

APLICAÇÃO DE REDES NEURAIS CONVOLUCIONAIS PARA DETECÇÃO E RECONHECIMENTO DE DOENÇAS EM PLANTAS

Michel Victor Carvalho Costa¹ – Unifesspa
michelvictor@unifesspa.edu.br
Adam Dreyton Ferreira dos Santos² - Unifesspa
adamdreyton@unifesspa.edu.br

Agência Financiadora: UNIFESSPA/PNAES

Eixo Temático/Área de Conhecimento: Engenharias IV

1. INTRODUÇÃO

O advento da industrialização no setor agrícola resultou no crescimento significativo da produção de alimentos mundialmente, através da incorporação de tecnologias que viabilizaram a mecanização do campo e estudos que possibilitaram a fertilização do solo, o melhoramento genético de sementes e a criação de pesticidas mais eficazes (THORSTENSEN; GABRIEL; MESQUITA, 2019).

Embora a mecanização do campo tenha possibilitado o aumento da produção mundial de alimentos nas últimas cinco décadas, a expectativa de vida da população também aumentou consideravelmente. Estima-se que a produção de alimentos deve crescer 70% no mundo e dobrar nos países em desenvolvimento para atender a demanda alimentar da população mundial, que deve chegar a 9,1 bilhões em 2050, levando em conta as mudanças climáticas e a rápida urbanização (STEENSLAND; ZEIGLER, 2018).

Nesse cenário, um dos maiores desafios relacionados à segurança alimentar mundial são as doenças que afetam as plantas, pois sua incidência pode resultar em uma redução drástica no rendimento das lavouras. De acordo com a *Society for General Microbiology* (2011), as doenças das plantas contribuem com cerca de 10% a 16% das perdas na safra anual global, custando aproximadamente US \$220 bilhões.

Nesse contexto, o presente trabalho tem como foco realizar um estudo comparativo entre diferentes arquiteturas de redes neurais convolucionais (CNNs), quando aplicadas a classificação de doenças em plantas, com o objetivo de classificar entre 50 e 66 doenças de múltiplas espécies de plantas presentes na base de dados de doenças de plantas XDB, disponibilizada pela Embrapa (BARBEDO et al., 2018).

2. MATERIAS E MÉTODOS

Para alcançar o objetivo principal desta pesquisa, foi utilizado uma metodologia baseada em quatro fases, conforme ilustra a Figura 1.



Figura 1 - Metodologia para classificação de doenças em plantas.

¹Graduando em Sistemas de informação - Universidade Federal do Sul e Sudeste do Pará (FACEEL/IGE/Unifesspa).

²Doutor em Eng. Elétrica - Prof. Adjunto da Universidade Federal do Sul e Sudeste do Pará (FACEEL/IGE/Unifesspa).

A primeira fase compreende a organização da base dados XDB, disponível publicamente no endereço eletrônico <https://www.digipathos-rep.cnptia.embrapa.br/>. A segunda fase relaciona-se com o pré-processamentos das imagens: anotação das classes, seleção e redimensionamento das imagens, padronizando as dimensões das imagens e eliminando imagens com dimensões extremamente pequenas. Então, dez novas bases são geradas, com diferentes tamanhos e quantidades de imagens (ver Tabela 1).

Tabela 1 - Configurações das bases de dados criadas.

Denominação	Dimensão alvo	Qtd. classes	Qtd. Imagens
bd32final	32 × 32	50	35.430
bd32hard	32 × 32	66	36.558
bd40final	40 × 40	50	32.049
bd40hard	40 × 40	65	33.043
bd48final	48 × 48	50	29.020
bd48hard	48 × 48	64	29.878
bd56final	56 × 56	50	27.079
bd56hard	56 × 56	62	27.786
bd64final	64 × 64	50	25.211
bd64hard	64 × 64	60	25.778

