

USO DE APRENDIZADO DE MÁQUINA PARA CLASSIFICAÇÃO DE ESPÉCIES FRUTÍFERAS A PARTIR DE IMAGENS RGB

Isaias Brinati Valentim, Thiago Alexandre da Silva Oliveira, Amanda Teixeira Moreira Capacia, João Mendes Cicarini Hott, Maísa Martins de Oliveira, Samuel de Assis Silva

Universidade Federal do Espírito Santo/Centro de Ciências Agrárias e Engenharias, Alto Universitário, S/N, Guararema - 29500-000 – Alegre-ES, Brasil, isaiasbrinativalentim@gmail.com, thiagoalexandre984@gmail.com, amandacapacia@gmail.com, joaoagro18@hotmail.com, maisamartins20@gmail.com, samuel.silva@ufes.br.

Resumo

O artigo apresenta como objetivo testar a viabilidade do sensor RGB, que apresenta menor custo quando comparado aos sensores multiespectrais, para a classificação automatizada de espécies frutíferas, visando a automatização das etapas de produção agrícola. O trabalho integra sensoriamento remoto e aprendizado de máquina utilizando o algoritmo K-Nearest Neighbor (k-NN) para a classificação automatizada. A pesquisa foi conduzida com espécies frutíferas do setor de fruticultura localizado na área experimental do Centro de Ciências Agrárias e Engenharias – UFES. Foi realizado um aerolevantamento utilizando-se um VANT, modelo Phantom 4 Pro, equipado com um sensor RGB-CMOS. A partir das imagens geradas foi feita a classificação pixel-a-pixel através do algoritmo k-NN. Métricas como Precisão, Recall e F-score foram geradas a partir da matriz de confusão. A partir da métricas obteve-se índice kappa de 0.445125, indicando nível fraco de concordância, o que sugere confusão significativa durante a classificação. Não obstante, a classe de solo exposto apresentou elevada precisão, sendo um dado promissor para futuras estratégias de manejo agrícola.

Palavras-chave: Agricultura Digital. Sensoriamento remoto. *Machine Learning*. VANT.

Área do Conhecimento: Engenharia Agrônoma

Introdução

A crescente demanda de alimentos no mundo requer avanços significativos na agricultura, de modo a ampliar a eficiência de produção, otimizando todas as etapas do processo produtivo. Uma das vertentes que se destaca é a Agricultura de Precisão e Digital, que traz consigo diversas ferramentas que potencializam a tomada de decisão, aprimorando a atividade na lavoura. Uma das estratégias desse ramo é aliar o sensoriamento remoto com *machine learning* (aprendizado de máquina) para a classificação automatizada de cultivos agrícolas, plantas daninhas ou solo exposto.

A classificação supervisionada permite o monitoramento agrícola de forma mais eficiente, logo a tomada de decisão pode ser feita de forma mais rápida. Com isso, o desenvolvimento de melhores capacidades de monitoramento agrícola com base em dados de observação da Terra, como o sensoriamento remoto, é fundamental para fortalecer as informações de produção de alimentos e a transparência do mercado (GRIZONNET et al., 2017).

O *machine learning* (ML) emergiu junto de tecnologias de *big data* e computação de alto desempenho, criando assim novas oportunidades para desvendar, quantificar e entender processos intensivos em dados obtidos de ambientes operacionais agrícolas (LIAKOS et al., 2018). De acordo com AHMED et al (2012) a capacidade de localizar e classificar culturas e ervas daninhas a partir de imagens digitais pode levar ao desenvolvimento de equipamentos agrícolas autônomos guiados por visão para aplicação de herbicidas em locais específicos.

Ao se aplicar ML aos dados obtidos dos sensores embarcados em veículos aéreos não tripulados (VANT) é possível proceder com a classificação automática de diferentes alvos no sistema de cultivo, permitindo automatização das etapas produtivas. Com isso os sistemas de gerenciamento de fazendas estão evoluindo para sistemas reais de inteligência artificial, fornecendo recomendações e insights mais

A era digital e suas implicações sociais: Desafios e contribuições

ricos para as decisões e ações subsequentes com o objetivo final de melhoria da produção (MIRANI et al., 2021).

Apesar dos avanços na agricultura digital, o acesso aos sensores ainda é restrito, não estando disponível para todas as categorias produtivas. Logo, é imprescindível testar o uso de diferentes algoritmos com imagens RGB, provenientes de sensores mais acessíveis, visando assim expandir a utilização de tecnologias no meio agrícola.

