

CLASSIFICAÇÃO DE DOENÇAS EM FOLHAS DE MILHO UTILIZANDO REDES NEURAIS CONVOLUCIONAIS APRIMORADAS COM OTIMIZAÇÃO BAYESIANA DE HIPERPARÂMETROS

Erik Lucas da Rocha

Orientadora: Prof^a. Me. Larissa Ferreira Rodrigues

ROTEIRO

- Introdução
- Objetivos
- Referencial Teórico
- Trabalhos Relacionados
- Material e Métodos
- Resultados e Discussões
- Conclusão

INTRODUÇÃO

- Até 2050 - 9,7 bilhões de pessoas no mundo
- Escassez de terras e demanda por alimentos
- Aprendizado de Máquina e Processamento Digital de Imagens aplicados na agricultura
 - Controle de pragas e doenças
 - Acompanhamento do cultivo
 - Monitoramento do solo

INTRODUÇÃO

- Milho > trigo e arroz
- Mais doenças
 - Degradação das terras
 - Mudanças no sistema de cultivo
- Doenças foliares

INTRODUÇÃO

- Inteligência Artificial
 - Aprendizado de Máquina e Processamento Digital de Imagens
 - Controle de pragas
 - Acompanhamento do cultivo
 - Monitoramento do solo

INTRODUÇÃO

- Deep Learning (Alto desempenho na resolução de problemas)
 - Redes Neurais Convolucionais
 - VGG, ResNet, Inception...
 - Saúde (diagnóstico e acompanhamento de doenças)
 - Agricultura (seleção e reconhecimento de espécies, gestão do solo, gerenciamento de água...)

OBJETIVOS

Fornecer um método capaz de classificar doenças em imagens de folhas de milho usando CNNs aprimoradas pela otimização Bayesiana de hiperparâmetros, técnicas de aumento de dados e treinamento baseado em fine-tuning.

- Comparar o desempenho de três arquiteturas CNN em termos de acurácia, precisão, recall e F1-Score;
- Analisar as CNNs com treinamento baseado em fine-tuning;
- Aplicar estratégias de aumento de dados baseadas em rotações aleatórias, inversões verticais e horizontais, para superar o desequilíbrio entre as classes do conjunto de dados;
- Otimizar os hiperparâmetros de cada CNN utilizando algoritmo Bayesiano.

REFERENCIAL TEÓRICO

- Pragas e doenças
 - Cercosporiose do milho (Mancha cinza)
 - Ferrugem comum
 - Helminthosporiose (Queima de turcicum)



(a) Mancha Cinza nas Folhas

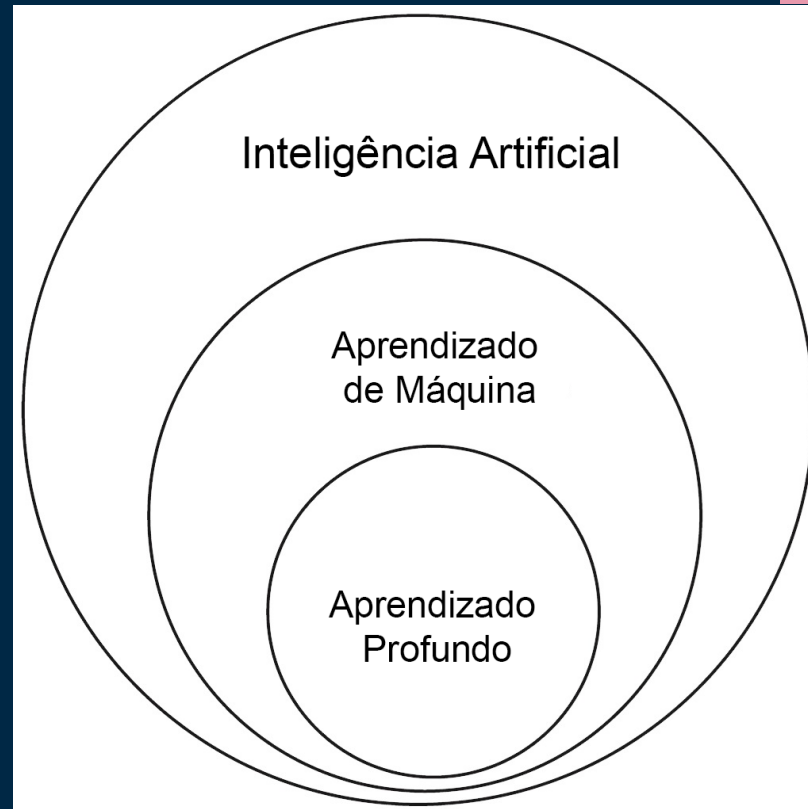


(b) Ferrugem Comum



(c) Queima de Turcicum

REFERENCIAL TEÓRICO



REFERENCIAL TEÓRICO

- Visão Computacional




01

Estração de características



02

Elaboração de um conjunto descritor



03

Classificador que define se um padrão pertence a uma determinada classe

REFERENCIAL TEÓRICO

- Reconhecimento de padrões e **Redes Neurais**
 - Construir fronteiras de decisões não lineares entre as diferentes classes
 - Oferecer um método prático para resolver problemas altamente complexos de classificação de padrões.



