

ANÁLISE DE IMAGENS COLETADAS POR DRONES PARA IDENTIFICAÇÃO DA SOJA

JOSÉ GABRIEL MADUREIRA ADAMI¹; GABRIEL GUIZARDI CARDOSO¹; JOÃO RICARDO FAVAN²; FLÁVIA LUIZE PEREIRA DE SOUZA³;

¹ Discente em Big Data no Agronegócio na FATEC Pompéia “Shunji Nishimura”, Pompeia-SP.

² Docente do curso de Big Data no Agronegócio, FATEC Pompéia “Shunji Nishimura”, Pompeia-SP.

³ Discente em Engenharia Agrícola de Precisão na Faculdade de Ciências Agrônômicas (FCA) da Universidade Estadual Paulista “Júlio de Mesquita Filho” (UNESP), Botucatu-SP.

RESUMO

Os espaçamentos falhos na linha de plantio da cultura, é um problema recorrente nas plantações da soja em todo o Brasil, afetando diretamente a sua qualidade e produtividade, essas falhas podem provocar a redução do surgimento de plantas e devido a isso ocorre o crescimento de plantas daninhas causando uma redução na produtividade. No presente momento, com os avanços da tecnologia, é possível fazer um escaneamento completo das lavouras utilizando Aeronaves Remotamente Pilotadas (RPA, na sigla em inglês), tirando imagens aéreas com altitude de sua preferência no campo de forma prática e precisa. Com a utilização dessas imagens, é possível fazer a identificação e reconhecimento de plantas com aprendizado de máquina. Este trabalho teve como objetivo analisar imagens coletadas por RPA para identificação da soja, utilizando o algoritmo de redes neurais artificiais perceptron de multicamadas (MLP, na sigla em inglês). Os resultados obtidos no processo deste trabalho, foram positivos, validando a viabilidade do uso de tecnologias de aprendizado de máquina no campo para a identificação da soja.

Palavras-chave: perceptron de multicamadas; identificação de soja; RPA.

1 - INTRODUÇÃO

O Brasil é o maior produtor de soja (*Glycine max*) do mundo, de acordo com a EMBRAPA (2021) o país teve uma produção de cerca de 135 milhões de toneladas relacionados à safra de 2020/2021. A *commodity* tem uma grande importância para a economia do país, gerando uma grande quantidade de renda e emprego, tendo em vista toda a potência de produção do Brasil para o mundo, sendo responsável por aproximadamente 37% do comércio mundial.

Seguindo a liderança mundial de produção da soja no Brasil, um dos principais fatores que podem acabar afetando diretamente a qualidade e produtividade da soja, são os espaçamentos falhos na linha da cultura essas falhas podem provocar a redução do surgimento de plantas e devido a isso ocorre o crescimento de plantas daninhas causando uma redução na produtividade (SOUZA, 2021).

Com os avanços tecnológicos, no presente momento é possível fazer um escaneamento das lavouras com a utilização de Aeronaves Remotamente Pilotadas (RPA, na sigla em inglês) de forma prática e precisa, tirando imagens aéreas com altitude de sua preferência no campo. Utilizando essas imagens com aprendizado de máquina é possível fazer a identificação e reconhecimento de plantas.

O aprendizado de máquinas é uma área pertencente à inteligência artificial, e tem como objetivo otimizar um critério de desempenho usando dados de exemplo ou experiências anteriores. Essa otimização se define quando ocorre o treinamento do modelo, que normalmente é dividido entre supervisionado quando realiza aprendizado por meio dos dados já classificados, e não supervisionado quando realiza o aprendizado diferenciando os dados de forma autônoma. O modelo pode ser preditivo para fazer previsões ou descritivo para obter conhecimento dos dados, ou ambos (ALPAYDIN, 2010).

O algoritmo perceptron de multicamadas é a implementação mais utilizada das redes neurais artificiais, ela simula artificialmente o cérebro humano com neurônios artificiais, a capacidade de aprendizagem de um neurônio artificial é alcançada ajustando os pesos de acordo com o algoritmo de aprendizagem escolhido. A estrutura básica de uma rede neural artificial consiste em três camadas de neurônios, a *input* (entrada), *hidden* (escondida), e a *output* (saída), na qual são conectadas umas com as outras (ABRAHAM, 2005).

Este trabalho teve como objetivo analisar imagens coletadas por RPA para identificação da soja, utilizando o algoritmo de redes neurais artificiais perceptron de multicamadas e obter uma acurácia superior a 80%.

