

AValiação de Descritores de Imagem no Aprendizado de Máquina para a Detecção de Falhas de Plantio de Feijão-Comum

Guilherme Makoto Harakuchi¹, Jean Vitor Cavalcante Calisso², Luiz Fernando Sommaggio Coletta¹

¹ Universidade Estadual Paulista (UNESP), Faculdade de Ciências e Engenharia, Câmpus de Tupã, makotoharakuchi@gmail.com, luiz.coletta@unesp.br

² ETEC Professor Massuyuki Kawano, Tupã/SP, jean.calisso@etec.sp.gov.br

RESUMO

Imagens aéreas resultantes do uso de Veículos Aéreos Não Tripulados (VANTs) ajudam a identificar, em particular, falhas de plantio que afetam diversas áreas plantadas, como as que se destinam ao cultivo do feijão-comum. Em tal contexto, a identificação de padrões de solo em imagens envolve, em grande parte, o uso de métodos/algoritmos de Aprendizado de Máquina. Este trabalho teve como foco a etapa de extração de *features* das imagens coletadas, a qual esta intimamente relacionada ao desempenho da aplicação. Assim, estudou-se três diferentes descritores de imagens, CIE-LAB, BIC (*Border/Interior pixel Classification*) e Haralick, os quais foram usados individualmente ou combinados para enriquecer representações. Estes descritores buscam representar imagens extraíndo delas um conjunto de atributos numéricos. Resultados de classificação sobre os diferentes espaços de atributos gerados mostraram que as melhores acurácias provêm de representações com menos atributos e, em especial, ao se adotar o filtro de atributos *Correlation-based Feature Selection*.

Palavras-chave – Agricultura de Precisão, Classificação de Dados, Visão Computacional, Descritores de Imagens, Falhas de Plantio.

ABSTRACT

Aerial images resulting from the use of Unmanned Aerial Vehicles (UAVs) help to identify, in particular, planting failures that affect several planted areas, such as those used to grow common bean. In this context, the identification of soil patterns in images involves typically the use of Machine Learning methods/algorithms. This work focused on the feature extraction of the collected images, which is closely related to the performance of the application. Thus, three different image descriptors, CIE-LAB, BIC (Border/Interior pixel Classification), and Haralick, were used individually or combined to enrich representations. These descriptors aim to representing images by extracting from them a set of numerical features. Classification results on different feature spaces showed that the best accuracies come from representations with fewer features, and especially when adopting the filter Correlation-based Feature Selection.

Keywords – Precision Agriculture, Data Classification, Computer Vision, Image Descriptors, Planting Failures.

1. INTRODUÇÃO

A inspeção em culturas, para a identificação de pragas, gramíneas, falhas de plantio, etc. é realizada tradicionalmente por análise visual de especialistas e profissionais bem treinados da área. Contudo, esta tarefa de observação é muito dispendiosa e de pouca acurácia, principalmente em plantios de grandes extensões, onde normalmente talhões são amostrados para esta verificação. Neste contexto, a análise de dados visuais capturados por Veículos Aéreos Não Tripulados (VANTs) torna-se uma alternativa barata e mais efetiva [1, 2]. Adicionalmente (e naturalmente), envolver ferramentas tecnológicas e computacionais nesse processo é uma tendência já bastante aceita como parte da evolução da agricultura no Brasil e no mundo [3].

Tendo em mãos dados visuais obtidos por um VANT, a ideia primordial deste trabalho foi, então, se utilizar de sistemas inteligentes capazes de detectar padrões nessas imagens. Sendo assim, empregou-se técnicas de Aprendizado de Máquina [4] capazes de identificar, dentre os diferentes padrões contidos nas imagens, especificamente aqueles referentes à falha de plantio em uma cultura de feijão-comum.

O feijão-comum é uma cultura composta por três safras anuais, a saber: safra das águas, safra da seca e a safra irrigada. A primeira safra é cultivada principalmente entre os meses de Agosto a Novembro nas regiões Sul, Sudeste e Centro-Oeste do Brasil, além de alguns Estados do Norte e Nordeste. A segunda safra acontece nas mesmas regiões, porém nos Estados da região Norte ocorre em apenas um período por causa do consórcio com o milho; por via, realizada nos meses de Dezembro a Abril. No Centro-Sul, por fim, ocorre a terceira safra entre os meses de Abril a Julho por meio de irrigação, na qual a produção é um pouco menor que a da primeira safra [5].

