



Classificação de Grãos de Soja utilizando Aprendizagem Profunda

Classification of Soybean Seeds Using Deep Learning

Pedro Henrique da Rocha¹, Claiton de Oliveira²,
Silvio Ricardo Rodrigues Sanches³

RESUMO

A soja é considerada uma das mais importantes culturas em todo o mundo. Ainda assim, a demanda pelo produto tende a aumentar devido ao crescimento da população. Consequentemente, a necessidade de ampliar a sua produtividade torna-se um desafio para os pesquisadores da área. A classificação da qualidade da semente, de forma rápida e confiável, pode otimizar os custos da colheita pois esse fator afeta o preço, prejudica o cultivo e influencia o consumo de soja. O resultado são perdas econômicas para os agricultores. Neste trabalho, a rede neural MobileNet foi treinada para classificar automaticamente, por meio da imagem, as sementes de soja de acordo com sua qualidade. Os resultados mostraram que, mesmo com o treinamento utilizando baixo número de épocas, a precisão de 94,06% foi alcançada no conjunto de testes utilizado. A pouca quantidade de camadas e parâmetros da rede neural convolucional MobileNet permitiu a obtenção de um modelo mais leve com bom desempenho para uso em dispositivos móveis.

PALAVRAS-CHAVE: Aprendizagem Profunda; Grão de Soja; Qualidade de Soja.

ABSTRACT

Soybean is considered one of the most important crops in the world. Still, demand for the product tends to increase due to population growth. Consequently, the need to increase productivity becomes a challenge for researchers in the field. Classifying seed quality quickly and reliably can optimize harvest costs as this factor affects the price, harms cultivation, and influences soybean consumption. The result is economic losses for farmers. In this work, we trained the MobileNet neural network to automatically classify, through images, soybean seeds according to their quality. The results showed that, even with training using a low number of epochs, our approach achieved an accuracy of 94.06% in the used dataset. The small number of layers and parameters of the MobileNet convolutional neural network allowed us to obtain a light model with good performance for use on mobile devices.

KEYWORDS: Deep Learning; Soybean Seeds; Soybean Quality.

INTRODUÇÃO

A soja é uma das cinco principais culturas globais e a principal em muitos países. A presença de patógenos e pragas na agricultura é uma grande preocupação, pois impactam negativamente o rendimento e a qualidade da produção agrícola, gerando perdas econômicas e afetando a segurança

¹ Bolsista do Programa Institucional de Bolsas de Iniciação Científica e Desenvolvimento Tecnológico. Universidade Tecnológica Federal do Paraná, Cornélio Procópio, PR, Brasil. E-mail: rocha.2021@alunos.utfpr.edu.br. ID Lattes: <http://lattes.cnpq.br/0802832921569195>.

² Docente no Departamento de Computação. Universidade Tecnológica Federal do Paraná, Cornélio Procópio, PR, Brasil. E-mail: claitonoliveira@utfpr.edu.br. ID Lattes: <http://lattes.cnpq.br/8851289265109891>.

³ Docente no Departamento de Computação. Universidade Tecnológica Federal do Paraná, Cornélio Procópio, PR, Brasil. E-mail: silviosanches@utfpr.edu.br. ID Lattes: <http://lattes.cnpq.br/9931293076574399>.



alimentar em todos os níveis (SAVARY et al., 2019; WANG et al., 2022). Além disso, o aumento populacional impulsiona a crescente demanda por soja, tornando essencial aumentar a produtividade dessa cultura (ZHANG; WU; CHEN, 2021).

Nesse cenário, aprimorar a qualidade das sementes pode ter um impacto significativo no aumento do rendimento agrícola. Essa qualidade é influenciada pela saúde, fisiologia, germinação e características físicas das sementes. Fatores como a presença de doenças, composição química, infestação de insetos e a existência de sementes de plantas daninhas ou outras variedades de plantas também afetam a qualidade. Além disso, a qualidade das sementes e seus derivados está ligada, de forma direta ou indireta, à saúde humana. Contudo, a avaliação dos parâmetros de qualidade das sementes é um processo que demanda tempo (RAHMAN; CHO, 2016), e a falta de uma avaliação precisa da qualidade da semente pode resultar em perdas econômicas para os agricultores (CARMONA et al., 2015).