REFERENCIAL TEÓRICO

- Visão Computacional
 - Processamento e análise de imagens
 - Matriz bidimensional - imagens monocromáticas $f(x, y)$
 - Amplitude f - intensidade ou nível de cinza
 - Mais dimensões - imagens coloridas

REFERENCIAL TEÓRICO

- Visão Computacional
 - Reconhecimento de padrões
 - identificar elementos, a interação entre os elementos e a própria imagem
 - Imprescindível para sistemas de análise de imagens em alto nível
 - simular processamentos complexos de percepção visual

REFERENCIAL TEÓRICO

- Visão Computacional
 - Reconhecimento de padrões
 - Extração de características
 - Elaboração de um conjunto descritor
 - Classificador que define se um padrão pertence a uma determinada classe

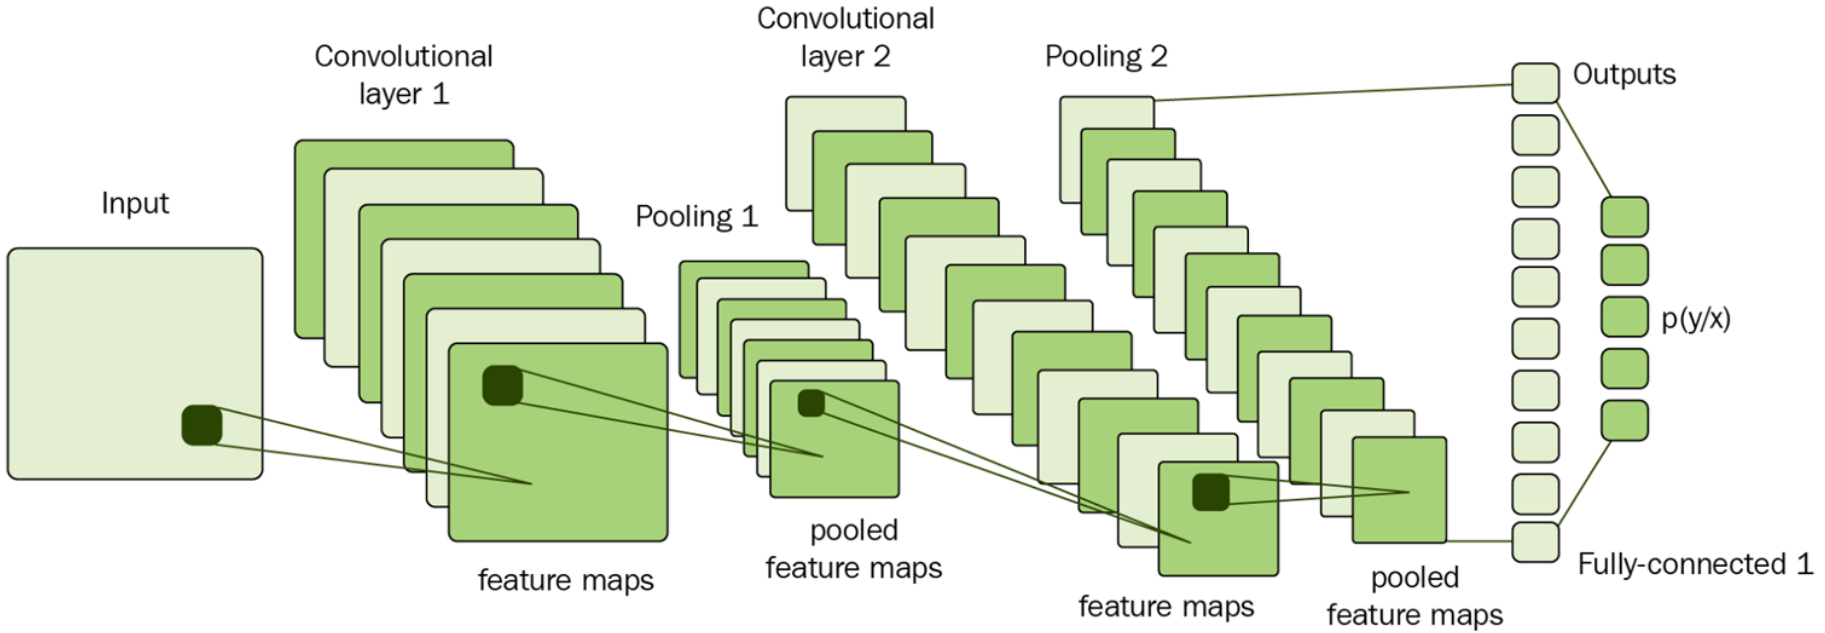
REFERENCIAL TEÓRICO

- Aprendizado Profundo
 - Construção de modelos de previsão para problemas complexos (visão computacional)
 - Modelagem de linguagem natural