Existem vários tipos de fungos no solo que podem causar grandes perdas na produção de feijão-comum, assim como, a murcha-de-fusário, murcha-de-esclerócio, podridão-radicar, podridão-cinza-da-haste, mofo-branco, dentre outros. Grande parte da devastação das áreas plantadas ocorre devido à resistência desses agentes nocivos, os quais podem sobreviver no mesmo ambiente durante anos por causa da presença de matéria orgânica morta, restos culturais e baixo alcance dos fungicidas [6].

Diante da necessidade de identificação das falhas de plantio, inclusive para se estimar a produção, o foco deste trabalho foi na etapa de pré-processamento das imagens coletadas, a qual esta intimamente relacionada ao desempenho da aplicação. Sendo assim, foram investidos

esforços para o estudo e implementação computacional de três diferentes descritores de imagens: CIE-LAB [7, 8], BIC (*Border/Interior pixel Classification*) [9] e Haralick [10]. Esses descritores visam representar imagens computacionalmente, extraindo delas um conjunto de atributos numéricos. Tais atributos podem ser, então, fornecidos para os chamados Classificadores de Dados [11] para que se possa detectar solo (ou seja, a falha de plantio).

2. MATERIAIS E MÉTODOS

Uma das principais tarefas de Aprendizado de Máquina é a Classificação de Dados, a qual consiste de dois passos [11]: (i) um modelo (classificador) é treinado a partir de um conjunto de dados de treinamento, no qual cada objeto (e.g., imagem) está rotulado de acordo com a categoria/classe a qual pertence; (ii) subsequentemente, o classificador obtido em (i) é usado para inferir a classe de objetos não rotulados (i.e., novos objetos não observados durante o treinamento). Formalmente, um objeto trata-se de um vetor \mathbf{x} , formado por M atributos (numéricos) e atrelado a um rótulo de classe de um conjunto finito de rótulos de classe $C = \{c_1, c_2, \dots, c_k\}$. A tarefa de classificação, então, considera um conjunto de treinamento $\mathcal{X} = \{\langle \mathbf{x}_i, c_\ell^i \rangle\}_{i=1}^N$, $c_\ell^i \in C$, na construção de uma função $f(\mathbf{x}) : \mathbb{R}^M \rightarrow C$, ou seja, $\{\langle \mathbf{x}_i, c_\ell^i \rangle, i = 1, \dots, N; \ell = 1, \dots, k\} \mapsto f$. A função f é um classificador dito supervisionado capaz de prever o rótulo de classe de novos objetos, cuja classe/categoria é desconhecida.

Os classificadores, por conta da capacidade de predição a partir dos dados, têm sido amplamente utilizados em diversas áreas do conhecimento humano. Por exemplo, estas ferramentas têm sido usadas no reconhecimento de escrita [12], classificação de sentimentos [13], análise de dados de expressão gênica [14], detecção de padrões em imagens [1], modelagem do ciclo hidrológico [15], classificação de solos [16], etc. Os classificadores elementares, de uso comum para diferentes áreas do conhecimento humano, são [11, 17]:

- Redes Bayesianas (BN): redes construídas a partir de distribuições probabilísticas;
- Naive Bayes (NB): baseia-se no teorema de Bayes para a inferência das classes/categorias;
- Multilayer Perceptron (MLP): Rede Neural que tradicionalmente usa o algoritmo de treinamento *Backpropagation* para atualizar pesos entre neurônios e aprender padrões;
- Máquina de Vetores de Suporte (SVM): constrói um hiperplano de decisão que proporciona maior margem entre as classes do problema de maneira a reduzir o risco/erro de classificação;
- K-Vizinhos Mais Próximos (K-NN): baseia-se na proximidade dos objetos no espaço de atributos, classificando novos objetos com base em seus K vizinhos mais próximos;
- Árvore de Decisão (DT): gera uma árvore na qual cada nó é um atributo que subdivide os objetos até sua

classificação; atributos com maior eficiência em separar objetos pelas suas classes tendem a ficar no topo da árvore.

- Floresta Aleatória (RF): constrói árvores de decisão diversificadas, sendo que os atributos para cada nó de cada árvore são escolhidos aleatoriamente; busca-se maximizar a acurácia de classificação com base na melhor combinação das árvores disponíveis.