Neste trabalho, conduzimos um estudo utilizando uma rede neural convolucional conhecida como MobileNet, nosso objetivo foi treinar essa rede para realizar uma classificação automática da qualidade das sementes de soja, utilizando informações visuais extraídas das imagens das sementes. Essa metodologia inovadora tem o potencial de facilitar a análise e seleção das sementes, contribuindo para melhorias no processo de produção agrícola.

CLASSIFICAÇÃO DE SEMENTES

Para a classificação da qualidade de sementes, existem técnicas de visão computacional capazes de utilizar características extraídas da imagem, como tamanho, forma, cor e textura (RAHMAN; CHO, 2016). Neste trabalho, foram consideradas cinco classes de qualidade, de acordo com o Padrão de Classificação de Soja (GB1352-2009) (SAC, 2009). A Tabela 1 apresenta as classes de sementes consideradas neste trabalho e uma breve descrição de cada uma delas.

Tabela 1 – Classes de qualidade, de acordo com o Padrão de Classificação GB1352-2009 (SAC, 2009; LIN et al., 2023a).

Classe	Descrição
Intacta	Inteiras com coloração normal.
Imatura	Encolhida ou com partes verdes.
Casca danificada	Apresenta casca danificada.
Manchada	Apresentam manchas de doença na superfície.
Quebrada	Apresenta picada de inseto, rachaduras ou quebras de forma que a avaria afeta um quarto ou mais do volume da semente.

Para treinamento, validação e teste do modelo de classificação foi utilizado um conjunto de dados denominado Sementes de Soja (LIN et al., 2023b). Este conjunto de dados é composto por 5513 imagens, com resolução de 227×227 pixels cada, divididas em 5 pastas, onde cada pasta representa uma classe de semente de soja. As cinco classes são: Quebrada (1.002 imagens), Imaturo (1.125 imagens), Intacta (1.201), Casca Danificada (1.127) e Manchada (1.058 imagens).



Abordagem

Para classificar as sementes de soja, foi utilizada a rede neural convolucional MobileNet (HOWARD et al., 2017) por ser menos complexa e mais leve que outros modelos de aprendizagem profunda. A rede foi projetada para dispositivos móveis. Com o uso das bibliotecas Keras (KERAS, 2022) e Tensorflow (TENSORFLOW, 2022), foi instanciada um modelo do MobileNet pré-treinado.

Como este modelo base foi pré-treinado, os pesos oriundos da ImageNet foram utilizados. Além disso, foi definido que todo o modelo base deveria ser adaptável em vez de congelar os pesos pré-treinados. Em seguida, foi adicionada a camada de entrada no topo do modelo base para receber imagens de 224x224 pixels com 3 canais de cores (a resolução padrão do modelo base pré-treinado).

Para normalizar a saída do modelo base, foi adicionada uma camada de normalização em lote seguida por uma camada 2D de pool para reduzir a resolução da saída normalizada da camada anterior. Também foi adicionada uma camada de *dropout* para evitar *overfitting*. Finalmente, uma camada densa com 5 unidades (o número de classes do conjunto de dados) e a função softmax de ativação como saída do modelo de classificação foram utilizados. Um resumo do modelo pode ser visto na Tabela 2.

Tabela 2 – Resumo do Modelo

Camada	Output Shape	#Layers	# Parametros
InputLayer	[(None, 224, 224, 3)]	1	0
Mobilenet_1.00_224	(None, 7, 7, 1024)	86	3228864
BatchNormalization	(None, 7, 7, 1024)	1	4096
GlobalAveragePooling2D	(None, 1024)	1	0
Dropout	(None, 1024)	1	0
Dense	(None, 5)	1	5125
Total:		91	3,238,085

Os valores de pixel de todas as imagens (treinamento, validação e conjunto de teste) foram normalizados do intervalo entre 0 e 255 para o intervalo entre 0 e 1. Além disso, para reduzir o *overfitting* durante a fase de treinamento.

Treinamento

Antes de iniciar a fase de treinamento, o conjunto de dados foi dividido usando a abordagem 80/10/10 (80% das imagens para treinamento, 10% para validação e 10% para teste). As imagens do conjunto de treinamento e do conjunto de validação foram carregadas de um diretório em lotes de tamanho 32 e seus rótulos foram definidos de 0 a 4 (0 correspondente à primeira pasta/classe do diretório e 4 à última). O modelo final foi definido com o otimizador Adam (KINGMA; BA, 2017) e função categórica de perda de entropia cruzada (ambos com parâmetros padrão). Para avaliar o desempenho do modelo a métrica de precisão foi utilizada.