REFERENCIAL TEÓRICO

- Aprendizado Profundo
 - Redes Neurais Convolucionais (córtex do cérebro)
 - Processamento e reconhecendo imagens
 - Digitaliza regiões e resume no espaço de menor dimensão
 - Alta dimensionalidade

REFERENCIAL TEÓRICO




REFERENCIAL TEÓRICO

- Arquiteturas CNNs
 - AlexNet (2012)
 - 5 camadas convolucionais
 - 3 camadas max-pooling
 - 2 camadas totalmente conectadas
 - Dropout (overfitting)
 - Função ReLU

REFERENCIAL TEÓRICO

- AlexNet



Fonte: XXXX

REFERENCIAL TEÓRICO

- Arquiteturas CNNs

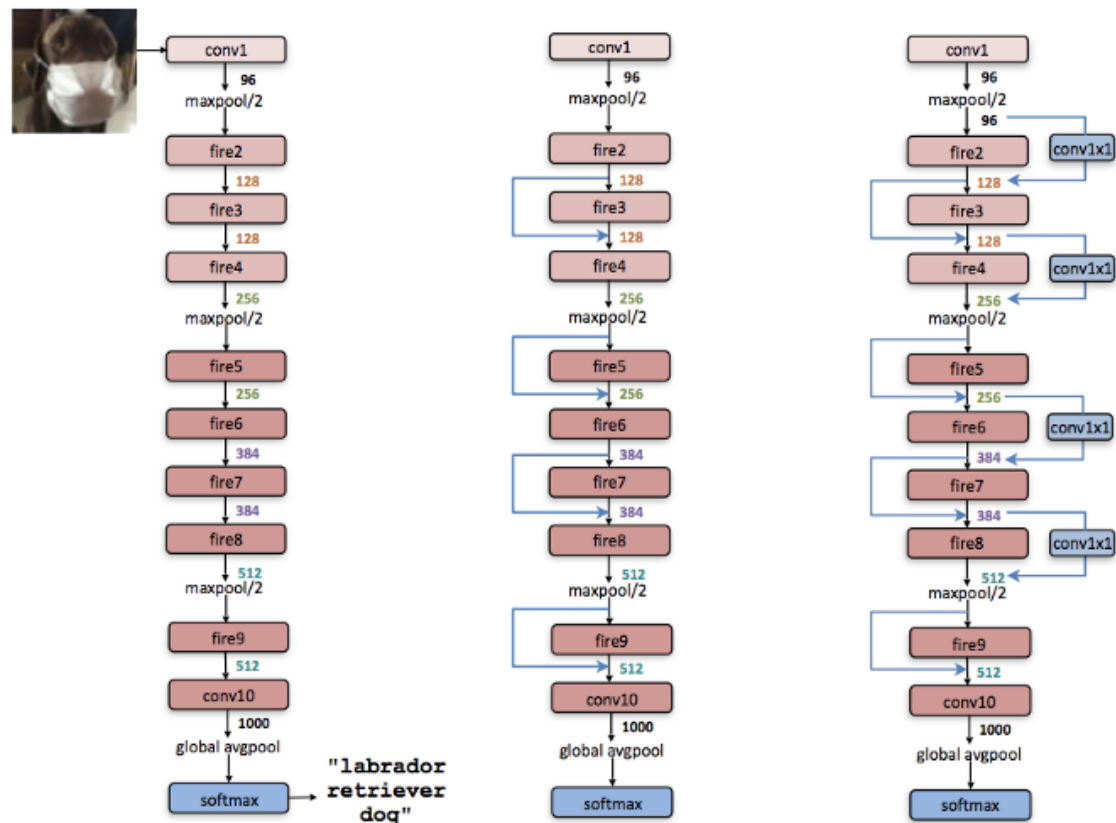
- SqueezeNet (2016)

- Mesmo nível de precisão da AlexNet
- 50x menos parâmetros
- 0,5mb (510x menor que a AlexNet)

- Módulos de compressão (filtros 3x3 em 1x1)