O desempenho dos classificadores, como os apresentados acima, depende muito do conjunto de atributos usado para representar os objetos em classificação – no caso, as imagens aéreas do plantio de feijão-comum. Neste trabalho, conjuntos de atributos foram, então, formados com base nos chamados descritores de imagens, os quais extraíram atributos quantitativos das imagens levando-se em conta, por exemplo, características de cor, textura, etc. Em particular, foram implementados no *Software* MATLAB, tendo como base a literatura, três descritores de imagens, a saber:

- CIE-LAB: gera 3 atributos, mas apenas 2 foram usados: os que se referem as coordenadas cromáticas vermelho/verde (A) e amarelo/azul (B). Destaca-se que, A possui valores positivos para cores avermelhadas e valores negativos para esverdeadas, enquanto que B possui valores positivos para cores amareladas e valores negativos para azuladas. Estas escalas estão muito próximas da percepção visual humana e são muito usadas, por exemplo, no monitoramento da maturação de frutas [7, 8].
- BIC (*Border/Interior pixel Classification*): considera imagens requantizadas – com 16 cores – para gerar dois histogramas: o primeiro com base nos píxeis classificados como parte de bordas, e o segundo para aqueles píxeis classificados como sendo do interior da imagem. Um pixel é classificado como borda se, ao menos, um de seus vizinhos possui cor quantizada diferente; caso contrário, é classificado como do interior da imagem. Produziu-se, assim, um conjunto com 32 atributos [1, 9].
- Haralick: utiliza-se aqui 6 atributos representativos de texturas: máxima probabilidade, correlação, contraste, uniformidade (energia), homogeneidade e entropia. Esses atributos são estatísticas extraídas de uma matriz de coocorrência baseada na frequência de tons de cinza na imagem para cada pixel (de referência) e um de seus vizinhos. Levou-se em conta os 8 possíveis vizinhos de um dado pixel produzindo, assim, 48 atributos [1, 10].

Os atributos gerados pelos descritores apresentados foram usados individualmente e também combinados com o intuito de complementar a representação das imagens verificando, assim, se tal junção fornece melhores resultados. Considerou-se as seguintes combinações: LAB-BIC, LAB-HAR, BIC-HAR e LAB-BIC-HAR (por questões de simplificação, LAB refere-se ao CIE-LAB e HAR ao Haralick). Ao notar que unindo todos os atributos produzidos (LAB-BIC-HAR) compõe-se um conjunto com 82 atributos, testou-se também

um método para a redução de dimensionalidade dos dados. O filtro *Correlation-based Feature Selection* (CFS) [18] reduz o número de atributos de um conjunto de dados mantendo apenas aqueles atributos que são altamente correlacionados com as classes, mas que são pouco correlacionados entre si. Vários trabalhos mostram que filtros, como o CFS, viabilizam melhorias na classificação de dados [19].

Para avaliar os descritores usados, suas combinações, bem como o filtro CFS, na capacidade de representar padrões contidos em imagens aéreas da cultura do feijão-comum, levou-se em conta a acurácia balanceada dos classificadores em um procedimento experimental, no qual duas imagens de 512x512 píxeis foram usadas. Estas imagens estão apresentadas na Figura 1¹.




Figura 1: Duas imagens aéreas do cultivar de feijão-comum com falhas de plantio.

3. RESULTADOS

As duas imagens usadas neste trabalho (ver Figura 1 na seção anterior) foram recortadas em subimagens de 16x16 píxeis gerando, então, 1024 objetos provindos de cada imagem. Estes objetos tiveram suas *features* extraídas compondo, então, um banco de dados para treinamento e teste dos Classificadores de Dados. O banco de dados oriundo da primeira imagem (a), possui 884 objetos da classe “*planta*” e 140 da classe “*solo*”; já o da segunda imagem (b), 981 são da classe “*planta*” e apenas 43 da classe “*solo*”. Especialistas da área agrônoma rotularam estas subimagens, portanto, como sendo “*planta*” ou “*solo*” [1]. Por se tratar de um problema de classificação com desbalanceamento de classes, utilizou-se a medida de acurácia balanceada para se estimar a capacidade de generalização dos classificadores.

O procedimento experimental considerou o treinamento dos classificadores com objetos de uma imagem – e.g., imagem (a) – e subsequentemente a classificação de objetos da outra imagem – imagem (b). Anotados os resultados de classificação nesta última imagem, o experimento foi realizado novamente, mas alternando as imagens. Ou seja, treinamento com objetos da imagem (b) e teste/classificação com objetos da imagem (a). Tendo também estes resultados, a Tabela 1 mostra a média das acurácias balanceadas obtidas na imagem (a) e na imagem (b) para cada classificador induzido sobre os diferentes espaços de atributos gerados. Os melhores resultados aparecem em negrito.

¹Dados obtidos em <<http://www.icmc.usp.br/~moacir/data>>.

