

SUPPORT VECTOR MACHINE E IMAGENS AÉREAS PARA IDENTIFICAÇÃO DE SECA DOS PONTEIROS EM CAFEEIROS

Samuel L. F. de ARAUJO¹; Thomé S. ALMEIDA²

RESUMO

Detectar problemas existentes na lavoura pode se tornar uma tarefa difícil quando esta se localiza por grandes extensões. O sensoriamento remoto é uma importante ferramenta na identificação do estado atual de uma determinada cultura agrícola. Desta forma, este projeto tem como objetivo avaliar a técnica de classificação *Support Vector Machine* para identificação de seca dos ponteiros presentes em plantações de culturas de café. Para isto, foram utilizadas imagens provenientes de uma câmera convencional a bordo de um VANT. No âmbito computacional serão utilizadas técnicas de aprendizado de máquina e técnicas de processamento digital de imagem na aplicação do método de segmentação e extração de atributos. A técnica de classificação utilizada para o projeto foi a SVM, presente na biblioteca scikit-learn. Para a validação da classificação foram aplicadas as métricas precisão, revocação e pontuação-f1. Os resultados apresentam uma acurácia de 97% na identificação de ramos secos, apontando um reconhecimento satisfatório das secas dos ponteiros na cena apresentada.

Palavras-chave: OBIA; Aprendizado de máquina; Agricultura de precisão.

1. INTRODUÇÃO

O monitoramento das culturas agrícolas se mostra importante para a detecção de problemas ou condições existentes na lavoura, contribuindo para tomadas de decisão que visem aumentar a produtividade e melhoria do produto. Muitas aplicações em lavouras possuem o intuito de gerar mapas de monitoramento de infestação de pragas e de cobertura, estimativa de biomassa, predição de rendimento e estresse de colheita (PAJARES, 2015).

Já no âmbito computacional, a classificação de dados tem sido estudada por várias disciplinas (AGGARWAL, 2014). Possui aplicações em textos, multimídias, redes sociais e dados biológicos. Além disso, também pode ser aplicada em diferentes cenários de acordo com os dados disponibilizados, sendo o algoritmo de classificação dependente do domínio dos dados e do cenário do problema. Dentre os algoritmos de classificação pode-se citar os algoritmos estatísticos, onde o *Support Vector Machine* vem se destacando quando há uma menor quantidade de dados disponíveis para análise (MOUNTRAKIS et al., 2011). Este classificador apresentou sucesso ao ser aplicado na classificação com imagens de cultura agrícola (EBRAHIMI et al, 2017).

1 Bolsista PIBIC/FAPEMIG, IFSULDEMINAS – Campus Passos. E-mail: samuel.araujo@alunos.ifsuldeminas.edu.br.

2 Orientador, IFSULDEMINAS – Campus Passos. E-mail: thome.almeida@ifsuldeminas.edu.br.

Com isto, foi proposta nesse trabalho uma análise em cenas de imagens de culturas de café a fim de identificar áreas com o problema de seca dos ponteiros das plantas utilizando o classificador *Support Vector Machine* (SVM). Serão utilizadas imagens aéreas produzidas por um veículo aéreo não tripulado (VANT) de culturas cafezeiras presente no IFSULDEMINAS - *Campus* Machado. As etapas de segmentação e extração de atributos foram realizadas no sistema de informações geográficas TerraView e a classificação foi realizada pela ferramenta scikit-learn.

2. MATERIAL E MÉTODOS

Foi selecionado a região cafeeira para o imageamento presente em uma área experimental do IFSULDEMINAS - *Campus* Machado. As imagens obtidas nas áreas foram empregadas para o treinamento e na validação do SVM. Para a obtenção das imagens, foi utilizada uma câmera convencional presente em um *Phantom 4*, capaz de adquirir as bandas do sistema de cores RGB.

O método de segmentação que utilizado no trabalho foi o Crescimento de Regiões Médio disponibilizado no software TerraView, onde os parâmetros: tamanho mínimo de segmentos e o limiar de similaridade foram alterados para 30 e 0.02 respectivamente. As bandas utilizadas na segmentação foram a Vermelha, Verde e Azul, além do índice de vegetação *Excess Green* (ExG), descrito na Equação 1.

$$ExG = 2 * (G / (R + G + B)) - R / (R + G + B) - B / (R + G + B) \quad (1)$$

em que,

- G são os valores da banda do verde;
- R são os valores da banda do vermelho;
- B são os valores da banda do azul.