REFERENCIAL TEÓRICO

- SqueezeNet



REFERENCIAL TEÓRICO

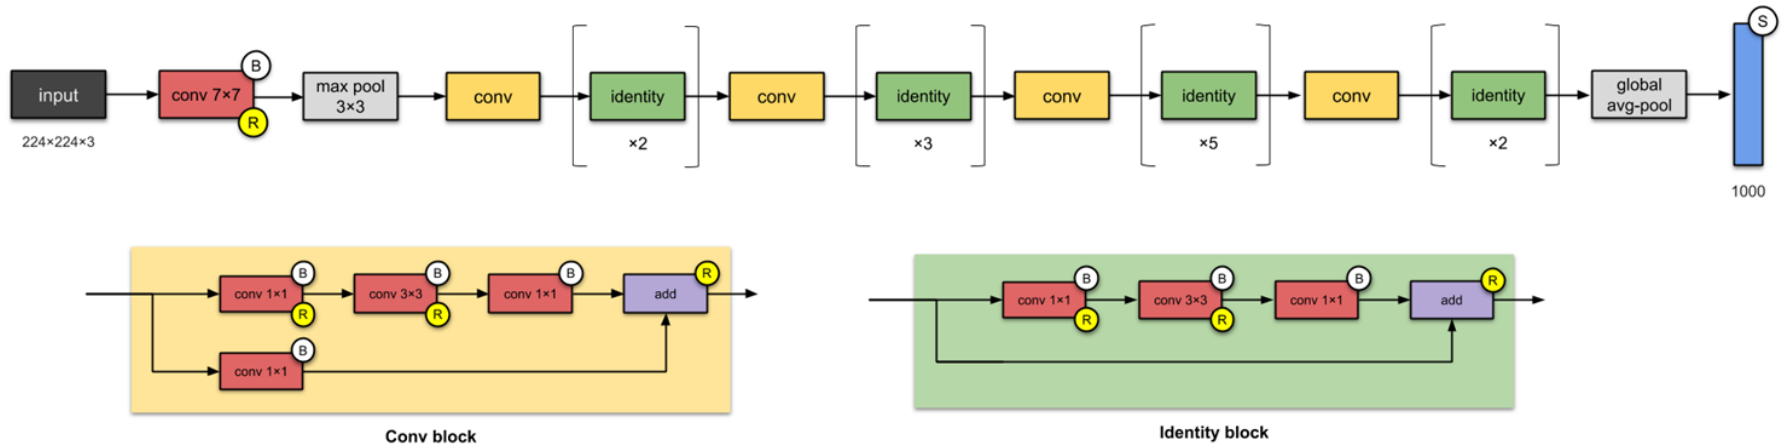
- Arquiteturas CNNs

- ResNet (2015)

- Arquitetura com 50 camadas (Resnet 50)
- Blocos residuais que corrigem a degradação do gradiente no treinamento
- 1 camada de convolução 7x7
- Várias camadas de convolução 3x3 e 1x1

REFERENCIAL TEÓRICO

- ResNet



REFERENCIAL TEÓRICO

- Aumento de dados
- Fine-tuning
- Otimização de hiperparâmetros
 - Batch size
 - Learning rate
 - Momentum

REFERENCIAL TEÓRICO

- Otimização Bayesiana
 - Função objetivo
 - Desempenho do modelo
 - Espaço de hiperparâmetros
 - Algoritmo otimizador
- Aumento no tempo de seleção
- Menor tempo na avaliação da função objetivo

Menor custo
computacional

REFERENCIAL TEÓRICO

- Protocolo de Avaliação
 - Validação cruzada k-fold
 - Divisão do dataset (k-1)
 - Matriz de Confusão

		Valor Previsto	
		Positivo	Negativo
Valor Verdadeiro	Negativo	Verdadeiros Positivos	Falsos Negativos
	Positivo	Falsos Positivos	Verdadeiros Negativos

REFERENCIAL TEÓRICO

- Protocolo de Avaliação

$$\text{Acurácia} = \frac{TP + TN}{TP + TN + FP + FN}$$

$$\text{Precisão} = \frac{TP}{TP + FP}$$

$$\text{Recall} = \frac{TP}{TP + FN}$$

$$\text{F1-Score} = 2 \times \frac{\text{Precisão} \times \text{Recall}}{\text{Precisão} + \text{Recall}}$$

TRABALHOS RELACIONADOS

- Mohanty, Hughes e Salathé (2016)
- Sladojevic et al. (2016)
- DeChant et al. (2017)
- Too et al. (2018)
- Rangarajan, Purushothaman e Ramesh (2018)
- Zhang et al. (2018)
- Lin et al. (2018)
- Carvalho e Zoby (2019)
- Barbedo (2019)
- Alehegn (2019)
- Bhatt et al. (2019)
- Priyadharshini et al. (2019)
- Sibiya e Sumbwanyambe (2019)
- Hu et al. (2020)
- Waheed et al. (2020)

TRABALHOS RELACIONADOS

- Classificação de doenças em diferentes culturas
 - PlantVillage
 - CNNs AlexNet, GoogleNet, CaffeNet, VGG 16, Inception V4, ResNet e DenseNet
 - Treinamento completo e fine-tuning
 - Análise das lesões e não da folha completa
 - Os resultados variaram entre 85,53% e 99,75%.