4. DISCUSSÃO

Bons resultados foram obtidos ao se combinar atributos dos três descritores testados (LAB-BIC-HAR). Por exemplo, ao se utilizar uma Árvore de Decisão (DT), neste caso, obteve-se acurácia de 0,8468 (ver Tabela 1). Contudo, resultados neste espaço de atributos envolvem a complexidade de 82 dimensões, o que pode ser custoso em termos de eficiência das ferramentas de classificação, sobretudo ao se considerar problemas com um número maior de objetos. Ao submeter este espaço de atributos ao filtro CFS, o número de atributos para o banco de dados da imagem (a) na Figura 1 foi redimensionado para 4, enquanto que para a imagem (b) para apenas 3 atributos. Ao se testar os classificadores neste espaço obteve-se os melhores resultados. Em particular, para cinco dos sete classificadores usados, as maiores acurácias foram quando este espaço de atributos foi adotado. Os outros dois classificadores (K-NN e DT) alcançaram melhores acurácias quando se optou pelo uso do espaço de atributos gerado pelo CIE-LAB (LAB na Tabela 1). Convém destacar que, para este descritor, o número de atributos usados foi apenas dois.

Na última linha da Tabela 1 aparecem as médias de acurácias dos sete classificadores para cada conjunto de atributos. Observa-se que, no geral, bons resultados foram alcançados pelo conjunto de atributos provenientes do LAB e CFS (acima de 0,8). Esta constatação é interessante por conta de que estes são os dois menores espaços de atributos testados. Neste sentido, enquanto os espaços de atributos formados pelos descritores BIC e Haralick envolvem no mínimo 32 e 48 atributos, respectivamente, estes não alcançaram bons resultados em comparação com os espaços de atributos menores (que são mais eficientes).

A Figura 2 exibe as imagens (a) e (b) com as classificações (em vermelho) dos objetos/subimagens da classe “*solo*”. Para a imagem (a) utilizou-se uma Árvore de Decisão sobre os atributos LAB, obtendo acurácia de 0,9083. Para a imagem (b) induziu-se uma MLP sobre o espaço de atributos oriundo do CFS, produzindo acurácia de 0,8933.




Figura 2: Áreas classificadas como solo nas duas imagens aéreas avaliadas.

5. CONCLUSÕES

Estudou-se o uso de descritores de imagens e diversos classificadores na detecção de falhas de plantio em imagens aéreas capturadas por um VANT. Os melhores resultados foram obtidos ao se adotar conjuntos de atributos

Tabela 1: Acurácia balanceada de cada classificador avaliado com base no espaço de atributos usado.

Classif.	LAB	BIC	HAR	LAB-BIC	LAB-HAR	BIC-HAR	LAB-BIC-HAR	CFS
BN	0,8184	0,5000	0,5598	0,8184	0,7276	0,5598	0,7276	0,8406
NB	0,8649	0,5611	0,6019	0,8319	0,7088	0,6146	0,6991	0,8730
MLP	0,8628	0,5443	0,5142	0,8007	0,8272	0,5473	0,8160	0,8901
SVM	0,8378	0,5000	0,5343	0,8323	0,8293	0,5291	0,8288	0,8505
K-NN	0,8530	0,4969	0,5168	0,5867	0,6829	0,5138	0,5848	0,8052
DT	0,8320	0,5252	0,5108	0,8518	0,8575	0,5139	0,8468	0,8004
RF	0,8409	0,5000	0,5406	0,7937	0,7337	0,5209	0,6562	0,8658
Média	0,8443	0,5182	0,5398	0,7880	0,7667	0,5428	0,7370	0,8465

formados pelo descritor CIE-LAB. Contudo, a maioria dos classificadores testados apresentou as maiores acurácias quando o espaço de atributos foi reduzido por meio do filtro *Correlation-based Feature Selection* (CFS).

Enquanto este trabalho focou na cultura do feijão-comum, outros experimentos para outras culturas poderão ser realizados em trabalhos futuros. Em específico, pretende-se investigar mais profundamente o comportamento de descritores, como o CIE-LAB, e também dos filtros de atributos, como o CFS, sendo que, no contexto desta pesquisa, se apresentaram como alternativas mais eficazes e eficientes.

6. AGRADECIMENTOS

Agradecemos à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), Proc. 2017/00357-7, e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), Bolsa PIBIC-EM #4275, pelo apoio financeiro.

