

Desenvolvimento de um Modelo Convolutacional Leve para Identificação de Doenças Foliare

Roney Nogueira de Sousa
Instituto Federal de Educação,
Ciência e Tecnologia do Ceará
Av. Treze de Maio, 2081 - Benfica
Fortaleza - CE

Email: roney.nogueira.sousa08@aluno.ifce.edu.br

Saulo Anderson Freitas Oliveira
Instituto Federal de Educação,
Ciência e Tecnologia do Ceará
Av. Treze de Maio, 2081 - Benfica
Fortaleza - CE

Email: saulo.oliveira@ifce.edu.br

Pedro Pedrosa Rebouças Filho
Instituto Federal de Educação,
Ciência e Tecnologia do Ceará
Av. Treze de Maio, 2081 - Benfica
Fortaleza - CE

Email: pedrosarf@ifce.edu.br

Abstract - Agricultural production faces significant annual losses due to plant diseases, with economic impacts exceeding 40 million dollars and contributing to acute hunger affecting over 281.6 million people in 2023. The identification of plant diseases through leaf image analysis is crucial to mitigate these losses. This study proposes a lightweight Convolutional Neural Network model, inspired by the MobileNet architecture, to classify various plant leaf diseases. Utilizing a public dataset, this research aims to develop a model that balances performance and computational efficiency. The proposed model achieved an accuracy of 98.94%, with precision, recall, F1-Score, and AUC metrics of 98.48%, 98.38%, 98.41%, and 99.99%, respectively. A comparative analysis was conducted with MobileNetV2 and a reference model from previous research, demonstrating the effectiveness of the proposed architecture in maintaining high performance with a reduced number of parameters.

Resumo - A produção agrícola enfrenta perdas significativas anualmente devido a doenças de plantas, com impactos econômicos superiores a 40 milhões de dólares e contribuindo para a fome aguda que afeta mais de 281,6 milhões de pessoas em 2023. A identificação de doenças de plantas por meio da análise de imagens de folhas é crucial para mitigar essas perdas. Este estudo propõe um modelo de Rede Neural Convolutacional leve, inspirado na arquitetura MobileNet, para classificar diversas doenças em folhas de plantas. Utilizando um conjunto de dados público, esta pesquisa visa desenvolver um modelo que equilibre desempenho e eficiência computacional. O modelo proposto alcançou uma acurácia de 98,94%, com métricas de precisão, recall, F1-Score e AUC de 98,48%, 98,38%, 98,41% e 99,99%, respectivamente. A análise comparativa foi realizada com o MobileNetV2 e um modelo de referência de pesquisas anteriores, demonstrando a eficácia da arquitetura

proposta em manter um alto desempenho com um número reduzido de parâmetros.

I. INTRODUÇÃO

Por ano, cerca de 30% da produção agrícola global é perdida devido a doenças nas mais diversas plantas, resultando em perdas econômicas superiores a 40 milhões de dólares anuais [1]. Além disso, há a problemática da fome aguda, a qual afetou mais de 281,6 milhões de pessoas em 2023 [2].

A identificação de doenças a partir de imagens de folhas de plantas é uma das áreas de pesquisa mais importantes na agricultura, ao ser essencial para evitar perdas na produção. Contudo, esta prática de identificação de doenças depende de elevados custos laborais, da falta de monitorização em tempo real e de erros de identificação por parte de pessoas não profissionais, aumentando a dificuldade de identificação de doenças na agricultura, conduzindo assim a declínios nos rendimentos e a problemas de segurança alimentar [3], [4]. Contudo, o estudo de [5] revela que a maioria das doenças foliares geram sintomas visíveis e por essa razão, os modelos de aprendizagem devem possuir habilidades de identificação dos sintomas característicos dessas doenças.

Para este processo de identificação de sintomas visíveis, pode-se usar de uma Rede Neural Convolutacional (RNC). Esta é um tipo de rede especializada em processamento de dados com topologia semelhante a uma grade, como, por exemplo, as imagens que têm sua representação em uma grade 2D de pixels ou dados de séries temporais que podem ser obtidos como amostras de grade 1D de um período regular [6]. A utilização deste tipo de rede, proporcionou incrementos em vários domínios, incluindo o campo da agricultura.

