

Avaliação do desempenho de classificadores em imagens de Veículo Aéreo Não Tripulado (VANT)

Isabela Simões^{1,2}
Daniel Garbellini Duft¹
Cauã Guilherme Miranda^{1,3}
Carlos Henrique Wachholz de Souza²
Guilherme Martineli Sanches^{1,2}
Michelle Cristina Araujo Picoli¹

¹ Laboratório Nacional de Ciência e Tecnologia do Bioetanol - CTBE / Centro Nacional de Pesquisa em Energia e Materiais - CNPEM
Caixa Postal 6170 - 13083-970- Campinas - SP, Brasil
{daniel.duft, caua.miranda, guilherme.sanches michelle.picoli}@bioetanol.org.br

² Universidade Estadual de Campinas - Unicamp/FEAGRI
Caixa Postal 6011 - 13083-875 - Campinas - SP, Brasil
isabela.silva@feagri.unicamp.br
carlos_hws@hotmail.com

³ Universidade Estadual de Campinas - Unicamp/IG
Caixa Postal 6152 - 13083-970 - Campinas - SP, Brasil

Abstract. UAV imagery, in combination with remote sensing and image processing provides a new lower cost opportunity for monitoring and assessing sugar cane crops with a greater objectivity than other traditional surveys. This research employed a 16MP camera (ELPH 300 NDVI, Canon, USA) with 0,012 m resolution, and interference filters with blue and green channel, and provide images in the red and NIR region of the spectrum (670 and 770 nm), based on a UAV (swinglet CAM, SenseFly, Ecublens) and ENVI 5.1 software to identify cover classes in sugar cane croplands. Six supervised classification methods (Minimum distance (MND), Mahalanobis distance (MHD), Maximum likelihood classifier (MLC), Parallelepiped (PL), Spectral angle mapper (SAM) and K-means) were tested in this work. Accuracy indices obtained through confusion matrices were used to evaluate the classifiers performances. The results showed that the Minimum distance and the Mahalanobis distance methods presented the smallest errors for the four sugarcane cropland classes (sugar cane, bare soil, straw and others) with overall accuracy values of 84% and 80,8%, respectively, and kappa index values 0,73 and 0,66 respectively.

Palavras-chave: Unmanned Aerial Vehicle (UAV), image processing, classifiers, sugarcane, Veículo Aéreo Não Tripulado (VANT), processamento de imagens, classificadores, cana-de-açúcar.

1. Introdução

O imageamento com uso de veículos aéreos não tripulados (VANTs) é o campo de estudos que se desenvolve mais rapidamente dentro das tecnologias de sensoriamento remoto, oferecendo uma opção de baixo custo que permite mensurar e monitorar aspectos do meio ambiente com a possibilidade de aquisição das imagens sob condições ambientais adversas, como por exemplo, sob cobertura de nuvens, e também com resolução espacial e temporal desejadas (Honkavaara et al., 2013). Os sistemas de imageamento baseados em VANTs são bastantes competitivos em aplicações locais, quando são necessárias repetitivas coletas de imagens, como por exemplo para o monitoramento de lavouras, mostrando-se uma ferramenta útil para a agricultura de precisão.

Avanços recentes na tecnologia computacional, desenvolvimento de software, materiais mais leves, sistemas globais de navegação, sofisticados sensores e a miniaturização são alguns dos motivos do crescente desenvolvimentos de VANTs.

No processamento das imagens de sensoriamento remoto, a natureza dos alvos é determinada baseada no fato de que diferentes materiais são caracterizados por interagir de diferentes formas em cada uma das faixas do espectro eletromagnético (Jensen, 2009). Por sua vez, a classificação automática de imagens multiespectrais de sensoriamento remoto diz respeito a associar cada pixel da imagem a um rótulo, descrevendo um objeto real (vegetação, solo etc) (Crósta, 1992). Dessa forma, os valores numéricos associados à cada pixel, definidos pela refletância dos materiais que compõem esse pixel, são identificados em termos de um tipo de cobertura de superfície terrestre imageada (água, tipo de vegetação, de solo, de rocha etc.), chamadas então de temas (Crósta, 1992). Os métodos de classificação podem ainda ser divididos em supervisionados e não-supervisionado. A classificação não-supervisionada não requer nenhum conhecimento prévio do classificador sobre os atributos das classes existentes na cena, enquanto que a supervisionada requer amostras para treinamento feitas anteriormente com as classes de interesse contidas na imagem.

