mark et al. MobileNetV2: Inverted Residuals and Linear Bottlenecks. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. [S.l.], 2018. p. 4510–4520. Disponível em: <https://arxiv.org/abs/1801.04381>.

HE, Kaiming et al. Identity Mappings in Deep Residual Networks. *arXiv preprint arXiv:1603.05027*, 2016. Disponível em: <https://arxiv.org/abs/1603.05027>.

SZEGEDY, Christian et al. Rethinking the Inception Architecture for Computer Vision. *arXiv preprint arXiv:1512.00567*, 2015. Disponível em: <https://arxiv.org/abs/1512.00567>.

DADOS CADASTRAIS

BOLSISTA: Lucas Gabriel Falcade Nunes

MODALIDADE DE BOLSA: PROIP/UDESC

VIGÊNCIA: Setembro/2024 a Setembro/2025 – Total: 12 meses

ORIENTADOR(A): Marcelo de Souza

CENTRO DE ENSINO: CEAVI

DEPARTAMENTO: Departamento de Engenharia de Software

ÁREAS DE CONHECIMENTO: Ciência da Computação / Metodologias e Técnicas da Computação.

TÍTULO DO PROJETO DE PESQUISA: Projeto Automático de Algoritmos

Nº PROTOCOLO DO PROJETO DE PESQUISA: NPP4054-2022