2 - MATERIAIS E MÉTODOS

2.1 - Obtenção das imagens

As imagens do plantio da soja foram obtidas da dissertação sobre Inteligência Artificial utilizada na determinação longitudinal da cultura da soja, capturadas por meio de um RPA, os registros estão no formato *Tagged Image File Format* (TIF) (SOUZA, 2021).

Esses registros foram retirados de um espaço rural fornecido pela UNESP de Botucatu na qual o período das informações coletadas foi entre Outubro, Novembro e Dezembro, do ano de 2019.

2.2 - Tratamento das imagens

Foi feita uma análise sobre a base de dados para identificar qual a imagem mais adequada, com referência no tamanho, espaçamento, e qualidade das plantas, optamos pelo período do mês de dezembro.

Com a imagem da lavoura inteira, ocorreu dois recortes utilizando o *GNU Image Manipulation Program* (GIMP), onde foram selecionados os locais que tinham plantas de soja com maior nitidez.

Para utilizar as imagens como entrada no modelo de aprendizado de máquinas, as fragmentamos em milhares de fotos de 35 pixels por 35 pixels. Nesta etapa foi usado como base o algoritmo de recorte (ANSELMO; TORRES, 2021), e aprimorado para as necessidades do tratamento. O algoritmo em questão foi feito utilizando o Python 3.9.5 (VAN ROSSUM; DRAKE, 2009), juntamente com as bibliotecas Numpy 1.20.2 (HARRIS, 2020), e OpenCV 4.5.3 (BRADSKI, 2000).

2.3 - Criação do dataset

Classificamos manualmente aproximadamente os setenta mil fragmentos, entre “planta” e “não planta” como na Figura 1, sendo os parâmetros de classificação para planta, apenas uma “planta” inteira por imagem, e a “não planta”, as demais imagens, resultando um valor simétrico de duzentos e trinta e quatro imagens.

Figura 1: Representação das classes “não planta” e “planta” em imagens.



Fonte: Adaptado de SOUZA (2021)

Diante disso, para ocorrer a etapa de aprendizagem do modelo, foi necessário a separação dos dados entre treino e teste, sendo destinado para treino 70% e para teste 30% dos fragmentos de imagens obtidas.

2.4 - Aplicação dos algoritmos

Para ajuste do modelo baseado no algoritmo perceptron de multicamadas, foi utilizado a linguagem de programação o Python 3.7.12 (VAN ROSSUM; DRAKE, 2009), juntamente com as bibliotecas Sklearn 1.0 (PEDREGOSA, 2011), Numpy 1.19.5 (HARRIS, 2020), Pandas 1.1.5 (MCKINNEY, 2010), OpenCV 4.1.2.30 (BRADSKI, 2000), e Matplotlib 3.2.2 (HUNTER, 2007). Utilizando o modelo MLPClassifier do sklearn, para criação da inteligência artificial, aplicando o algoritmo de redes neurais artificiais.

O classificador foi configurado para utilizar como algoritmo de otimização o gradiente descendente, sendo necessário uma taxa de aprendizado constante de 0.001, assim também, foi ajustado a quantidade de camadas de neurônios artificiais para quinze e por fim, configurado também a quantidade máxima de iterações para duzentas vezes.

Utilizando o mesmo ambiente de desenvolvimento, ocorreu a implementação do *Dummy Validation* sendo um algoritmo de base negativa.

2.5 - Avaliação e validação dos algoritmos

Para realizar a avaliação, calculamos três métricas principais sendo elas, a acurácia, erro quadrático, e a raiz do erro quadrático.

Além disso, na validação do algoritmo de aprendizado supervisionado, foi usado o método *Cross Validation* (KOHAVI, 1995), sendo a quantidade de amostras dividida em cinco subconjuntos de dados (*folds*). Completando o processo, um subconjunto é selecionado para teste e o restante para treino, então o algoritmo é treinado e ocorre a repetição do processo cinco vezes até que todos os subconjuntos sejam selecionados para teste (CHICCO, 2017).

3 - RESULTADOS E DISCUSSÃO

Como resultado deste trabalho, foi desenvolvido o ajuste do modelo baseado no algoritmo perceptron de multicamadas, para identificação da soja por meio de imagens.

Na matriz de confusão é possível identificar o desempenho do algoritmo de classificação de aprendizado de máquina, com isso podemos analisar os resultados positivos e negativos com uma certa precisão. De início é possível identificar uma tabela 2x2, onde os dados do modelo são classificados como binários, podendo apenas ter dois tipos de valores, 0 para falso e 1 para verdadeiro.

Conforme **Figura 2** nos lugares de verdadeiro positivo (VP), verdadeiro negativo (VN), falso positivo (FP) e falso negativo (FN), foram realizadas as substituições pelos dados de valores predito e real.