TRABALHOS RELACIONADOS

- Classificação de doenças de milho
 - Técnica de aumento de dados
 - Desenvolvimento de uma CNN multi-canal
 - Desenvolvimento de uma técnica baseada na cor, textura e características morfológicas
 - Abordagem baseada em CNNs e reforço adaptativo com classificador baseado em árvore de decisão
 - Os resultados variaram entre 92,85% e 98%

TRABALHOS RELACIONADOS

- Classificação de doenças de milho
 - Bhatt et al. (2019), Priyadharshini et al. (2019), Sibiya e Sumbwanyambe (2019) e Hu et al. (2020)
 - PlantVillage
 - Hold-out (conjuntos de dados tendenciosos)
 - validação cruzada k-fold para estimar melhor a acurácia (evitando o overfitting)

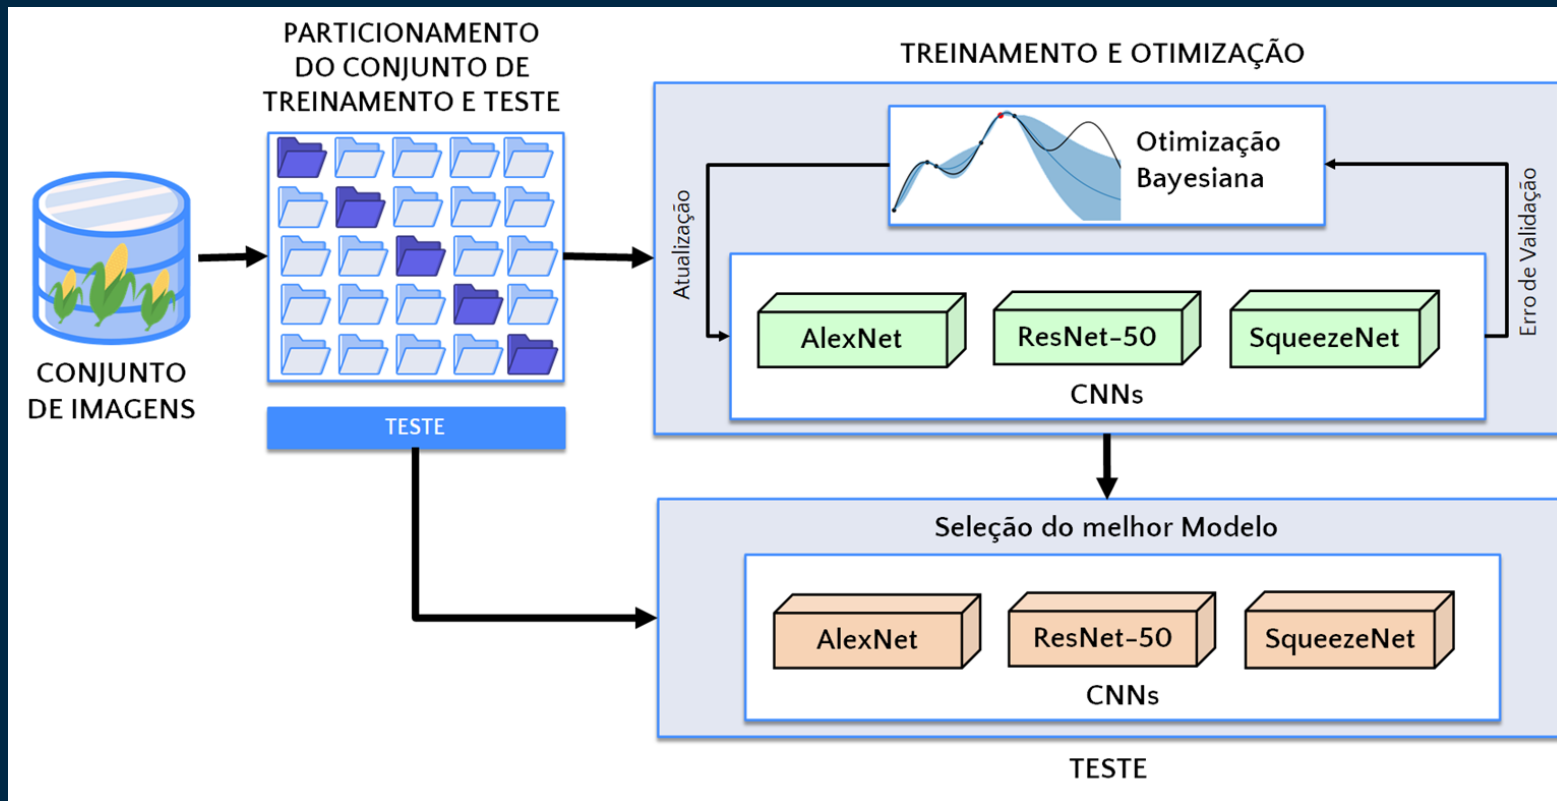
TRABALHOS RELACIONADOS

- Classificação de doenças de milho
 - Waheed et al. (2020)
 - DenseNet otimizada
 - Algoritmo grid search (maldição da alta dimensionalidade e falta de recursos)
 - Otimização Bayesiana de hyperparâmetros

TRABALHOS RELACIONADOS

- AlexNet, SqueezeNet e ResNet50
- Otimização Bayesiana de hiperparâmetros
- Treinamento com fine-tuning e validação cruzada

MATERIAL E MÉTODOS



MATERIAL E MÉTODOS


- Ferramentas Computacionais
 - Linguagem Python
 - Framework PyTorch
 - Módulos de Linguagem:
 - NumPy
 - Matplotlib
 - Scikit-learn e Scikit Image

MATERIAL E MÉTODOS

- Conjunto de Imagens
 - PlantVillage
 - Milho
 - 3852 imagens
 - 4 classes
 - Mancha cinza (513 imagens)
 - Ferrugem comum (1192 imagens)
 - Queima de turcicum (985 imagens)
 - Saudável (1162 imagens)