A tarefa de classificação de doenças em plantas utilizando de RNC já foi trabalhada por outros autores, sendo geralmente realizado esse processo com uma planta específica. Podendo ser citado, por exemplo, o trabalho de [7], o qual propôs um aplicativo mobile para identificar a ferrugem asiática da soja, atingindo uma acurácia de 84,61%. O autor [8], utilizou de uma rede AlexNet [9] modificada para o processo de identificação de doenças do arroz, alcançando uma precisão de reconhecimento de 95,4%. Sendo também utilizado do modelo de rede Inception [10] para identificação de doenças

81 em berinjela no trabalho de [11], chegando a uma acurácia de
82 95,09%.

83 A utilização de técnicas de inteligência artificial na agri-
84 cultura pode ser benéfica de inúmeras maneiras, seja na
85 solução de desafios complexos ou no incremento da eficiência
86 produtiva. O presente estudo foca no processo de diagnóstico
87 de diversas espécies de plantas utilizando de técnicas de inte-
88 ligência artificial. O objetivo principal deste trabalho é desen-
89 volver um modelo de RNC leve inspirado na rede MobileNet
90 [12] que consiga distinguir, por meio de imagens, diversas
91 doenças foliares em algumas espécies de plantas. O presente
92 artigo teve como inspiração o trabalho “*Identification of Plant
93 Leaf Diseases Using a 9-layer Deep Convolutional Neural
94 Network*” desenvolvido por [13], sendo utilizado da mesma
95 base de dados, a qual foi disponibilizada publicamente com o
96 título “*Data for: Identification of Plant Leaf Diseases Using a
97 9-layer Deep Convolutional Neural Network*”¹. Esta base de
98 dados foi disponibilizada já com os dados aumentados pelo
99 autor original, proporcionando assim uma melhor comparação
100 entre os algoritmos propostos nos trabalhos.

101 A arquitetura RNC proposta neste artigo atingiu uma
102 acurácia de 98,94%. As demais métricas de avaliação do
103 modelo foram: precisão alcançando 98,48%, o *recall* 98,38%,
104 o *F1-Score* com 98,41% e a área sob a curva ROC (do
105 inglês *Receiver Operating Characteristic Curve*) (AUC) atin-
106 gindo 99,99%. Esses resultados demonstram a capacidade do
107 modelo em fornecer classificações consistentes, mostrando a
108 sua eficácia e robustez na tarefa de classificação de doenças
109 foliares.

110 A. Organização do Documento

111 O trabalho está dividido em outras três seções, compostas
112 da seguinte forma:

113 **Seção II.** apresenta a metodologia adotada, abor-
114 dando a base de dados utilizada, como se deu o pro-
115 cesso de treinamento da rede e arquitetura proposta;
116 **Seção III.** apresenta os resultados obtidos, sendo
117 utilizado as métricas de avaliação: acurácia, precisão,
118 *recall*, *F1-Score* e AUC. Realizando comparações
119 com os resultados obtidos pelo trabalho proposto por
120 [13], além de comparar com uma rede MobileNetV2;
121 **Seção IV.** tem a função de discutir as conclusões
122 obtidas a partir dos resultados alcançados e apresenta
123 sugestões para trabalhos futuros.

124 II. METODOLOGIA

125 Este experimento teve como objetivo treinar e testar uma
126 nova arquitetura de RNC para classificação de imagens de
127 doenças foliares. Foi avaliada a capacidade da rede de identi-
128 ficar e classificar doenças nas imagens e analisar suas métricas
129 de avaliação. Todos os processos adotados para a elaboração
130 do presente estudo constam nas subseções a seguir.

A. Base de Dados

132 Foi utilizada da mesma base de dados utilizada no trabalho
133 “*Identification of Plant Leaf Diseases Using a 9-layer Deep
134 Convolutional Neural Network*”, disponibilizada publicamente
135 com o título “*Data for: Identification of Plant Leaf Diseases
136 Using a 9-layer Deep Convolutional Neural Network*”², já
137 com os dados aumentados pelo autor original.

138 O conjunto de dados inicialmente continha 54.305 imagens
139 de 13 espécies de plantas diferentes, distribuídas entre 38 clas-
140 ses de doenças que as afetam. Cada classe foi definida como
141 uma planta saudável ou infectada, sendo utilizado os rótulos
142 das doenças para classificar a doença. Além das classes de
143 doenças foliares, há também outra classe presente nesta base
144 de dados, a qual possui 1143 imagens que serão classificadas
145 como imagens de fundo. A Figura 1 mostra imagens amostrais
146 de cada uma das classes presentes na base de dados.