Figura 2: Representação da matriz de confusão do MLP.

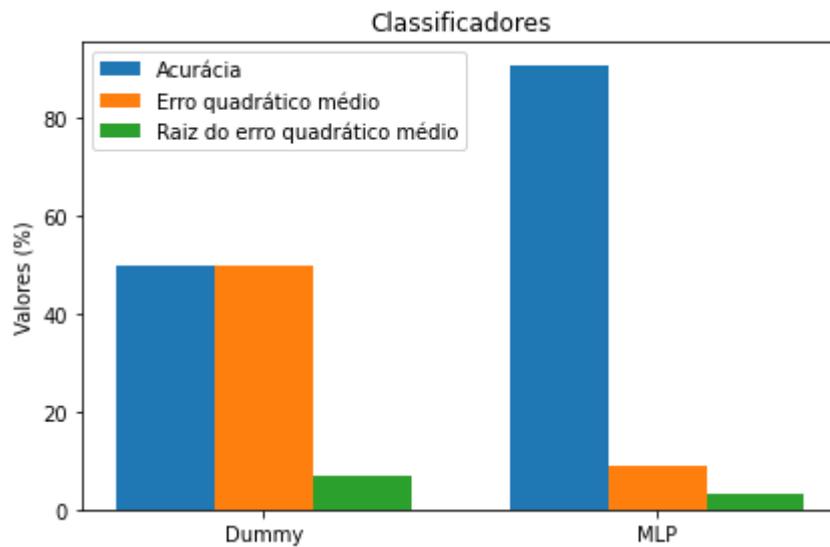


Fonte: Autores (2021)

Segundo (OLIVEIRA, 2019) a matriz de confusão consiste em representar os acertos e erros do modelo, sendo o valor real aquele que é confirmado por análise e o valor previsto aquele predito pelo teste.

De acordo com a **Figura 3**, é possível identificar a diferença entre os classificadores utilizados, sendo eles o *Dummy Classifier* que é a referência para base negativa e o Perceptron de multicamadas. A diferença é notória na comparação de todos os resultados, sendo valores próximos de acurácia para MLP de 91% e para *Dummy* de 50%, erro quadrático médio MLP de 9% e *Dummy* 50% e raiz do erro quadrático médio para MLP de 3% e *Dummy* de 7%.

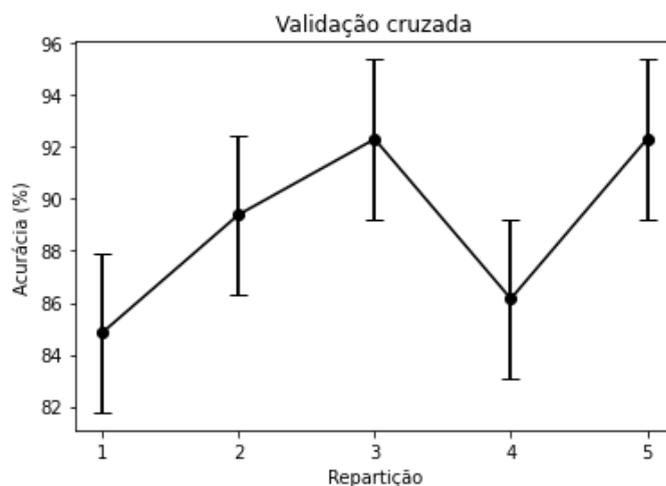
Figura 3: Representação da comparação de acurácia, erro quadrático médio e raiz do erro quadrático médio dos classificadores *Dummy* e MLP.



Fonte: Autores (2021)

A implementação do *Cross Validation* utilizou a definição de 5 repartições (*folds*), e para cada repartição se obteve aproximadamente as acurácias de 85%, 89%, 92%, 86% e 92%, com uma média respectiva das acurácias de 89%.

Figura 4: Representação dos resultados da validação cruzada entre os valores da acurácia para cada *fold* com a barra de erro.

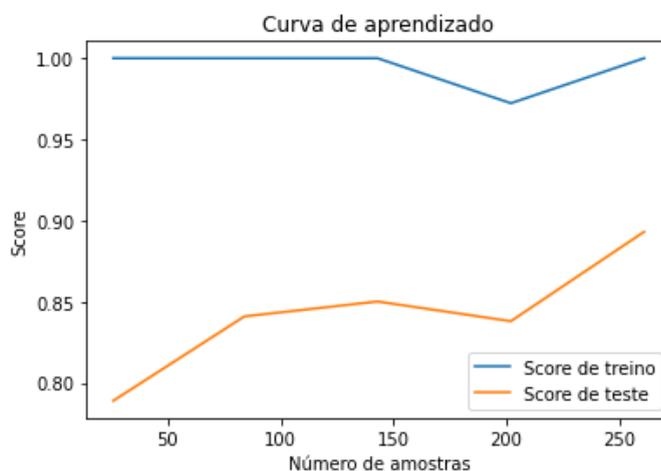


Fonte: Autores (2021)

De acordo com a **Figura 4**, podemos identificar a barra de erro com uma extensão referente ao desvio padrão, sendo um valor baixo de 3%.

