



Reconhecimento de padrões de produtividade de milho com a abordagem *few-shot learning*

Gabriel Tonon Cimatti¹, Alaine Margarete Guimarães¹, Eduardo Fávero Caires², Gabriel Passos de Jesus³

¹ Departamento de Informática – Universidade Estadual de Ponta Grossa (UEPG), Ponta Grossa – PR – Brazil

² Departamento de Ciência do Solo e Engenharia Agrícola – Universidade Estadual de Ponta Grossa (UEPG), Ponta Grossa – PR – Brazil

³ Programa de Pós-Graduação em Computação Aplicada – Universidade Estadual de Ponta Grossa (UEPG), Ponta Grossa – PR – Brazil

22001926@uepg.br, alainemg@uepg.br, efcaires@uepg.br,
3100122004015@uepg.br

Abstract. *Estimating yield is of particular interest in agriculture, and machine learning (ML) techniques have contributed to making it happen in a faster and more efficient way. Considering the frequent difficulty in acquiring large-scale agricultural data, few-shot learning (FSL) methods have emerged as an alternative. The goal of this work was to evaluate the use of different composition methods of images acquired by Remotely Piloted Aircraft (RPA), associated or not with plant height, for classifying maize yield, using classical ML techniques and FSL approach. The results of using FSL showed that the model with a siamese network can be viable without using the average height of the plant.*

Resumo. *A estimativa de produtividade é importante para agricultura, sendo que técnicas de aprendizado de máquina (AM) têm contribuído para que a mesma possa ocorrer de uma forma mais rápida e eficiente. Considerando a dificuldade de aquisição de dados agrícolas em grande escala, métodos de few-shot learning (FSL) se mostram como alternativa. O objetivo foi avaliar o uso de diferentes métodos de composição de imagem obtidas por Aeronave Remotamente Pilotada, associados ou não à altura da planta, para a classificação de produtividade do milho, utilizando técnicas de AM tradicionais e baseadas em FSL. Os resultados com FSL mostraram que o modelo com rede siamesa pode ser viável sem usar a altura média da planta.*

1. Introdução

O Brasil é o terceiro maior produtor de milho no mundo, atrás apenas dos Estados Unidos e da China [FPA 2023]. Na agricultura, a produtividade é o maior indicador de uma boa safra, e ter uma noção prévia desse número, com base no estado inicial da cultura, pode ser crucial para o agricultor saber se é necessária uma intervenção no modo de cultivo e no trato da planta. Porém, conseguir uma aproximação do valor da produtividade nos diferentes estádios de desenvolvimento da cultura é complexo devido ao alto custo e a longa duração desse procedimento.

O uso de abordagens baseadas em Inteligência Artificial (IA) tem trazido bons resultados para estimativa de produtividade de diferentes culturas quando associadas a imagens aéreas obtidas por diferentes fontes, como satélites e aeronaves remotamente pilotadas (RPA – do inglês *Remotely Piloted Aircraft*), como pode ser visto em Prestes (2020). Dentre as abordagens de IA está o aprendizado de máquina, que aprende padrões em dados históricos de diferentes fontes, como imagens. Normalmente, quanto maior a quantidade de dados melhor o desempenho do aprendizado. Porém, obter dados implica em tempo e custo. Assim, têm sido estudado técnicas que permitam extrair conhecimento de poucos exemplos, conhecidas como *few-shot learning* (FSL) [Wang et al. 2020]. As Redes Neurais Siamesas, baseadas no conceito de aprendizado profundo, adotam a técnica FLS [Chicco 2021]. Não foi encontrado nenhum artigo que utiliza a técnica de FSL para a predição da produtividade de grãos.

Este trabalho visou avaliar métodos diversos de composição de imagens obtidas por RPA, associados ou não à altura da planta, para classificar a produtividade do milho, empregando técnicas tradicionais e técnicas baseadas em FSL.

2. Material e Métodos

As áreas experimentais utilizadas nesse estudo pertencem a Fazenda Escola da Universidade Estadual de Ponta Grossa (UEPG), na região dos Campos Gerais do Paraná, no município de Ponta Grossa. São duas áreas, denominadas “Área 1” (Figura 1) e “Área 2” (Figura 2), nas quais foram cultivadas a cultura do milho.