147 Para o aumento da disposição de imagens presentes na
148 base de dados, os autores utilizaram de transformações de
149 imagem, reduzindo assim o risco de *overfitting*. Eles utilizaram
150 das seguintes transformações: inversão de imagem, correção
151 de gama, injeção de ruído, aumento de cor PCA, rotação e
152 transformações de escala. Por fim, o tamanho do conjunto de
153 dados aumentado é de 61.486 imagens.

B. Modelos de Classificação

155 Para realizar a classificação das imagens presentes na base
156 de dados, dois modelos de RNC foram treinados, sendo o
157 modelo de RNC MobileNetV2 [14] e a arquitetura de RNC
158 proposta neste trabalho. Para a arquitetura de rede Mobile-
159 NetV2, foi utilizado do modelo pré-treinado da biblioteca
160 Torchvision, sendo este modelo carregado com os pesos pré-
161 treinados na base de dados ImageNet³.

162 O uso desses pesos pré-treinados é conhecido como *Transfer
163 Learning*, que visa transferir o conhecimento adquirido entre
164 domínios, utilizando uma rede pré-treinada, reaproveitando a
165 estrutura e os parâmetros fazendo parte de uma nova rede
166 neural para um novo domínio, podendo evitar problemas de
167 *overfitting*, uma vez que os modelos já foram regularizados e
168 generalizados durante o treinamento original [15], [16]. Essa
169 abordagem economiza tempo e recursos computacionais, en-
170 quanto ainda contribui para o desempenho na tarefa que deseja
171 ser realizada com o classificador. Para a execução deste tra-
172 balho, a máquina utilizada possui as seguintes especificações
173 técnicas:

- 174 • AMD Ryzen 5 5600X, 4,6 GHz com 6 núcleos físicos e
175 12 threads;
- 176 • Memória RAM de 32 GB;
- 177 • Unidade de armazenamento de 1,5 TB;
- 178 • Placa de vídeo NVIDIA GeForce RTX 2060 Super, com
179 8 GB de memória dedicada.

180 As duas RNC passaram por um treinamento com um total
181 de 3.000 épocas. Contudo, foi utilizada da *callback* de *early
182 stopping* durante o treinamento do modelo, tendo o objetivo de

¹<https://data.mendeley.com/datasets/tywbtsjrjv/1>

²<https://data.mendeley.com/datasets/tywbtsjrjv/1>

³<https://image-net.org/>



Figura 1. Exemplos de Amostras da Base de Dados

183 evitar o *overfitting* do modelo, sendo monitorada a métrica de
 184 *F1-Score*, interrompendo o treinamento quando essa métrica
 185 não melhorar a cada 50 épocas. Caso o modelo não melhore
 186 o *F1-Score* ao fim desse intervalo, o treinamento é encerrado
 187 e os pesos obtidos na melhor época é restaurado.

188 Cada época de treinamento consistiu na exposição de todas
 189 as imagens presentes no conjunto de treino à rede. Após a
 190 conclusão de cada época, o estado atual da rede foi avaliado
 191 usando o conjunto de validação, sendo registrados os resulta-
 192 dos desse estágio. Após o término completo do processo de
 193 treinamento, os dois modelos foram submetidos a um teste
 194 utilizando o conjunto de teste, permitindo uma avaliação final
 195 do desempenho alcançado.

196 Assim como no artigo de inspiração, foram realizados testes
 197 com base em 2 cenários diferentes: (i) Cenário 1: sem utilizar
 198 o processo aumento de dados, e (ii) Cenário 2, utilizando do
 199 processo de aumento de dados. Essa análise será realizada para
 200 verificação de qual cenário a rede terá um melhor resultado,
 201 avaliando assim impactos da disponibilidade de dados na
 202 aprendizagem do modelo.