7. REFERÊNCIAS

- [1] PONTI, M. et al. Precision agriculture: Using low-cost systems to acquire low-altitude images. *IEEE Computer Graphics and Applications*, IEEE, v. 36, n. 4, p. 14–20, 2016.
- [2] SOUZA, J. R. et al. Automatic detection of ceratocystis wilt in eucalyptus crops from aerial images. In: *Robotics and Automation (ICRA), 2015 IEEE International Conference on*. [S.l.: s.n.], 2015. p. 3443–3448.
- [3] DRUCKER, D. P. et al. Soluções tecnológicas para solucionar problemas em agricultura: o caso do desafio de inovação do congresso brasileiro de agroinformática. In: IN: CONFÊRENCIA ANPROTEC 2018: AGRO: NEGÓCIO, TECNOLOGIA E INOVAÇÃO. *Embrapa Informática Agropecuária - Artigo em anais de congresso (ALICE)*. [S.l.], 2018.
- [4] ALPAYDIN, E. *Introduction to Machine Learning*. 2nd. ed. [S.l.]: The MIT Press, 2010.
- [5] FEIJÃO, E. A. E. *Dados conjunturais da produção de feijão (Phaseolus vulgaris L.) e caupi (Vigna unguiculata L.) no Brasil (1985 a 2014): área, produção e rendimento*. [S.l.]: Santo Antonio de Goiás: Embrapa Arroz e Feijão, 2015.
- [6] MESQUITA, D. C. M. et al. Antagonismo in vitro de trichoderma spp. a sclerotinia sclerotiorum do feijão comum. *Embrapa Recursos Genéticos e Biotecnologia-Artigo em periódico indexado (ALICE)*, Agropecuária Científica no Semi-Árido, v. 13, n. 1, p. 1-4, 2017., 2017.
- [7] PATHARE, P. B.; OPARA, U. L.; AL-SAID, F. A.-J. Colour measurement and analysis in fresh and processed foods: a review. *Food and Bioprocess Technology*, Springer, v. 6, n. 1, p. 36–60, 2013.
- [8] GRANATO, D.; MASSON, M. L. Instrumental color and sensory acceptance of soy-based emulsions: a response surface approach. *Food Science and Technology (Campinas)*, SciELO Brasil, v. 30, n. 4, p. 1090–1096, 2010.
- [9] STEHLING, R. O.; NASCIMENTO, M. A.; FALCÃO, A. X. A compact and efficient image retrieval approach based on border/interior pixel classification. In: *ACM. Proceedings of the eleventh international conference on Information and knowledge management*. [S.l.], 2002. p. 102–109.
- [10] HARALICK, R. M.; SHANMUGAM, K. et al. Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, Ieee, n. 6, p. 610–621, 1973.
- [11] WITTEN, I. H.; FRANK, E. *Data mining: practical machine learning tools and techniques*. 2. ed. [S.l.]: Morgan Kaufmann, 2005. (Morgan Kaufmann Series in Data Management Systems). ISBN 0-12-088407-0.
- [12] LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature, Nature Research*, v. 521, n. 7553, p. 436–444, 2015.
- [13] COLETTA, L. et al. Combining classification and clustering for tweet sentiment analysis. In: *Intelligent Systems (BRACIS), 2014 Brazilian Conference on*. [S.l.: s.n.], 2014. p. 210–215.
- [14] BROWN, M. P. et al. Knowledge-based analysis of microarray gene expression data by using support vector machines. *Proceedings of the National Academy of Sciences*, National Acad Sciences, v. 97, n. 1, p. 262–267, 2000.
- [15] KUMAR, M.; RAGHUWANSHI, N.; SINGH, R. Artificial neural networks approach in evapotranspiration modeling: a review. *Irrigation science*, Springer, v. 29, n. 1, p. 11–25, 2011.
- [16] NETO, A. B. et al. Artificial neural network for classification and analysis of degraded soils. *IEEE Latin America Transactions*, v. 15, n. 3, p. 503–509, March 2017. ISSN 1548-0992.
- [17] BISHOP, C. M. *Pattern Recognition and Machine Learning - Information Science and Statistics*. 1. ed. [S.l.]: Springer, 2007. ISBN 0387310738.
- [18] HALL, M. A. *Correlation-based feature selection for machine learning*. University of Waikato Hamilton, 1999.
- [19] COLETTA, L. et al. Fuzzy clustering-based filter. In: *Information Processing and Management of Uncertainty in Knowledge-Based Systems. Theory and Methods*. [S.l.]: Springer Berlin/Heidelberg, 2010, (Communications in Computer and Information Science, v. 80). p. 406–415. ISBN 978-3-642-14055-6.