(a) Mancha Cinza nas Folhas



(b) Ferrugem Comum



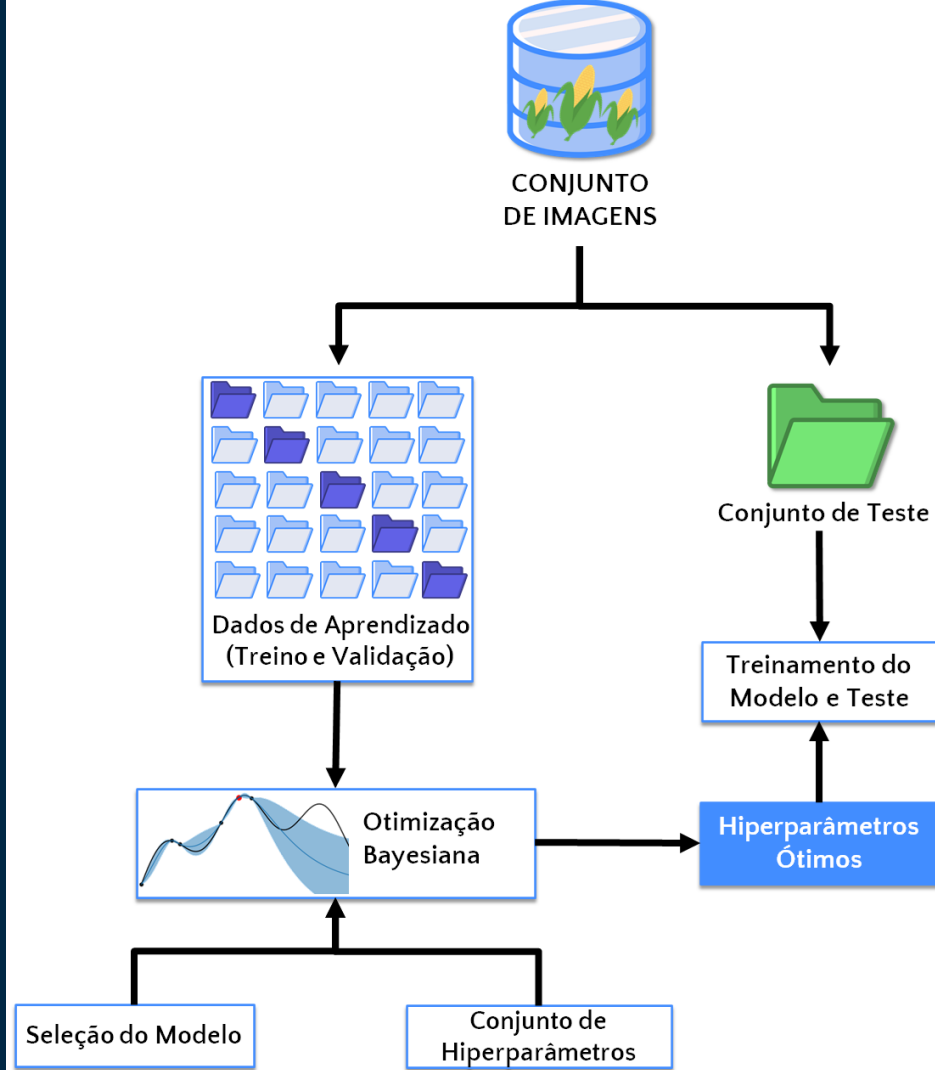
(c) Queima de Turcicum



(d) Saudável

MATERIAL E MÉTODOS

MATERIAL E MÉTODOS



MATERIAL E MÉTODOS

Hiperparâmetro	Valor
<i>Batch Size</i>	[16, 32]
Taxa de Aprendizado	[0.001, 0.01]
<i>Momentum</i>	[0, 1]

MATERIAL E MÉTODOS

Hiperparâmetros	AlexNet	ResNet-50	SqueezeNet
<i>Batch size</i>	32	32	18
Taxa de Aprendizagem	0.0036931912206946992	0.0042498507802230421	0.0026763419023990384
<i>Momentum</i>	0.13865257470287484	0.4755170748794698	0.34556072704304774

RESULTADOS E DISCUSSÕES

- Ambiente de testes

- Processador Intel Core i5 de 3,00 GHz
- Memória RAM 16 GB
- GPU NVIDIA GeForce GTX Titan Xp (12 GB RAM)
- S.O Ubuntu 16.04.2 LTS



RESULTADOS E DISCUSSÕES

AlexNet	Precisão	<i>Recall</i>	<i>F1-Score</i>