203 C. Lightweight Disease Prediction Network

204 A arquitetura da RNC proposta, intitulada de *Lightweight*
 205 *Disease Prediction Network* (LDPNet) foi projetada com
 206 inspiração nos princípios das redes MobileNet, as quais usam
 207 de convoluções separáveis em profundidade. O uso dessas
 208 convoluções reduz significativamente o número de parâmetros
 209 e operações computacionais realizadas pelo modelo, mas ainda
 210 mantém um bom desempenho. O *design* da RNC proposta
 211 incorpora camadas convolucionais e de *pooling*, permitindo
 212 a extração de características em diferentes níveis, similar à
 213 arquitetura MobileNet original, porém utilizando de poucos

214 parâmetros. A Tabela I mostra um comparativo da quantidade
 215 de parâmetros entre cada uma das arquiteturas utilizadas no
 216 presente estudo

Tabela I
 COMPARATIVO DA QUANTIDADE DE PARÂMETROS DAS ARQUITETURAS

Modelo	Total de Parâmetros
LDPNet	1.817.063
MobileNetV2	2.273.831
Modelo do Artigo de Referência	2.672.735

217 Como ilustrado na Tabela I, a LDPNet possui a menor
 218 quantidade de parâmetros entre os modelos comparados. Refle-
 219 tando a eficácia dessa abordagem em simplificar a arquitetura
 220 sem comprometer o desempenho. A menor quantidade de
 221 parâmetros pode levar a uma redução na necessidade de
 222 recursos computacionais, enquanto ainda oferece um bom
 223 desempenho.

224 A arquitetura da RNC proposta é ilustrada na Figura 2.
 225 Ela inicia com uma camada convolucional básica, seguida de
 226 uma camada de *batch normalization* e uma função de ativação
 227 ReLU, após essas camadas iniciais, há uma série de blocos
 228 MobileNet. Estes blocos são compostos por uma convolução
 229 separável em profundidade e uma convolução ponto-a-ponto,
 230 fazendo com que a rede aprenda filtros espaciais independentes
 231 para cada canal de entrada. Ainda nestes blocos, após cada
 232 convolução ponto-a-ponto, é aplicada uma camada de *batch*
 233 *normalization* e uma função de ativação ReLU.

234 Após a última camada convolucional do modelo, os mapas
 235 de características são reduzidos a um vetor de características
 236 por meio de uma camada de *pooling* adaptativo, reduzindo
 237 a dimensionalidade dos mapas de características para um




Figura 2. Arquitetura da Rede Neural Convolutiva Proposta

238 tamanho de 1×1 . Este vetor é então passado para uma camada
 239 densa que utiliza a função de ativação *softmax* para prever
 240 as probabilidades das 39 classes. Essa arquitetura simplificada
 241 mostra que, mesmo com um número reduzido de parâmetros,
 242 é possível alcançar um desempenho eficiente e robusto, sus-
 243 tentando a hipótese de que a redução da complexidade pode
 244 beneficiar a prática ao manter um equilíbrio entre eficiência e
 245 precisão.

246 Para uma análise mais detalhada da arquitetura, a Tabela
 247 II apresenta a configuração das camadas da rede proposta,
 248 incluindo o tipo de camada, a quantidade de parâmetros e
 249 a saída de cada camada.

Tabela II
 CONFIGURAÇÃO DAS CAMADAS DA REDE NEURAL CONVOLUCIONAL
 PROPOSTA

Tipo	Saída	Parâmetros
Convolutiva	$64 \times 64 \times 32$	896
Batch Normalization	$64 \times 64 \times 32$	128
Bloco MobileNet 1	$64 \times 64 \times 64$	2.432
Bloco MobileNet 2	$32 \times 32 \times 128$	9.152
Bloco MobileNet 3	$16 \times 16 \times 256$	35.328
Bloco MobileNet 4	$8 \times 8 \times 512$	138.576
Bloco MobileNet 5	$8 \times 8 \times 1024$	1.055.328
Global Average Pooling	$1 \times 1 \times 1024$	0
Densa	39	39.975

III. RESULTADOS E DISCUSSÕES

250 Na presente Seção, será discutido os resultados obtidos
 251 a partir da metodologia apresentada na Seção II para a
 252 classificação de doenças foliares a partir de imagens.
 253

A. Resultados Cenário 1

254 Nesta subseção, apresentamos o desempenho das arquite-
 255 turas de Redes Neurais Convolutivas (RNC) sem o uso
 256 de aumento de dados, analisando como a disponibilidade de
 257 dados influencia o processo de aprendizagem dos modelos.
 258 As métricas de avaliação, obtidas no conjunto de testes, estão
 259 ilustradas na Figura III.
 260

Tabela III
 COMPARAÇÃO DE DESEMPENHO NO CENÁRIO 1

Métrica	MobileNetV2	LDPNet
Acurácia	94,69%	98,64%
Precisão	93,94%	98,16%
Recall	92,81%	97,75%
F1-Score	93,02%	97,93%
AUC	99,04%	99,98%

261 Ao comparar o desempenho dos dois modelos no Cenário 1,
 262 observa-se que a arquitetura proposta superou o MobileNetV2
 263 em todas as métricas principais, exceto na AUC, onde ambos
 264 os modelos apresentaram um bom desempenho.