Metodologia

O estudo foi realizado no polo de fruticultura da área experimental do Centro de Ciências Agrárias da Universidade Federal do Espírito Santo – UFES. No município de Alegre, sul do estado do Espírito Santo. As avaliações foram realizadas nas culturas da bananeira, da mangueira, do maracujazeiro, da aceroleira, do cafeeiro, da goiabeira e da mangueira, que são cultivadas na área, além disso, avaliou-se as plantas daninhas e o solo exposto.

Foi realizado um aerolevanteamento, no mês de novembro, utilizando um veículo aéreo não-tripulado (VANT) multirrotor, modelo Phantom 4 Pro. O VANT aerotransportava um sensor RGB-CMOS capaz de determinar a reflectância nas bandas do espectro eletromagnético correspondentes a parte dos comprimentos do azul (B), do verde (G) e do vermelho (R). O aerolevanteamento foi realizado a uma altura de 80m respeitando a janela de voo de 11 às 13h evitando ao máximo o sombreamento, e com velocidade de deslocamento da aeronave de aproximadamente 9 m.s-1.

As imagens obtidas do aerolevanteamento foram processadas no software Agisoft Metashape, sendo obtido o ortomosaico. A partir do ortomosaico foi construído, no QGIS, um arquivo vetorial de polígonos, onde para cada classe foram feitas 30 amostras. Onde cada amostra englobava pixels correspondentes a classe em questão. Os polígonos obtidos foram usados como exemplos de treinamento da classificação da imagem.

Para a classificação pixel-a-pixel foi utilizado o software Orfeo ToolBox (OTB), que consiste em uma biblioteca de código aberto, desenvolvido pelo CNES (Centro Nacional Francês de Estudos Espaciais), fornecendo ferramentas para o processamento de imagens de sensoriamento remoto (CRESSON et al., 2018).

No OTB o algoritmo utilizado foi o k-Nearest Neighbor (k-NN), utilizado para classificação e regressão, a classificação é baseada na similaridade entre as instâncias de dados, onde a classe de um novo ponto é atribuída com base naquele mais próximo, nomeado como vizinho, de um conjunto de pontos previamente classificados (COVER & HART, 1967). O número de vizinhos, denotado pelo valor "k", determina quantos dos vizinhos mais próximos serão considerados ao fazer a classificação, se o valor de k for muito pequeno, pode ser classificado erroneamente devido à presença de ruído nos dados de treinamento (JAGTAP et al., 2022), logo para a classificação utilizou-se o número de vizinhos igual a 32. O algoritmo foi executado em Python no QGIS.

Foi realizado o treinamento do classificador, resultando na geração de uma matriz de confusão, que proporciona uma avaliação eficaz do modelo de classificação, ao mostrar o número de classificações corretas e as classificações preditas para cada classe em um determinado conjunto de exemplos (MATOS et al., 2009). Essas classificações são: verdadeiros positivos (VP), onde o modelo classifica corretamente as instâncias como pertencentes à classe em questão; verdadeiros negativos (VN), nos quais o modelo classifica corretamente as instâncias como não pertencentes à classe; falsos positivos (FP), quando o modelo incorretamente classifica uma instância como pertencente a uma classe específica, quando na verdade não pertence; e falsos negativos (FN), onde uma instância é equivocadamente classificada como não pertencente a uma determinada classe, embora ela realmente pertença. A partir dessas classificações são calculadas métricas para avaliação do modelo, estando expressas matematicamente na tabela a seguir:

A era digital e suas implicações sociais: Desafios e contribuições

Tabela 1 – Formulação utilizada para avaliação de desempenho do classificador.

Métrica	Fórmula
Precisão	$\frac{VP}{VP + FP}$
Recall	$\frac{VP}{VP + FN}$
F-score	$2 \times \frac{\text{Recall} \times \text{Precision}}{\text{Recall} + \text{Precision}}$

Fonte: CARVALHO, 2020

Onde a precisão é a proporção de instâncias classificadas corretamente como essa classe em relação ao total de instâncias classificadas como essa classe. O recall indica a proporção de instâncias classificadas corretamente como essa classe em relação ao total de instâncias que realmente são dessa classe. E o F-score é uma média ponderada da precisão e do recall, que combina as duas em uma única pontuação.

As métricas oferecem uma análise mais específica para cada classe, desse modo através delas, foi gerado o índice kappa. Esse índice mede a concordância entre as classificações reais e as classificações previstas pelo modelo, oferecendo uma visão geral do desempenho global do classificador. Um valor kappa próximo de 1 indica uma concordância quase perfeita, enquanto um valor próximo de 0 indica que as classificações são essencialmente aleatórias, como demonstrado pela tabela, sendo esta uma interpretação feita por MCHUGH (2012) do índice kappa desenvolvido por COHEN (1960).