O treinamento utilizou 30 épocas com uma função de parada antecipada para interromper o treinamento se não houver alteração na perda de validação durante 4 épocas. Além disso, a taxa de aprendizagem inicial foi definida como 0,001 e reduzida em dez vezes a cada época quando não havia alteração na perda de validação em comparação com a época anterior. A Figura 1 mostra a



perda de treinamento e validação ao longo de 14 épocas (parada antecipada), onde a melhor época é 10.




Figura 1 – Perda e precisão do treinamento e da validação ao longo das épocas.

RESULTADOS E DISCUSSÕES

Após a função de parada antecipada interromper a fase de treinamento, o modelo foi carregado com os melhores pesos (da melhor época) para prosseguir com a predição. Cada imagem do conjunto de teste (10% de todo o conjunto de dados) foi inserida no modelo para previsão. As classes previstas das imagens de teste foram comparadas com as classes verdadeiras dessas imagens e os resultados mostram uma precisão de 94,06%. A matriz de confusão, bem como a precisão do teste podem ser vistas na Figura 2.

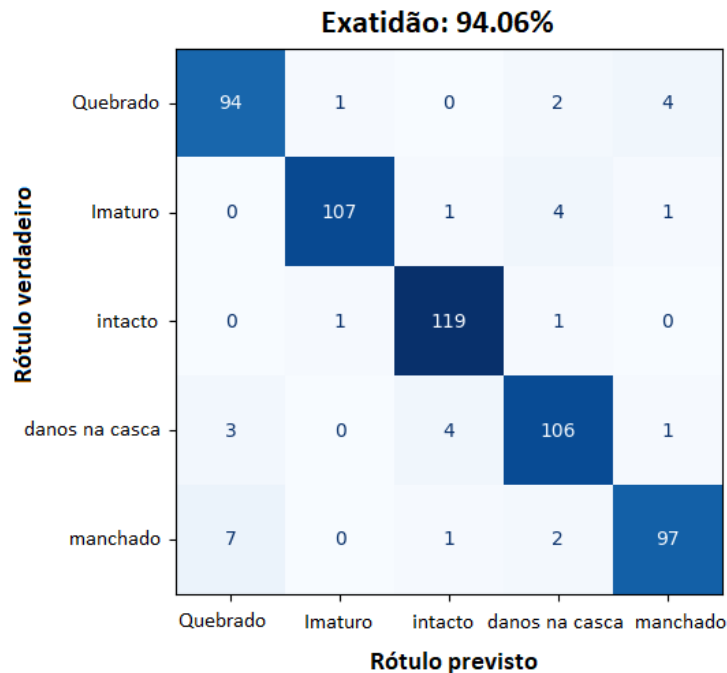


Figura 2 – Matriz de confusão e precisão do teste após a fase de teste.

A primeira abordagem avaliada congela os pesos do modelo base e treina apenas as camadas adicionadas ao modelo base, mas foi observado que a convergência não conseguiu superar a faixa



de precisão de 85% nos conjuntos de validação e teste. Após treinar todo o modelo final, a perda de validação foi menor e a precisão da validação foi maior que os resultados da primeira abordagem.

Também foi avaliada a abordagem de adicionar diferentes números de camadas densas com diferentes números de unidades por camada ao modelo base, mas essa estratégia aumentou a complexidade do modelo sem melhorar os resultados de um modelo com apenas uma camada densa na saída com 5 unidades.

A Figura mostra que os valores de precisão de treinamento e validação estão próximos na melhor época, o que sugere que o *overfitting* foi baixo. Isso também pode ser observado com a precisão do teste mostrada na Figura 2, onde o modelo apresentou uma alta taxa de desempenho na previsão de imagens que nunca foram utilizadas na fase de treinamento. O baixo número de épocas de treinamento necessárias para atingir uma precisão de 94,06% no conjunto de testes sugere uma rápida convergência do modelo para o conjunto de dados utilizado. A quantidade de camadas e parâmetros da rede neural convolucional MobileNet permitiu a obtenção de um modelo mais leve para uso em dispositivos móveis, comparado a outros modelos de aprendizagem profunda, aliado a um bom desempenho.