265 A tabela de resultados indica que a LDPNet atingiu uma
 266 acurácia de 98,64%, enquanto o MobileNetV2 ficou em
 267 94,69%, uma diferença de quase 4 pontos percentuais, o que
 268 sugere que o modelo proposto oferece uma classificação geral
 269 mais precisa. Em termos de precisão, a LDPNet alcançou
 270 98,16%, demonstrando uma taxa de falsos positivos infe-
 271 rior à do MobileNetV2, que apresentou 93,94%, indicando
 272 maior eficácia em evitar tratamentos desnecessários em plan-
 273 tas saudáveis. O recall do modelo proposto foi de 97,75%,
 274 superior aos 92,81% do MobileNetV2, mostrando uma maior
 275 capacidade de identificar corretamente plantas doentes. No F1-
 276 Score, a LDPNet manteve um equilíbrio mais eficaz entre
 277 precisão e recall, com 97,93%, superando o MobileNetV2,
 278 que obteve 93,02%. Por fim, a métrica de AUC da LDPNet
 279 foi de 99,98%, enquanto o MobileNetV2 obteve 99,04%, o
 280 que indica que, embora ambos os modelos tenham mostrado
 281 capacidade discriminativa, o modelo proposto teve um desem-
 282 penho superior.

283 Os resultados obtidos no Cenário 1 revelam que a LDPNet,
 284 embora mais simples e menos complexo que o MobileNetV2,
 285 conseguiu alcançar um desempenho superior. Isso indica que
 286 a simplificação do modelo não comprometeu a qualidade das
 287 previsões, mas sim potencializou a capacidade do modelo
 288 de lidar com a tarefa específica de classificação de doenças

289 foliares. Esses resultados sugerem é que a redução na comple- 335
290 xidade da arquitetura não só preservou o desempenho, como 336
291 também proporcionou uma solução mais prática e viável para 337
292 a tarefa proposta. Essa eficiência estrutural é o verdadeiro 338
293 diferencial do modelo, que demonstra que não é necessário 339
294 recorrer a arquiteturas mais complexas e pesadas para alcançar 340
295 capacidade generalização e desempenho. 341

296 B. Resultados Cenário 2

297 Esta subseção visa mostrar o desempenho das arquiteturas 342
298 de RNC quando se é utilizado de processos de aumento de 343
299 dados, verificando assim se uma maior disponibilidade de da- 344
300 dos pode impactar positivamente no processo de aprendizagem 345
301 dos modelos. Essas métricas de avaliação são demonstradas na 346
302 Tabela IV. 347

Tabela IV
RESULTADOS NO CONJUNTO DE TESTES NO CENÁRIO 2

Métrica	MobileNetV2	LDPNet
Acurácia	97,89%	98,94%
Precisão	97,36%	98,48%
Recall	97,13%	98,38%
F1-Score	97,20%	98,41%
AUC	99,96%	99,99%

303 No Cenário 2, observou-se que a aplicação de técnicas de 352
304 aumento de dados resultou em melhorias em todas as métricas 353
305 avaliadas para ambos os modelos. A LDPNet apresentou uma 354
306 melhoria geral nas métricas em comparação ao Cenário 1: a 355
307 acurácia aumentou para 98,94%, com um incremento de 0,30 356
308 pontos percentuais; a precisão subiu para 98,48%, um aumento 357
309 de 0,32 pontos percentuais; o recall alcançou 98,38%, com 358
310 uma melhora de 0,63 pontos percentuais; o F1-Score subiu 359
311 para 98,41%, melhorando 0,48 pontos percentuais; e a AUC 360
312 atingiu 99,99%, uma leve elevação de 0,01 pontos percentuais. 361