Mancha cinza nas folhas	91%	85%	88%
Ferrugem comum	100%	99%	100%
Queima de turcicum	92%	95%	93%
Saudável	99%	100%	100%
Média	96%	95%	95%
Acurácia		97%	

RESULTADOS E DISCUSSÕES

SqueezeNet	Precisão	<i>Recall</i>	<i>F1-Score</i>
Mancha cinza nas folhas	86%	93%	89%
Ferrugem comum	100%	99%	100%
Queima de turcicum	96%	91%	93%
Saudável	99%	100%	100%
Média	95%	96%	96%
Acurácia		97%	

RESULTADOS E DISCUSSÕES

ResNet50	Precisão	<i>Recall</i>	<i>F1-Score</i>
Mancha cinza nas folhas	86%	93%	89%
Ferrugem comum	100%	99%	100%
Queima de turcicum	96%	91%	93%
Saudável	99%	100%	100%
Média	95%	96%	96%
Acurácia		97%	

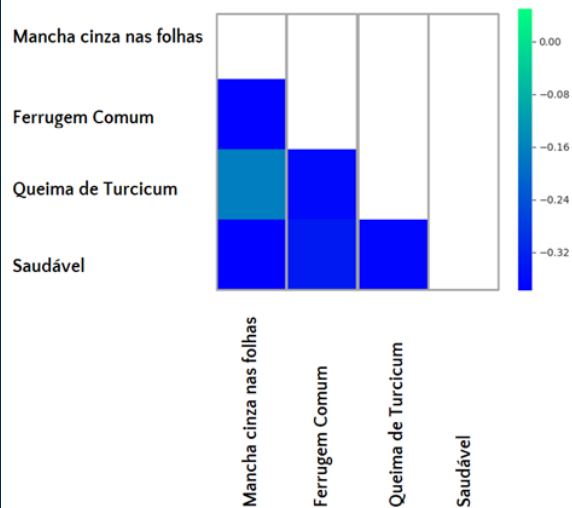
RESULTADOS E DISCUSSÕES

- Mancha Cinza
 - Resultados inferiores
 - 43% do tamanho da maior classe (“ferrugem comum”)
 - Aumento de dados