CONCLUSÕES

Neste estudo foi possível observar que a utilização da rede neural convolucional MobileNet para classificação de sementes de soja com base em suas imagens é uma abordagem promissora. O processo de divisão do conjunto de dados em 80% para treinamento, 10% para validação e 10% para teste se mostrou eficaz para o treinamento e avaliação do modelo. A utilização do otimizador Adam e a função de perda de entropia cruzada auxiliaram para um treinamento eficiente e a métrica de precisão foi adequada para avaliação do desempenho do modelo. Durante a experimentação, diversas abordagens foram consideradas, incluindo o treinamento de camadas adicionadas ao modelo base e a adição de camadas densas, porém, a configuração final, onde todo o modelo foi treinado, apresentou os melhores resultados. Observou-se que o modelo alcançou uma alta precisão de 94,06% no conjunto de testes, indicando que a rede foi capaz de generalizar bem para dados não vistos previamente. Além disso, a análise de convergência demonstrou que o modelo teve uma rápida adaptação aos dados de treinamento, indicando eficiência no processo de aprendizado. A leveza do modelo obtido, adequado para dispositivos móveis, e seu desempenho satisfatório destacam a viabilidade dessa solução para aplicativos práticos, facilitando a classificação automática de sementes de soja com base em imagens.

REFERÊNCIAS

CARMONA, Marcelo et al. Development and validation of a fungicide scoring system for management of late season soybean diseases in Argentina. **Crop Protection**, v. 70, p. 83–91, 2015. ISSN 0261-2194. DOI: [10.1016/j.cropro.2015.01.019](https://doi.org/10.1016/j.cropro.2015.01.019).



- HOWARD, Andrew G. et al. **MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications**. [S.l.: s.n.], 2017. arXiv: 1704.04861 [cs.CV].
- KERAS. **Keras**. 2022. Disponível em: [↗](#).
- KINGMA, Diederik P.; BA, Jimmy. **Adam: A Method for Stochastic Optimization**. [S.l.: s.n.], 2017. arXiv: 1412.6980 [cs.LG].
- LIN, Wei et al. Soybean image dataset for classification. **Data in Brief**, v. 48, p. 109300, 2023. ISSN 2352-3409. DOI: [10.1016/j.dib.2023.109300](https://doi.org/10.1016/j.dib.2023.109300).
- LIN, Wei et al. **Soybean Seeds**. [S.l.]: Mendeley, 2023. DOI: [10.17632/V6VZVFSZJ6.6](https://doi.org/10.17632/V6VZVFSZJ6.6).
- RAHMAN, Anisur; CHO, Byoung-Kwan. Assessment of seed quality using non-destructive measurement techniques: a review. **Seed Science Research**, Cambridge University Press, v. 26, n. 4, p. 285–305, 2016. DOI: [10.1017/S0960258516000234](https://doi.org/10.1017/S0960258516000234).
- SAC. **Standardization Administration of the People's Republic of China, Inspection and Quarantine of the People's Republic of China - GB 1352-2009 (GB1352-2009)**. [S.l.: s.n.], 2009. Acessado em 3 de julho de 2023. Disponível em: [↗](#).
- SAVARY, Serge et al. The global burden of pathogens and pests on major food crops. **Nature Ecology & Evolution**, v. 3, n. 3, p. 430–439, 2019. ISSN 2397-334X. DOI: [10.1038/s41559-018-0793-y](https://doi.org/10.1038/s41559-018-0793-y).
- TENSORFLOW. **TensorFlow**. 2022. Disponível em: [↗](#).
- WANG, Bin et al. Fusing deep learning features of triplet leaf image patterns to boost soybean cultivar identification. **Computers and Electronics in Agriculture**, v. 197, p. 106914, 2022. ISSN 0168-1699. DOI: [10.1016/j.compag.2022.106914](https://doi.org/10.1016/j.compag.2022.106914).
- ZHANG, Keke; WU, Qiufeng; CHEN, Yiping. Detecting soybean leaf disease from synthetic image using multi-feature fusion faster R-CNN. **Computers and Electronics in Agriculture**, v. 183, p. 106064, 2021. ISSN 0168-1699. DOI: [10.1016/j.compag.2021.106064](https://doi.org/10.1016/j.compag.2021.106064).