313 Para o MobileNetV2, o aumento nos dados também foi 362
314 benéfico. A acurácia melhorou para 97,89%, um ganho de 363
315 3,20 pontos percentuais; a precisão subiu para 97,36%, com 364
316 um incremento de 3,42 pontos percentuais; o recall alcançou 365
317 97,13%, uma melhoria de 4,32 pontos percentuais; o F1-Score 366
318 aumentou para 97,20%, melhorando 4,18 pontos percentuais; 367
319 e a AUC foi de 99,96%, uma melhoria de 0,02 pontos 368
320 percentuais. 369

321 Em resumo, o aumento de dados demonstrou ser um fator 370
322 significativo para melhorar a capacidade de generalização e 371
323 o desempenho dos modelos, tanto para o modelo proposto 372
324 quanto para o MobileNetV2. No entanto, a LDPNet não apenas 373
325 se beneficiou dessas técnicas, mas também se destacou pela 374
326 sua simplicidade e eficiência superior. A análise reforça que, 375
327 enquanto técnicas de aumento de dados são essenciais para oti- 376
328 mizar o desempenho dos modelos em contextos desafiadores, 377
329 a combinação de uma arquitetura simplificada com aumento 378
330 de dados pode oferecer uma solução mais prática e eficiente 379
331 para a tarefa de classificação de doenças foliares. 380

332 C. Comparação com o Artigo de Referência

333 Esta subseção compara os resultados obtidos com os apre- 381
334 sentados no artigo “Identification of plant leaf diseases using

a nine-layer deep convolutional neural network” [13], que 335
inspirou este trabalho. O objetivo é avaliar o desempenho 336
relativo dos modelos de redes neurais convolucionais desen- 337
volvidos, destacando as melhorias alcançadas e o impacto da 338
simplificação da arquitetura. 339

A arquitetura do artigo de referência, composta por 340
múltiplas camadas convolucionais e de *pooling* seguidas por 341
camadas densas, representa uma abordagem clássica e re- 342
lativamente complexa para a tarefa de classificação, totali- 343
zando 2.672.735 parâmetros. Em contraste, o modelo pro- 344
posto neste trabalho é mais simples, refletindo uma redução 345
significativa na complexidade estrutural, com um total de 346
1.817.063 parâmetros. Essa redução de aproximadamente 32% 347
no número de parâmetros não apenas torna o modelo mais 348
leve, mas também evidencia que é possível alcançar um 349
desempenho competitivo sem a necessidade de um modelo 350
excessivamente complexo. 351

Uma limitação do artigo de referência é a falta de avaliação 352
em um conjunto de teste sem técnicas de aumento de dados, 353
reportando apenas a acurácia no conjunto de validação como 354
91,43%. A ausência de testes sem aumento de dados limita a 355
avaliação completa da capacidade de generalização do modelo. 356
Assim, a comparação aqui é baseada apenas no cenário com 357
aumento de dados. 358

A Tabela V apresenta uma comparação entre as métricas de 359
desempenho da LDPNet e do modelo do artigo de referência, 360
considerando acurácia, precisão, *recall* e *F1-Score*. 361

Tabela V
COMPARAÇÃO DAS MÉTRICAS DE AVALIAÇÃO COM O ARTIGO DE REFERÊNCIA

Métrica	Modelo de Referência	LDPNet
Acurácia	96,46%	98,94%
Precisão	96,47%	98,48%
Recall	99,89%	98,38%
F1-Score	98,15%	98,41%

Os resultados da Tabela V evidenciam que a LDPNet 362
alcançou 98,94%, superando o modelo de referência em 2,48 363
pontos percentuais. Isso indica uma capacidade superior do 364
modelo simplificado em realizar previsões corretas, supor- 365
tando a hipótese de que a simplificação pode ser eficaz sem 366
sacrificar a precisão geral. Com 98,48%, o modelo proposto 367
é 2,01 pontos percentuais melhor que o modelo de referência. 368
Isso sugere que a redução da complexidade pode ter con- 369
tribuído para uma melhor eficiência na minimização de falsos 370
positivos, um aspecto crucial, na prática de diagnóstico de 371
doenças. O modelo de referência obteve um *recall* de 1,51 372
pontos percentuais superiores aa LDPNet. Embora o modelo 373
de referência tenha mostrado maior capacidade em identificar 374
casos positivos, a diferença é relativamente pequena e pode 375
refletir a eficácia da arquitetura mais simples em manter 376
um bom desempenho geral. O modelo proposto alcançou 377
98,41%, superando o modelo de referência por 0,26 pontos 378
percentuais. Este resultado demonstra que, apesar da redução 379
na complexidade, a LDPNet conseguiu equilibrar efetivamente 380
precisão e *recall*. 381