A classificação correta das áreas com cana-de-açúcar nas imagens geradas por VANTs é de grande utilidade para o controle e avaliação de muitas variáveis ao longo de seu processo produtivo, como avaliação do plantio, planejamento do manejo, previsão de safra e outros.

Desta forma, o objetivo deste estudo foi avaliar e comparar o desempenho de seis classificadores: Distância mínima (MND), Máxima verossimilhança (MLC), Distância de Mahalanobis (MHD), Mapeador de ângulo espectral (SAM) e Paralelepípedo (PL), para a determinação das classes cana-de-açúcar, palha, solo e outros elementos em imagens de VANT, criando uma metodologia para o uso cotidiano.

2. Metodologia

2.1 Área de estudo

A imagem coletada pertence a uma área comercial de 50 hectares no município de Serra Azul, SP, pertencente à Usina da Pedra (Figura 1). O clima dessa área está entre o tropical e subtropical, com uma média anual de precipitação de 1560 mm e temperatura média de 22,9 °C. O solo é do tipo Latossolo Vermelho-amarelo (Soil Survey Staf, 2010). A cana-de-açúcar tem sido cultivada no local por 30 anos.

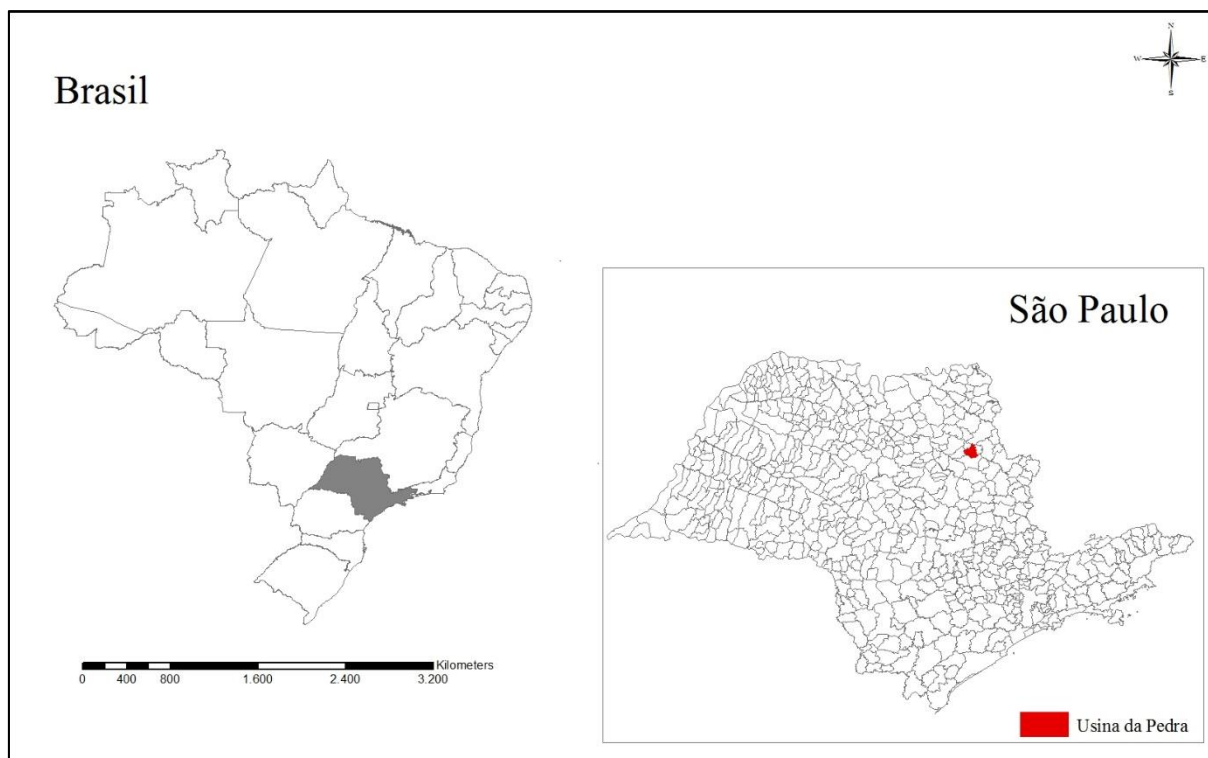


Figura 1. Localização da área de estudo.