Para medir se a quantidade de amostras disponíveis no treinamento é suficiente, utilizamos o método da curva de aprendizagem, no qual separou a quantidade das amostras em porções, e para a realização do treino e teste em cada uma delas, o resultado se apresenta na **Figura 5**.

Figura 5: Representação da aprendizagem com diferentes quantidades de amostras.



Fonte: Autores (2021)

Foi identificado que a curva de aprendizagem referente ao treino e teste, estão muito distantes uma da outra, por este motivo presumimos que existe uma forte relação entre a quantidade do número de amostras para a acurácia, tendo em vista esta análise, o modelo necessita de mais amostras para ser validado por completo.

4 - CONCLUSÕES

Levando-se em consideração todos os aspectos relatados no processo deste trabalho, foi possível validar a viabilidade de uso de tecnologias de aprendizado de máquina no campo para a identificação da soja, tendo como objetivo no início do estudo a acurácia de 80%, e com a conclusão chegando aos 91% de acurácia.

Para futuras pesquisas com o mesmo intuito, podemos aconselhar aos próximos uma contagem de plantas utilizando também imagens de RPA, ou testando

em outras culturas e validando seus respectivos resultados, diversificando modelos de aprendizado de máquina.

5 - AGRADECIMENTOS

Gostaríamos de agradecer a todos que colaboraram para a finalização deste trabalho. Ao nosso professor e orientador João Ricardo Favan, assim como também à pesquisadora Flávia Luize Pereira de Souza, que a todo momento estavam à nossa disposição.

6 - REFERÊNCIAS

ABRAHAM, Ajith. **Artificial Neural Networks**. Handbook of Measuring System Design, Stillwater, v. 8, 2005.

ALPAYDIN, Ethem. **Introduction to Machine Learning**. Massachusetts Institute of Technology, Londres, v. 2, 2010.

ANSELMO, Leandro Gelain; TORRES, Fernanda Tiemi Nishizaki. **Utilização de algoritmos de aprendizagem de máquinas para identificação de campos de culturas de soja (*Glycine max*) e milho (*Zea mays*) por meio de imagens de satélite**. FATEC Shunji Nishimura, Pompéia, 2021.

BRADSKI, Gary. **The OpenCV Library**. Dr. Dobb's Journal: Software Tools for the Professional Programmer, n. 25, v. 11, p. 120-123, 2000.

CHICCO, Davide. **Ten quick tips for machine learning in computational biology**. BioData Mining, v. 10, n. 35, 2017.

EMBRAPA, Empresa Brasileira de Pesquisa Agropecuária. **Soja em números (safra 2020/21)**, Disponível em <<https://www.embrapa.br/soja/cultivos/soja1/dados-economicos>>. Acesso em 1 out. 2021.

HARRIS, Charles. et al. **Array programming with NumPy**. Nature, v. 585, p. 357–362, 2020.

HUNTER, John. **Matplotlib: A 2D graphics environment**, **Computing in Science & Engineering**. vol. 9, n. 3, p. 90-95, 2007.

KOHAVI, Ron. **A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection**. 1995.

MCKINNEY, Wes. **Data Structures for Statistical Computing in Python**. Proceedings of the 9th Python in Science Conference. p. 56-61, 2010.

OLIVEIRA, Felipe Matheus Fernandes de. **Identificação fotométrica de supernovas através de algoritmos de machine learning**. Universidade Federal do Rio de Janeiro, Rio de Janeiro, p. 46, 2019.

PEDREGOSA, Fabian et al. **Scikit-learn: Machine Learning in Python**. Journal of Machine Learning Research, v. 12, p. 2825-2830, 2011.

SOUZA, Flávia Luize Pereira de. **Inteligência Artificial utilizada na determinação longitudinal da cultura da soja**. Universidade Estadual Paulista “Júlio de Mesquita Filho”, Botucatu, p. 53, 2021.

VAN ROSSUM, Guido; DRAKE, Fred. **Python 3 Reference Manual**. CreateSpace, Scotts Valley, 2009.