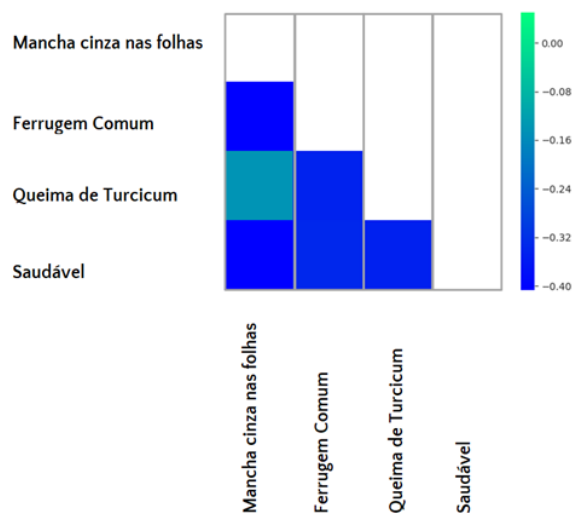


RESULTADOS E DISCUSSÕES

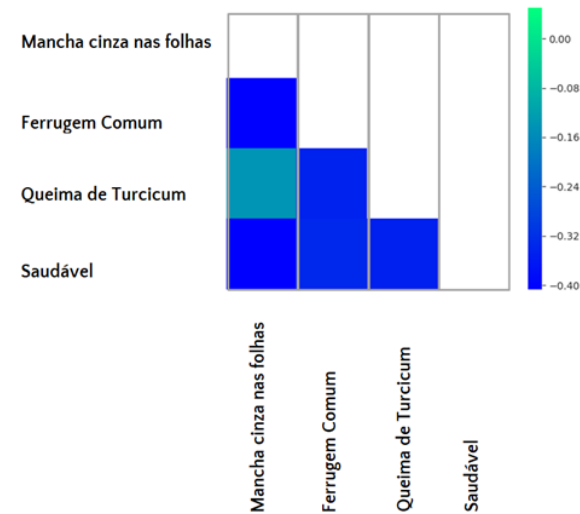
(a) AlexNet



(b) ResNet-50



(c) SqueezeNet



RESULTADOS E DISCUSSÕES

Método	Acurácia (%)
Sibiya e Sumbwanyambe (2019)	92,85
Hu et al. (2020)	97,60
Priyadharshini et al. (2019)	97,89
Bhatt et al. (2019)	98,00
Presente trabalho	97,00

CONCLUSÃO

- A otimização bayesiana é uma alternativa promissora
- Melhor resultado: 97% de acurácia
- Validação cruzada (overfitting)
- A proposta pode exigir menos de tempo de investimento em aplicações reais

CONCLUSÃO

- Trabalhos futuros

- Classificar mais tipos de doenças em folhas de milho
- Classificar outras culturas
- Avaliar outros algoritmos de otimização de hiperparâmetros
- Explorar mais estratégias de aumento de dados.

CONTRIBUIÇÃO EM PRODUÇÃO BIBLIOGRÁFICA ■

■
Rocha, E.L; Rodrigues, L.F.; Mari, J.F.

Maize leaf disease classification using convolutional neural networks and hyperparameter optimization.

■ In: Workshop de Visão Computacional (WVC 2020).

DOI: <https://doi.org/10.5753/wvc.2020.13489>.

REFERÊNCIAS

ALEHEGN, Enquhone. Ethiopian maize diseases recognition and classification using support vector machine. *International Journal of Computational Vision and Robotics*, v. 9, n. 1, p. 90-109, 2019.

BHATT, Prakruti et al. Identification of Diseases in Corn Leaves using Convolutional Neural Networks and Boosting. In: *ICPRAM*. 2019. p. 894-899.

DECHANT, Chad et al. Automated identification of northern leaf blight-infected maize plants from field imagery using deep learning. *Phytopathology*, v. 107, n. 11, p. 1426-1432, 2017.

HU, Rongjie et al. The identification of corn leaf diseases based on transfer learning and data augmentation. In: *Proceedings of the 2020 3rd International Conference on Computer Science and Software Engineering*. 2020. p. 58-65.

LIN, Zhongqi et al. A novel method of maize leaf disease image identification based on a multichannel convolutional neural network. *Transactions of the ASABE*, v. 61, n. 5, p. 1461-1474, 2018.

REFERÊNCIAS

PRIYADHARSHINI, Ramar Ahila et al. Maize leaf disease classification using deep convolutional neural networks. *Neural Computing and Applications*, v. 31, n. 12, p. 8887-8895, 2019.

SIBIYA, Malusi; SUMBWANYAMBE, Mbuyu. A computational procedure for the recognition and classification of maize leaf diseases out of healthy leaves using convolutional neural networks. *AgriEngineering*, v. 1, n. 1, p. 119-131, 2019.

WAHEED, Abdul et al. An optimized dense convolutional neural network model for disease recognition and classification in corn leaf. *Computers and Electronics in Agriculture*, v. 175, p. 105456, 2020.

ZHANG, Xihai et al. Identification of maize leaf diseases using improved deep convolutional neural networks. *IEEE Access*, v. 6, p. 30370-30377, 2018.

The background features a dark blue field with scattered geometric elements. These include thin white vertical lines of varying lengths, and small squares in teal, orange, and pink. Some squares are solid, while others are hollow. The word 'OBRIGADO!' is centered in a large, bold, orange, sans-serif font.

OBRIGADO!