2.2 Dados

A imagem utilizada no presente estudo foi obtida no dia 24 de outubro de 2013, por meio de um VANT (swinglet CAM, SenseFly, Ecublens), utilizando uma câmera de 16MP (ELPH 300 NDVI, Canon, USA) com 0,012 m de resolução espacial, e filtros interferentes com canais azul e verde, captando imagens nas regiões do vermelho e do infravermelho próximo do espectro (670 e 770 nm), porém esta imagem foi obtida com o infravermelho próximo no lugar do vermelho. Nesta data da passagem do VANT a cana-de-açúcar estava com oitenta e quatro dias após o corte (84 DAC).

2.3 Metodologia

Os métodos supervisionados avaliados neste trabalho foram:

1. Método da distância mínima: apropriado para quando o número de amostras para treinamento for pequeno por ser um método de classificação mais simples. (Richards, 1993). Neste, os modelos de classes são caracterizados pela simetria espectral e cada pixel desconhecido é atribuído à classe cuja média seja mais próxima a ele;
2. Método da máxima verossimilhança: mais utilizado no tratamento de dados adquiridos por satélite, o resultado desse método é melhor quanto maior o número de pixels numa amostra de treinamento para implementá-los na matriz de covariância (ENVI, 2010). O método de Maxver deve ser aplicado quando o analista conhece bem a imagem a ser classificada, para que possa definir classes que sejam representativas (Crósta, 1992);
3. Mapeador de ângulo espectral: utiliza o ângulo entre as amostras de treinamento no espaço de n-dimensões para determinar os pixels para uma determinada classe. Ele determina a similaridade espectral entre dois

- espectros e calcula o ângulo entre eles, sendo que os ângulos menores representam relações mais próximas ao espectro de referência (ENVI, 2010);
4. Método do paralelepípedo: considera uma área em forma de retângulo no espaço de atributos ao redor do conjunto de treinamento, definindo os níveis de cinza máximo e mínimo do conjunto. Os lados desse retângulo chamam-se os limites de decisão da classe contida. A correlação normalmente existente entre bandas irá causar uma distribuição ao longo da reta de 45 graus no espaço de atributos e os limites de decisão vão sempre abranger alguns pixels não pertencentes à classe (Crósta, 1992);
 5. Método de classificação por distância de Mahalanobis: similar ao da distância mínima, porém supõe que a covariância das amostras é igual, portanto um classificador mais rápido que o da distância mínima. (ENVI, 2010)

O método não-supervisionado escolhido para avaliação neste estudo foi o algoritmo K-means pois este calcula inicialmente as classes em um processo iterativo usando a técnica de distância mínima, e esta é mais simples para conjuntos de treinamentos pequenos como visto anteriormente (ENVI, 2010).

Inicialmente, a imagem foi processada com o software ENVI 5.1. O primeiro passo do processamento foi a seleção manual de amostras da imagem para a criação de regiões de interesse (ROIs) que foram posteriormente utilizadas na classificação supervisionada. A seleção das amostras foi feita, a partir do reconhecimento visual do analista, para as classes: cana-de-açúcar, palha, solo exposto e outros elementos. Optou-se por não utilizar nenhum tratamento de restauração na imagem original.

Após a seleção das amostras, classificadores supervisionados e um não-supervisionado foram aplicados na imagem. Os classificadores selecionados baseados em métodos de distância foram: o método do paralelepípedo, da distância mínima e da distância de Mahalanobis e, os baseados em probabilidade e ângulo espectral foram: o método da máxima verossimilhança (Maxver) e o mapeador de ângulo espectral, o método não-supervisionado escolhido foi o K-means que apresentou melhores resultados em uma avaliação prévia para comparação deste com o método Isodata.

Para avaliar a acurácia dos classificadores utilizando-se matrizes de erros, foi adotado o método do painel de amostras. Este método é caracterizado pela amostragem randômica de pontos (pixels) em toda a imagem, com a finalidade de verificar a validade das classificações realizadas (Luiz et al., 2002). Quatrocentos pontos amostrais foram dispersos randomicamente na imagem (Figura 2) para serem utilizados na pós-classificação. Os pontos amostrais foram calculados de acordo com as Equações 1 e 2.

$$N_o = 1/E_o^2 \quad (\text{Equação 1})$$

$$N = (N \cdot N_o)/(N + N_o) \quad (\text{Equação 2})$$

Onde,

N = tamanho da população (número de pixels)

E_o = erro amostral tolerável (0,05)

N_o = primeira aproximação do tamanho da amostra

N = tamanho da amostra corrigido

Os quatrocentos pontos foram distribuídos entre as classes de acordo com a quantidade total de pixels da imagem atribuídos a cada classe. A acurácia da classificação em cada ponto amostral foi avaliada por inspeção visual, e foram alocados na matriz de

confusão (Tabela 1). As matrizes de confusão foram usadas para calcular os índices descritos a seguir.