Tabela 2 – Interpretação do índice kappa.

Valor de Kappa	Nível de concordância	% de dados confiáveis
0 – 0,20	Nenhum	0 – 4%
0,21 – 0,39	Mínimo	4 – 15 %
0,40 – 0,59	Fraco	15 – 35%
0,60 – 0,79	Moderado	35 – 63%
0,80 – 0,90	Forte	64 – 81%
Acima de 0,90	Quase perfeito	82 – 100%

Fonte: MCHUGH, 2012.

Resultados

A matriz de confusão gerada pelo OTB, disposta na tabela 3, demonstra em cada linha a classe de referência e nas colunas o classificador, desse modo é possível avaliar a classificação feita a partir do algoritmo. As classes estão dispostas de 1 a 8, onde são respectivamente: bananeira, mangueira, maracujazeiro, aceroleira, cafeeiro, goiabeira, mangueira, plantas daninhas e solo exposto. A diagonal principal demonstra os casos onde as instâncias foram classificadas corretamente pelo modelo, indicando os verdadeiros positivos.

Tabela 3 – Matriz de confusão gerada pelo modelo utilizado para classificação automatizada de espécies frutíferas.

Classe de referência	Classe produzida							
	1	2	3	4	5	6	7	8
1	1011	522	735	176	773	691	490	12
2	474	1159	1286	144	696	252	399	0
3	362	683	2744	23	244	195	158	1
4	27	132	73	2887	112	177	389	613
5	558	575	647	275	1568	221	564	2
6	263	285	444	433	459	1933	584	9


A era digital e suas implicações sociais: Desafios e contribuições

7	244	273	264	276	408	368	2526	51
8	0	0	0	73	1	0	13	4323

Fonte: o autor.

Com os dados da matriz de confusão foi possível gerar um gráfico (Gráfico 1) para melhor compreensão da classificação. Nota-se que a tendência era de a matriz principal se encontrar com a tonalidade mais escura de azul em caso de uma classificação com nível maior de concordância. Contudo é perceptível que houve um elevado grau de confundimento, em destaque para a classe 2, que foi mais classificada como 3 do que propriamente como 2.

Gráfico 1 – Matriz de confusão gerada pelo modelo de classificação.



Fonte: o autor.

A partir dos valores dispostos na matriz de confusão, o OTB gerou três métricas, que estão dispostas na tabela 4. A partir dessas métricas é possível aferir sobre qual classe apresentou maior precisão, ou seja, teve uma proporção maior de verdadeiros positivos em relação ao número total de instâncias que foram classificadas como dessa classe.

Tabela 4 – Métricas calculadas a partir da matriz de confusão.

Classes	Precisão	Recall	F-score
Bananeira	0.3439	0.2293	0.2751
Maracujazeiro	0.3194	0.2628	0.2883
Aceroleira	0.4431	0.6222	0.5176
Cafeeiro	0.6734	0.6546	0.6639
Goiabeira	0.3679	0.3556	0.3617
Mangueira	0.5038	0.4383	0.4688
Plantas daninhas	0.4931	0.5728	0.5299
Solo	0.8627	0.9803	0.9177

Fonte: o autor.

As métricas expressas na tabela 4 avaliam o desempenho do classificador por classe e permite a avaliação global, pois a partir delas foi calculado o índice kappa, que apresentou valor igual a 0.4451, indicando um nível de concordância fraco, segundo a tabela 2.

Discussão

A era digital e suas implicações sociais: Desafios e contribuições

Observa-se que as classes 1, 2, 3, 5 e 7 apresentaram um número de falsos positivos maior que de verdadeiros positivos, indicando que o modelo classificou um elevado número de instâncias de outras classes como sendo dessas citadas. Isso refletiu nos valores de Precisão mais baixos, sendo todos abaixo de 0.5.

As classes 1, 2, 5 e 6 apresentaram Recall abaixo de 0.5 indicando que apresentaram maior proporção de falsos negativos comparado com verdadeiros positivos, demonstrando que o modelo classificou elevado número de instâncias como não pertencentes a classes, contudo realmente pertenciam.

Por conta da maioria das classes (plantas) avaliadas serem caracterizadas por elevada capacidade vegetativa, os pixels apresentaram em sua maioria coloração semelhante ou igual. Desse modo, existe elevada similaridade espectral entre as classes. Com isso houve certo grau de dificuldade do modelo em distinguir as classes durante a classificação.