382 Em resumo, a LDPNet supera o modelo de referência em
383 acurácia, precisão e *F1-Score*, enquanto o modelo de refer-
384 ência tem um *recall* ligeiramente superior. Esses resultados
385 confirmam que a simplificação da arquitetura pode oferecer
386 uma solução prática e eficiente, mantendo um desempenho
387 robusto. A abordagem simplificada, ao mesmo tempo, em que
388 melhora a acurácia e a precisão, demonstra que é possível
389 alcançar alta eficiência com modelos menos complexos, sem
390 a necessidade de estruturas excessivamente complicadas.

391 IV. CONCLUSÃO E TRABALHOS FUTUROS

392 Este estudo descreveu a proposta de uma arquitetura CNN
393 baseada no modelo MobileNet, visando classificar imagens
394 de doenças foliares em 13 espécies vegetais diferentes. A
395 arquitetura proposta foi testada em dois cenários: com e sem
396 aumento de dados, e os resultados foram comparados com o
397 MobileNetV2 e o modelo do estudo de referência.

398 No Cenário 1, a rede proposta demonstrou um desempe-
399 nho superior em todas as métricas em comparação com o
400 MobileNetV2. A RNC alcançou uma acurácia de 98,64%,
401 uma precisão de 98,16%, um *recall* de 97,75%, um *F1-*
402 *Score* de 97,93% e uma AUC de 99,98%, destacando sua
403 eficácia na classificação de imagens, mesmo em cenários com
404 desequilíbrio de dados.

405 No Cenário 2, com aumento de dados, a arquitetura proposta
406 superou o MobileNetV2 em todas as métricas, alcançando
407 98,94% de acurácia, 98,48% de precisão, 98,38% de *recall*,
408 98,41% de *F1-Score* e 99,99% de AUC. Notavelmente, a
409 RNC proposta também se destacou em comparação com o
410 modelo de referência do estudo anterior, apresentando melho-
411 rias significativas. O modelo de referência, que foi uma rede
412 convolucional profunda com uma arquitetura mais complexa,
413 obteve 96,46% de acurácia, 96,47% de precisão, 99,89% de
414 *recall*, 98,15% de *F1-Score* e 98,96% de AUC.

415 Um aspecto a ser destacado é que, apesar da maior com-
416 plexidade e do maior número de parâmetros do modelo de
417 referência, a RNC proposta alcançou um desempenho superior
418 com um número significativamente menor de parâmetros. A
419 LDPNet possui 1.817.063 parâmetros, enquanto o modelo
420 de referência conta com 2.672.735 parâmetros. Esta redução
421 substancial no número de parâmetros não apenas contribui
422 para uma menor carga computacional e maior eficiência,
423 mas também demonstra que uma arquitetura mais enxuta
424 pode alcançar desempenho superior ou equivalente em tarefas
425 complexas de classificação de imagens.

426 A análise dos resultados confirma que a rede sugerida é
427 eficaz, mostrando um equilíbrio notável entre desempenho e
428 complexidade. A introdução de técnicas de aumento de dados
429 melhorou ainda mais o desempenho do modelo, reforçando a
430 importância dessas técnicas para otimizar a generalização.

431 Embora os resultados sejam promissores, há oportunidades
432 para aprimorar ainda mais a abordagem, como implementar
433 e testar técnicas de regularização adicionais, como *dropout* e
434 técnicas de normalização de pesos. Avaliar outras arquiteturas
435 de redes neurais avançadas, como redes baseadas em atenção
436 ou redes de cápsulas. Além de avaliar o desempenho da RNC

proposta em diferentes domínios de aplicação, por exemplo, 437
testar a arquitetura em imagens médicas para a detecção de 438
anomalias pode revelar como o modelo lida com características 439
visuais complexas e variáveis, ampliando seu potencial de 440
aplicação para diagnósticos de saúde. Esses passos futuros 441
poderão validar ainda mais a versatilidade e a eficácia da 442
abordagem apresentada. 443