A terceira fase é o treinamento e testes das CNNs. As arquiteturas escolhidas foram: VGG16, RestNet101v1, ResNet101v2, ResNetXt50 e DenseNet169. Foram realizadas dez execuções para cada uma das dez bases de dados, e a cada execução os conjuntos de dados eram divididos na proporção 70% para treino e 30% para teste. Ao final das execuções de cada CNN, foram obtidas médias de desempenho para as métricas de acurácia, *f1-score* e AUC nos dados de teste. A quarta etapa se dá pela análise dos resultados, assim como também pela realização do teste estatístico não-paramétrico de Friedman. Ademais, outras configurações utilizadas para os experimentos foram: Todas as CNNs foram implementadas utilizando o framework Keras (CHOLLET et al, 2020); A técnica de *data augmentation* foi aplicada com o intuito de evitar problemas de sobre-ajuste (*overfitting*); O treinamento de todos os modelos foi realizado através do uso do algoritmo *stochastic gradient descent* (POLYAK; JUDITSKY, 1992), com *momentum* igual a 0,9 e *learning rate* variável, iniciando em 10^{-3} e decaindo ao longo das épocas até no máximo $0,5 \times 10^{-6}$. Foram consideradas 200 épocas e *batch* de tamanho 64 para todas as CNNs, com redução na taxa de aprendizado pelos fatores 10^{-1} , 10^{-2} , 10^{-3} e $0,5 \times 10^{-1}$ quando o número de épocas era maior que 80, 120, 160, e 180, respectivamente, e quando o resultado no teste não melhorou após 5 épocas consecutivas.

Mais informações podem ser encontradas nos trabalhos publicados de (RESENDE; COSTA; SANTOS, 2019) e (REZENDE; COSTA; SANTOS, 2020).

3. RESULTADOS E DISCUSSÃO

Considerando a Tabela 2, através dos resultados obtidos em termo de acurácia, verificou-se que os modelos ResNetXt50 e DenseNet169 obtiveram um melhor desempenho no que tange todas as bases de dados utilizadas neste trabalho, com uma leve vantagem para a ResNetXt50. Com a finalidade de verificar significância em todas as possíveis comparações de performance par-a-par entre as CNNs, o teste estatístico não-paramétrico de Friedman foi realizado, sendo complementado pelos procedimentos *post-hoc* Shaffer e Bergmann, de forma a ajustar o valor *p* computado inicialmente.

Para aplicar o teste de Friedman, os resultados originais em termos de acurácia no teste (Tabela 2) foram convertidos por meio de uma transformação baseada em ranking. A Tabela 3 mostra o ranking computado a partir do teste de Friedman, ressaltando as CNNs ResNetXt50 e DenseNet169 como as melhores, com uma leve vantagem para a primeira, enquanto a ResNet101v2 foi considerada a pior CNN

levando em consideração todas as bases de dados desta pesquisa. Logo, é possível inferir que existe significância nas múltiplas comparações possíveis entre as CNNs. Na Tabela 4 são apresentadas todas as hipóteses de comparações e os valores p não-ajustados e ajustados pelos procedimentos *post-hoc*. É importante notar que quanto menor o valor de p , maior a significância entre os resultados das CNNs comparadas, culminando no fato de uma CNN ser melhor que a outra com um grau de confiança elevado.

Tabela 2 - Média da métrica de acurácia no teste para as bases de dados.

	VGG16	ResNet101v1	ResNet101v2	ResNetXt50	DenseNet169
bd32final	0,936	0,876	0,916	0,940	0,942
bd32hard	0,929	0,878	0,911	0,936	0,940
bd40final	0,947	0,943	0,933	0,955	0,954
bd40hard	0,941	0,939	0,930	0,950	0,949
bd48final	0,955	0,953	0,943	0,965	0,962
bd48hard	0,950	0,946	0,938	0,961	0,957
bd56final	0,959	0,959	0,951	0,966	0,962
bd56hard	0,954	0,958	0,949	0,965	0,961
bd64final	0,963	0,964	0,953	0,970	0,971
bd64hard	0,960	0,966	0,949	0,968	0,967

Tabela 3 - Ranking médio computado pelo teste de Friedman.

CNN	Ranking
ResNetXt	1,3
DenseNet169	1,7
VGG16	3,4
ResNet101v1	3,8
ResNet101v2	4,8

Tabela 4 - Valores p não-ajustado (Friedman) e ajustado (Shaffer e Bergmann) para múltiplas comparações.

Hipótese	não-ajustado	Shaffer	Bergmann
ResNet101v2 vs. ResNetXt50	7,430983723703081E-7	7,430983723703081E-6	7,430983723703081E-6
ResNet101v2 vs. DenseNet169	1,1648657367238044E-5	6,989194420342827E-5	6,989194420342827E-5
ResNet101v1 vs. ResNetXt50	4,0695201744492504E-4	0,0024417121046695503	0,0024417121046695503
VGG16 vs. ResNetXt50	0,0029794666563330327	0,017876799937998195	0,01191786662533213
ResNet101v1 vs. DenseNet169	0,0029794666563330444	0,017876799937998268	0,01191786662533213
VGG16 vs. DenseNet169	0,01620954140922542	0,06483816563690167	0,03241908281845084
VGG16 vs. ResNet101v2	0,04771488023735128	0,19085952094940511	0,19085952094940511
ResNet101v1 vs. ResNet101v2	0,1572992070502848	0,47189762115085443	0,3145984141005696
ResNetXt50 vs. DenseNet169	0,5716076449533316	1,1432152899066632	1,1432152899066632
VGG16 vs. ResNet101v1	0,5716076449533326	1,1432152899066632	1,1432152899066632