Após a etapa de segmentação, foi realizada a extração dos atributos utilizados como entradas para as etapas de treinamento e validação. Atributos como máximo e mínimo valor, média e mediana de cada objeto foram agrupados de acordo com o identificador de cada região, gerando com isso uma tabela. As regiões foram divididas para dois propósitos servir como entrada para o treinamento ou na validação do classificador.

Foi utilizada a SVM presente na biblioteca *scikit-learn* para realizar o processo de classificação. O método multi classe que foi utilizado é o *one-against-one* (OAO), no qual a classificação é dividida em M modelos binários de classificação (ZHENG et al., 2014). Dentre os quatro *kernels* mais utilizados (linear, polinomial, *radial basis function* e sigmoide), foi utilizado o *kernel* linear.

Os parâmetros que foram empregues na análise do classificador foram a precisão, revocação e pontuação-f1, a primeira se dá pela proporção das amostras serem preditas como positivas quando

são verdadeiros positivos enquanto a segunda é a proporção de verdadeiros positivos que foram preditos como positivos, já a pontuação-f1 é a média harmônica entre a precisão e revocação.

3. RESULTADOS E DISCUSSÕES

Os resultados obtidos após as etapas de segmentação, extração e classificação apresentaram os seguintes valores para uma área retirada de uma cena da área de estudo:

Tabela 1 - Avaliação dos resultados da classificação

	Precisão	Revocação	Pontuação-f1
Ramo Seco	0.97	0.97	0.97
Café	0.92	0.80	0.86
Plantas Rasteiras	0.95	0.91	0.93
Solo Exposto	0.96	0.96	0.96
Sombra	0.80	1.00	0.89
Média	0.94	0.94	0.94

Fonte: Autor

Para a área informada, os resultados apresentados na tabela apresentam uma alta porcentagem de precisão, revocação e pontuação-f1, demonstrando que foi possível identificar as áreas do plantio com o problema da seca dos ponteiros, revelando adequada para o cenário proposto. A média das métricas utilizadas para a avaliação também se mantiveram altas, indicando que os objetos presentes na cena foram adequadamente identificados.

Nesta análise foi obtida uma acurácia de 85.10% utilizando 47 amostras em uma cena distinta do treinamento. Em Chen *et al.* (2018), com a proposta de identificar a ferrugem em cultura de trigo o trabalho obteve uma acurácia entre 90.80% e 95.10% na classificação.

4. CONCLUSÕES

Neste trabalho, foi aplicado o método de classificação SVM em cenas cafeeiras para identificação de seca dos ponteiros no plantio. Os resultados obtidos na segmentação e extração de características pelo software TerraView apresentaram boas características proporcionando a identificação dos objetos.

Foi possível observar pela análise dos resultados apresentados que a identificação das secas dos ponteiros obteve uma boa performance ao utilizar a técnica SVM com os parâmetros padrões da biblioteca scikit-learn.

AGRADECIMENTOS

Os autores agradecem o apoio da FAPEMIG no desenvolvimento deste trabalho, através da concessão de bolsa de pesquisa.

REFERÊNCIAS

- AGGARWAL, C. C. *Data classification: algorithms and applications*. New York: CRC Press, 2014.
- CHEN, D. ; SHI, Y.; HUANG W.; ZHANG J.; WU K. Mapping wheat rust based on high spatial resolution satellite imagery. **Computers and Electronics in Agriculture**, v. 152, p. 109-116, 2018.
- PAJARES, G. Overview and current status of remote sensing applications based on unmanned aerial vehicles (UAVs). **Photogrammetric Engineering & Remote Sensing**, v. 81, n. 4, p. 281-329, 2015.
- MOUNTRAKIS, G.; IM, J.; OGOLE, C. Support vector machines in remote sensing: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**. v. 66, p. 247-259, 2011.
- EBRAHIMI, M. A.; KHOSHTAGHAZA, M. H.; MINAEI S.; JAMSHIDI B. Vision-based pest detection based on SVM classification method. **Computers and Electronics in Agriculture**, v. 137, p. 52-58, 2017.
- ZHENG, B; MYINT, S. W.; THENKBAIL, P. S.; AGGARWAL, R. M. A support vector machine to identify irrigated crop types using time-series Landsat NDVI data. **International Journal of Applied Earth Observation and Geoinformation**, v. 34, p. 103-112, 2015.