444 AGRADECIMENTOS

Os autores gostariam de agradecer o apoio financeiro da 445
Coordenação de Aperfeiçoamento de Pessoal de Nível Supe- 446
rior (CAPES — Código de Financiamento 001) e do Instituto 447
Federal de Educação, Ciência e Tecnologia do Ceará (IFCE). 448

449 REFERÊNCIAS

- 450 [1] A.-Y. Dong, Z. Wang, J.-J. Huang, B.-A. Song, and G.-F. Hao, "Bioin- 451
formatic tools support decision-making in plant disease management," 452
Trends in Plant Science, vol. 26, no. 9, pp. 953–967, 2021.
- 453 [2] O. D. N. Unidas, "Risco de fome generalizada aumenta pelo quinto ano 454
consecutivo," <https://news.un.org/pt/story/2024/04/1830741>, 2024.
- 455 [3] S. D. Khirade and A. B. Patil, "Plant disease detection using image pro- 456
cessing," in *2015 International conference on computing communication 457
control and automation*. IEEE, 2015, pp. 768–771.
- 458 [4] K. P. Ferentinos, "Deep learning models for plant disease detection and 459
diagnosis," *Computers and electronics in agriculture*, vol. 145, pp. 311– 460
318, 2018.
- 461 [5] A. A. Bharate and M. S. Shirdhonkar, "A review on plant disease 462
detection using image processing," in *2017 International Conference 463
on Intelligent Sustainable Systems (ICISS)*, 2017, pp. 103–109.
- 464 [6] I. Goodfellow, Y. Bengio, and A. Courville, *Deep learning*. MIT press, 465
2016.
- 466 [7] F. C. Funck, "Detectando a ferrugem asiática na folha da soja utilizando 467
redes neurais convolucionais," B.S. thesis, Universidade Tecnológica 468
Federal do Paraná, 2019.
- 469 [8] Y. Lu, S. Yi, N. Zeng, Y. Liu, and Y. Zhang, "Identification of rice 470
diseases using deep convolutional neural networks," *Neurocomputing*, 471
vol. 267, pp. 378–384, 2017.
- 472 [9] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification 473
with deep convolutional neural networks," *Communications of the ACM*, 474
vol. 60, no. 6, pp. 84–90, 2017.
- 475 [10] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, 476
V. Vanhoucke, and A. Rabinovich, "Going deeper with convolutions," 477
in *Proceedings of the IEEE conference on computer vision and pattern 478
recognition*, 2015, pp. 1–9.
- 479 [11] Z. Li, Y. Yang, Y. Li, R. Guo, J. Yang, and J. Yue, "A solanaceae disease 480
recognition model based on se-inception," *Computers and Electronics 481
in Agriculture*, vol. 178, p. 105792, 2020. [Online]. Available: 482
<https://www.sciencedirect.com/science/article/pii/S0168169920313454>
- 483 [12] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, 484
M. Andreetto, and H. Adam, "Mobilenets: Efficient convolutional neural 485
networks for mobile vision applications," *CoRR*, vol. abs/1704.04861, 486
2017. [Online]. Available: <http://arxiv.org/abs/1704.04861>
- 487 [13] G. Geetharamani and A. Pandian, "Identification of plant leaf diseases 488
using a nine-layer deep convolutional neural network," *Computers & 489
Electrical Engineering*, vol. 76, pp. 323–338, 2019.
- 490 [14] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, 491
"Mobilenetv2: Inverted residuals and linear bottlenecks," *Proceedings 492
of the IEEE conference on computer vision and pattern recognition*, pp. 493
4510–4520, 2018.
- 494 [15] F. Zhuang, Z. Qi, K. Duan, D. Xi, Y. Zhu, H. Zhu, H. Xiong, and 495
Q. He, "A comprehensive survey on transfer learning," *Proceedings of 496
the IEEE*, vol. 109, no. 1, pp. 43–76, 2020.
- 497 [16] C. Tan, F. Sun, T. Kong, W. Zhang, C. Yang, and C. Liu, "A survey 498
on deep transfer learning," in *Artificial Neural Networks and Machine 499
Learning – ICANN 2018*, V. Kůrková, Y. Manolopoulos, B. Hammer, 500
L. Iliadis, and I. Maglogiannis, Eds. Cham: Springer International 501
Publishing, 2018, pp. 270–279.