Dessa forma, conforme atesta a Tabela 4, a CNN ResNetXt50 possui uma performance significativamente superior quando comparada a ResNet101v1, ResNet101v2 e a VGG16, possuindo os melhores resultados. Por outro lado, o comparativo entre ResNetXt50 e DenseNet169 não demonstrou significância adequada para garantir qualquer inferência de performance melhor ou pior com grau de confiança satisfatório. Ao comparar o desempenho da VGG16 com a ResNet101v1, percebe-se que não há significância, enquanto a comparação entre VGG16 e ResNet101v2 sugere alguma significância, apontando certa superioridade nos resultados apresentados pela VGG16. Por fim, as hipóteses que fizeram a comparação entre o desempenho das ResNets de 101 camadas não apresentou significância.

4. CONSIDERAÇÕES FINAIS



Em geral, os experimentos desta pesquisa apontaram que as CNNs selecionadas conseguem aprender os padrões relacionados às patologias presentes nas imagens digitais de plantas doentes, sendo úteis para classificar problemas com uma variada quantidade de dados e múltiplas classes de forma satisfatória.

As principais contribuições desta pesquisa foram:

- Criação de uma ferramenta para auxiliar no controle da propagação de epidemias, contribuindo para a segurança alimentar na produção de alimentos, e utilidade para especialistas da área, possibilitando diagnósticos precoces que contribuem para a redução das perdas de lucros no setor agrícola;
- Método de pré-processamento de imagens que facilita a criação de bases de dados padronizadas, a partir de repositórios de imagens de doenças de plantas que ainda estão em desenvolvimento e possuem imagens de qualidade variada;
- Estudo comparativo entre CNNs, que comprovou a significância dos resultados obtidos para diferentes bancos de dados com múltiplas doenças de plantas, de diferentes regiões brasileiras.

Para continuar esta pesquisa, as ideias para possíveis trabalhos futuros são:

- Criação de outras bases de dados de doenças de plantas, a partir da base de dados XDB com dimensões superiores a 64×64 ;
- Combinar dois ou mais critérios para tomada de decisão sobre o melhor modelo da CNN.

REFERÊNCIAS

BARBEDO, J. G. A. et al. Annotated Plant Pathology Databases for Image-Based Detection and Recognition of Diseases. **IEEE Latin America Transactions**, v. 16, n. 6, p. 1749–1757, junho 2018.

CHOLLETET, F. et al. Framework “Keras”. Disponível em <https://keras.io>, acessado em 8 de out. 2020.

POLYAK, B. T.; JUDITSKY, A. B. Acceleration of Stochastic Approximation by Averaging. **SIAM Journal on Control and Optimization**, v. 30, n. 4, p. 838-855, julho 1992.

REZENDE, Vanessa C.; COSTA, Michel V. C.; SANTOS, Adam. Image Processing with Convolutional Neural Networks for Classification of Plant Diseases. **2019 8th Brazilian Conference on Intelligent Systems (BRACIS)**, Salvador, Brazil, setembro 2019.

REZENDE, Vanessa C.; COSTA, Michel V. C.; SANTOS, Adam. Aplicação de Redes Neurais Convolucionais na Classificação de Doenças de Plantas. **Congresso Brasileiro de Inteligência Computacional**, junho 2020.

STEENSLAND, A.; ZEIGLER, M. Agriculture for a Healthy Sustainable World. **GAP Report@2018: Global Agricultural Productivity Report**, Global Harvest Initiative, D.C (Washington), outubro 2018.

Society for General Microbiology. **Combating plant diseases is key for sustainable crops**. [S. l.], 13 abr. 2011. Disponível em: <https://www.sciencedaily.com/releases/2011/04/110411194819.htm>. Acesso em: 8 de out. 2020.

THORSTENSEN, Vera; GABRIEL, Vivian D. R.; MESQUITA, Alebe L. A participação de Brasil e estados unidos na formulação das regras multilaterais do comércio agrícola. **Revista de Direito Internacional**, Centro de Ensino Unificado de Brasília, n. 3, ed. 15, março 2019.