2.1. Captura das imagens e extração dos dados

As imagens foram capturadas por meio de voos realizados utilizando uma RPA de asa fixa modelo eBee (SenseFly), equipada com uma câmera RGB. As áreas experimentais foram divididas em 32 parcelas, correspondendo a diferentes tratamentos realizados. Dessa forma, nas imagens foram demarcadas as parcelas para extrair uma fração da imagem específica para cada parcela. Em cada uma das 32 parcelas, foi coletada em campo a altura de dez plantas e com essas fez-se o cálculo da altura média das plantas por parcela. (Figura 3). A produção de grãos foi obtida pela colheita por parcela, pesagem dos grãos e correção da umidade em 13% (valor padrão). O cálculo de produtividade de cada parcela considerou o peso final dos grãos na mesma (em kg) dividido pela área da parcela (em ha).




Figura 1. Imagem obtida da Área 1, com a demarcação das 32 parcelas.



Figura 2. Imagem obtida da Área 2, com a demarcação das 32 parcelas.




Figura 3. Altura média das plantas nas áreas 1 e 2.

Utilizando a biblioteca Pillow da linguagem de programação Python [Van Rossum e Drake Jr 1995] foi feito o recorte da imagem de cada área, por parcela, resultando em 32 novas imagens para cada área, todas com as mesmas dimensões. Após isso, foi feito mais dois recortes, um onde as imagens foram divididas em 128 imagens e outro em 256 imagens, sempre de tamanhos iguais. Isso foi feito para testar se o aumento de base de dados iria ajudar na tarefa de aprendizado de máquina.

2.2. Configuração das imagens e da abordagem de aprendizado de máquina

Com a utilização do *software* WEKA [Frank et al. 2016] e do pacote Auto-WEKA [Chris Thornton et al. 2013], foram realizados diversos testes, com diversas formas de interpretação de imagem. O pacote Auto-WEKA é uma ferramenta que busca encontrar o melhor algoritmo de classificação com seus melhores parâmetros para a sua base de dados. É possível definir limites máximos de tempo e espaço para realizar tal tarefa.

A tarefa definida foi de classificação. A produtividade foi convertida para um dado categórico de duas classes: “baixa/média produtividade” (< 15.000 kg/ha) e “alta produtividade” (>= 15.000 kg/ha). O limiar para essas classes foi definido considerando as altas taxas de produtividade ocorridas nas áreas, com o intuito de identificar modelos de classificação para altos patamares de produtividade. Para a área 1, foram obtidas 16 imagens para cada classe. Já para a área 2, foram obtidas 20 e 12 imagens para as classes baixa/média e alta produtividade, respectivamente.

Foi utilizada a técnica de cross-validation para validação, empregando a acurácia como métrica. As imagens separadas foram interpretadas de três modos diferentes: usando um filtro de imagem básico que as separa em três histogramas (vermelho, verde e azul), cada um com 32 compartimentos; usando a média de cor dos pixels em RGB de cada imagem, gerando atributos de média para vermelho, verde e azul, variando de 0 a 255; usando a média de cor dos pixels em HSB (matiz, saturação e brilho) de cada imagem, resultando em atributos de média para matiz, saturação e brilho.

As duas imagens (áreas 1 e 2) foram divididas em uma base de 128 imagens e outra de 256 imagens, para cada área, totalizando 4 bases de imagens diferentes. Cada imagem separada foi interpretada de quatro modos. Foram feitos os testes com e sem a altura para todas as variações e, por fim, um teste somente com a altura como parâmetro.

2.3. Uso da técnica *Few-Shot Learning*

A técnica FSL foi aplicada nas bases de dados utilizando Python e Redes Neurais Siamesas. Por meio da biblioteca matplotlib, os valores RGB das imagens foram extraídos e junto com a altura foram feitos três modelos diferentes: um somente com a imagem, um com a imagem e com a altura e o último só com a altura. Isso foi feito para as bases de 128 imagens e de 256, para cada uma das áreas (áreas 1 e 2).

Para o primeiro modelo, a base de dados de entrada foi transformada em uma matriz multidimensional cujas dimensões são “O número de imagens” pela “largura em pixels” pela “altura em pixels” por três valores RGB. No segundo modelo o que muda é a última dimensão da matriz, de três entradas (RGB) para quatro (RGB e a altura). No terceiro modelo a base é uma matriz de duas dimensões: altura por classe.

Essas bases de dados foram aplicadas em uma rede neural siamesa da biblioteca Keras que consiste em uma combinação de camadas “Conv2D”, “MaxPooling2D”, “Flatten” e “Dense”. Adotamos a validação hold-out com uma divisão variável entre treino (70-90%) e teste (10-30%) nos modelos, utilizando acurácia como métrica.