Houve um elevado número de instâncias das classes referentes às espécies frutíferas que foram classificadas como pertencentes à classe 7, relativa às plantas daninhas, sendo que o inverso também ocorreu. Portanto esse tipo de ambiguidade pode trazer certos problemas durante a adoção das estratégias de manejo em campo.

Ademais torna-se imprescindível testar ajustes ao modelo, como variação no número de amostras usadas na classificação. Um número maior de amostras implicará em uma base maior de dados para comparação durante a classificação. Além disso, é possível calcular índices de vegetação, o que diminuiria a similaridade entre as classes, aumentando a precisão do modelo.

Por fim, percebe-se que a classe 8, pertinente ao solo exposto, apresentou elevada precisão e recall, sendo as maiores entre todas as classes. Esse resultado permite aferir a capacidade do modelo para estimar áreas que contenham solo exposto de maneira precisa. Logo, se faz necessário novas pesquisas visando aproveitar essa eficácia em futuras estratégias de manejo.

Conclusão

Em síntese o modelo proposto para classificação utilizando as imagens RGB apresentou um nível fraco de concordância, evidenciado pela baixa precisão na distinção entre as diferentes classes. A dificuldade em discriminar com precisão as classes pode comprometer a otimização das decisões do manejo agrícola. Contudo, um aspecto notável é a elevada precisão do modelo para classificação de áreas com solo exposto em meio aos cultivos. Essa informação promissora pode ser utilizada para potencializar estratégias de manejo, quanto a recuperação de áreas que estejam ou que apresentem potencial de degradação.

Referências

AHMED, F.; AL-MAMUN, H.; BARI, A.; HOSSAIN, E.; KWAN, P. Classification of crops and weeds from digital images: A support vector machine approach. **Crop Protection**, v. 40, p. 98-104, 2012.

CARVALHO, E. D., CARVALHO, E. D., DE CARVALHO FILHO, A. O., DE ARAÚJO, F. H. D. & RABELO, R. D. A. L. Diagnosis of COVID-19 in CT image using CNN and XGBoost. In: **2020 IEEE Symposium on Computers and Communications (ISCC)**, p. 1-6, 2020.

COHEN, Jacob. A coefficient of agreement for nominal scales. **Educational and psychological measurement**, v. 20, n. 1, p. 37-46, 1960.

COVER, T.; HART, P. Nearest neighbor pattern classification. **IEEE transactions on information theory**, v. 13, n. 1, p. 21-27, 1967.

CRESSON, R.i; GRIZONNET, M.; MICHEL, J. Orfeo ToolBox Applications. **QGIS and Generic Tools**, v. 1, p. 151-242, 2018.

A era digital e suas implicações sociais: Desafios e contribuições

GRIZONNET, M.; MICHEL, J.; POUGHON, V.; INGLADA, J.; SAVINAUD, M.; CRESSON, R. Orfeo ToolBox: Open source processing of remote sensing images. **Open Geospatial Data, Software and Standards**, v. 2, n. 1, p. 1-8, 2017.

JAGTAP, S.T.; PHASINAM, K.; KASSANUK, T.; JHA, S.S.; GHOSH T.; THAKAR, C.M. Towards application of various machine learning techniques in agriculture. **Materials Today: Proceedings**, v. 51, p. 793-797, 2022.

LIAKOS, K.G.; BUSATO, P.; MOSHOU, D.; PEARSON, S.; BOCHTIS, D. Machine learning in agriculture: A review. **Sensors**, v. 18, n. 8, p. 2674, 2018.

MATOS, P.F.; LOMBARDI, L.O.; CIFERRI, R.R.; PARDO, T.A. S. CIFERRI, C.D.A.; VIEIRA, M. T. P. Relatório técnico "métricas de avaliação". Universidade Federal de São Carlos, 2009.

MCHUGH, Mary L. Interrater reliability: the kappa statistic. **Biochemia medica**, v. 22, n. 3, p. 276-282, 2012.

MIRANI, A.; MEMON, M.S.; CHOCHAN, R.; WAGAN, A.A.; QABULIO, M. Machine learning in agriculture: A review. **LUME**, v. 10, p. 5, 2021.

Agradecimentos

O presente trabalho foi realizado com apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq, da Universidade Federal do Espírito Santo – UFES e da equipe do Laboratório de Mecanização e Agricultura de Precisão e Digital – LabMAP/UFES.