3. Resultados e Discussão

3.1. Resultados com as diferentes configurações de imagens e algoritmos

Os resultados obtidos com as diferentes configurações de imagens e algoritmos são apresentados nas tabelas 5 a 8. A acurácia quando a altura foi levada em consideração, foi sempre superior a 87% e em vários casos acima de 95%, indicando a importância da altura da planta. Todavia, nem sempre ela é necessária, pois em alguns casos sem altura a acurácia foi maior que 80% (tabelas 5 e 8). Uma acurácia menor que 90% não é a ideal, mas pode ser considerada quando a coleta dos dados é muito custosa.

Tabela 5. Resultados da Área 1 com 128 imagens.

Área 1 - 128	Filtro	Filtro	HSB	HSB	RGB	RGB	Sem Imagem
	Com Altura	Sem Altura	Com Altura	Sem Altura	Com Altura	Sem Altura	Com Altura
Algoritmo	AdaBoost.M1	rules.PART	rules.PART	RandomForest	AdaBoost.M1	RandomForest	AdaBoost.M1
Instâncias Classificadas Corretamente	127 99.2188%	104 81.25%	125 97.6563%	94 73.4375%	116 90.625%	104 81.25%	124 96.875%
Instâncias Classificadas Incorretamente	1 0.7813%	24 18.75%	3 2.3438%	34 26.5625%	12 9.375%	24 18.75%	4 3.125%
Coefficiente Kappa	0.9844	0.625	0.9531	0.4688	0.8125	0.625	0.9375
Raiz Quadrada do Erro Médio	0.0881	0.3719	0.144	0.4127	0.2382	0.3537	0.1329

Tabela 6. Resultados da Área 1 com 256 imagens.

Área 1 - 256	Filtro Com Altura	Filtro Sem Altura	HSB Com Altura	HSB Sem Altura	RGB Com Altura	RGB Sem Altura	Sem Imagem Com Altura
Algoritmo	trees.REPTree	trees.J48	AdaBoost.M1	lazy.lbk	AdaBoost.M1	functions.SMO	rules.PART
Instâncias Classificadas Corretamente	248 96.875%	206 80.4688%	252 98.4375%	168 65.625%	256 100%	174 67.9688%	248 96.875%
Instâncias Classificadas Incorretamente	8 3.125%	50 19.5313%	4 1.5625%	88 34.375%	0 0%	82 32.0313%	8 3.125%
Coefficiente Kappa	0.9375	0.6094	0.9688	0.3125	1	0.3594	0.9375
Raiz Quadrada do Erro Médio	0.1581	0.3731	0.1134	0.444	0.0036	0.566	0.1581

Tabela 7. Resultados da Área 2 com 128 imagens.

Área 2 - 128	Filtro Com Altura	Filtro Sem Altura	HSB Com Altura	HSB Sem Altura	RGB Com Altura	RGB Sem Altura	Sem Imagem Com Altura
Algoritmo	lazy.LWL	rules.OneR	rules.Jrip	rules.OneR	rules.JRip	Multilayer Perceptron	rules.Jrip
Instâncias Classificadas Corretamente	121 94.5313%	80 62.5%	112 87.5%	85 66.4063%	112 87.5%	83 64.8438%	112 87.5%
Instâncias Classificadas Incorretamente	7 5.4688%	48 37.5%	16 12.5%	43 33.5938%	16 12.5%	45 35.1563%	16 12.5%
Coefficiente Kappa	0.8819	0	0.7333	0.1925	0.7333	0.1304	0.7333
Raiz Quadrada do Erro Médio	0.1789	0.6124	0.3048	0.5796	0.3171	0.4813	0.3171

Tabela 8. Resultados da Área 2 com 256 imagens.

Área 2 - 256	Filtro Com Altura	Filtro Sem Altura	HSB Com Altura	HSB Sem Altura	RGB Com Altura	RGB Sem Altura	Sem Imagem Com Altura
Algoritmo	lazy.LWL	AdaBoost.M1	RandomForest	lazy.LWL	trees.LMT	rules.Jrip	lazy.LWL
Instâncias Classificadas Corretamente	241 94.1406%	221 86.3281%	224 87.5%	165 64.4531%	224 87.5%	203 79.2969%	224 87.5%
Instâncias Classificadas Incorretamente	15 5.8594%	35 13.6719%	32 12.5%	91 35.5469%	32 12.5%	53 20.7031%	32 12.5%
Coefficiente Kappa	0.8732	0.7194	0.7419	0.0923	0.7333	0.5035	0.7241
Raiz Quadrada do Erro Médio	0.1966	0.2936	0.2616	0.464	0.3096	0.3944	0.2615

3.2 Resultados da Rede Siamesa

Os resultados obtidos com as redes siamesas apresentaram uma acurácia média menor que a conseguida com os algoritmos usados software WEKA. Entretanto, na Tabela 9 pode ser observada acurácia de 83% no teste com altura e imagem usando 128 imagens, sendo comparável aos do software WEKA.

Tabela 9. Resultados da Área 1 com 128 e com 256 imagens – Rede Siamesa.

Área 1 - 128	Com Imagem Com Altura	Com Imagem	Com Altura	Área 1 - 256	Com Imagem Com Altura	Com Imagem	Com Altura
Acurácia	Treino: 0,9515 Teste: 0,8333	Treino: 0,8462 Teste: 0,8095	0.923	Acurácia	Treino: 0,5217 Teste: 0,5652	Treino: 0,5121 Teste: 0,5217	1
Coefficiente Kappa	-0.08333	0.3575	0.831	Coefficiente Kappa	0	0	1
Raiz Quadrada do Erro Médio	0.6794	0.5651	0.0769	Raiz Quadrada do Erro Médio	0.7845	0.5651	0

A acurácia obtida com as redes siamesas sem o uso da altura média da planta chegou a 80%, mostrando que é um modelo confiável e de fácil aplicação para safras de larga escala. Na Tabela 10 também é apresentada uma acurácia satisfatória de 72% no teste somente com imagem na divisão de 128 imagens.

Tabela 10. Resultados da Área 2 com 128 e com 256 imagens – Rede Siamesa.

Área 2 - 128	Com Imagem Com Altura	Com Imagem	Com Altura	Área 2 - 256	Com Imagem Com Altura	Com Imagem	Com Altura
Acurácia	Treino: 1 Teste: 0,5833	Treino: 0,989 Teste: 0,7273	0.9	Acurácia	Treino: 1 Teste: 0,6087	Treino: 1 Teste: 0,6522	0.8653
Coefficiente Kappa	0.1495	-0.1192	0.8	Coefficiente Kappa	-0.3	-0.3558	0.6956
Raiz Quadrada do Erro Médio	0.7338	0.7071	0	Raiz Quadrada do Erro Médio	0.7845	0.8086	0

4. Conclusões

O desenvolvimento de um modelo de classificação baseado em fotos aéreas e a média de altura das plantas se mostrou eficaz quando usado junto ao *software* WEKA, podendo ser aplicado para qualquer safra de milho.

Os resultados obtidos utilizando a técnica FSL mostraram que, com a base de dados adequada e com a configuração certa, o modelo com uma rede siamesa pode ser aplicado sem o uso da altura média, trazendo grande vantagem ao agricultor.

Agradecimentos

Esta pesquisa foi apoiada pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico.

Referências

- Chicco, D. (2021). Siamese neural networks: An overview. In *Artificial Neural Networks*, p. 73–94.
- FPA. (2023) Brasil é destaque mundial na produção de milho. Disponível em: <<https://agencia.fpagropecuaria.org.br/2022/09/30/brasil-e-destaque-mundial-na-producao-de-milho>>. Acesso em: 25 abril 2023.
- Prestes, C. D. P. (2020). Predição de produtividade de trigo por meio de dados espectrais e altura estimada da planta obtidos por meio de aeronave remotamente pilotada. Dissertação (Mestrado em Computação Aplicada) – Universidade Estadual de Ponta Grossa, Ponta Grossa.
- Thornton, Chris et al. (2013). Auto-WEKA: Combined selection and hyperparameter optimization of classification algorithms, ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, p. 847–855.
- Van Rossum, G; Drake Jr, F.L. (1995). Python reference manual, Centrum voor Wiskunde en Informatica, Amsterdam.
- Wang, Y., Yao, Q., Kwok, J. T. e Ni, L. M. (2020). Generalizing from a few examples: A survey on few-shot learning. ACM computing surveys, ACM New York, USA, p. 1–34.
- Frank, E., Hall, M. A. e Witten, I. H. (2016). The WEKA Workbench. Online Appendix for "Data Mining: Practical Machine Learning Tools and Techniques", Morgan Kaufmann, Fourth Edition, 2016.