Tabela 1: Matriz de confusão

	Mapa referência	
Mapa temático	$a = \sum_{i=1}^K n_{ii}$	$b = \sum_{i=1}^k \sum_{j \neq i}^k n_{ij}$
Mapa	$c = \sum_{j=1}^k \sum_{i \neq j}^k n_{ij}$	$d = \sum_{j=1}^k \sum_{i \neq j}^k \sum_{j \neq i}^k n_{ij}$

Onde: a = quantidade de pixels classificados corretamente, b = quantidade de pixels classificados incorretamente pelo mapa gerado como pertencendo a classes do mapa verdadeiro, c = quantidade de pixels pertencentes a classes do mapa referência que pertencem a classes diferentes no mapa gerado, d = quantidade de pixels no mapa de gerado corretamente classificados como não pertencentes a classes do mapa referência.

A acurácia geral (Equação 3) apresenta a relação entre o número total de acertos e o número de total de amostras na imagem classificada.

$$\text{Exatidão global (\%)} = \frac{\sum X_{ii}}{N} \tag{Equação 3}$$

N = Número de observações (pontos amostrais)

X_{ii} = Observações na linha i e coluna i

A Equação 4 calcula o coeficiente Kappa (Cohen, 1960).

$$K = \frac{N \sum X_{ii} - \sum (x_{i+} \times x_{+i})}{N^2 - \sum (x_{i+} \times x_{+i})} \tag{Equação 4}$$

K = Coeficiente Kappa de concordância

N = Número de observações (pontos amostrais)

x_{ii} = Observações na linha i e coluna i

x_{i+} = Total marginal da linha i

x_{+i} = Total marginal da coluna i




Figura 2. Imagem coletada no espectro visível e infravermelho próximo e exemplo dos pontos amostrais distribuídos randomicamente para serem utilizados na avaliação dos classificadores.

3. Resultados e Discussão

Foi observado que dos seis classificadores avaliados, o método da Distância mínima e o da distância de Mahalanobis demonstraram as melhores performances, com uma exatidão global de 84% e 80,8% respectivamente, e índice Kappa de 0,73 e 0,66 respectivamente.

O bom resultado do método da distância mínima deve-se ao fato de que foram trabalhadas quatro classes de interesse na imagem que tiveram melhor adequação ao algoritmo do método. As classes da imagem utilizada não possuem formatos bem definidos mas apresentam boa semelhança espectral, o que facilitou este tipo de classificação.

O método do Paralelepípedo apresentou o pior resultado (Figura 3), o que era esperado, visto que ele é mais adequado para imagens que possuem classes com formatos bem definidos, diferente da imagem utilizada, obtida por VANT, da lavoura de cana-de-açúcar, que possui pouca definição dos limites das classes. Um dos problemas relatados por Crósta (1992) é que numa imagem que contenha milhares de pixels provavelmente a maioria caíra fora dos limites de decisão das classes, por mais classes que se defina. Isto ocorre por causa do volume do espaço de atributos que não pertence a nenhuma das classes ser grande.

A Figura 3 ilustra os mapas temáticos obtidos pelo método da Distância Mínima (o melhor método observado) e pelo método do Paralelepípedo (o pior método observado).




Figura 3. Resultado da classificação pelo método da Distância Mínima (esquerda) e pelo método do Paralelepípedo (direita).

A Tabela 3 apresenta os valores da exatidão global e do índice Kappa dos seis métodos de classificação.

Tabela 3: Valores da exatidão global e índice Kappa.

Classificadores	Exatidão Global (%)	Índice Kappa
MND	84,0	0,73
MHD	80,8	0,66
MLC	75,6	0,58
SAM	77,2	0,58
K-means	37,3	0,16
PL	23,8	0,02

MND: Distância mínima, MLC: Máxima verossimilhança, MHD: Distância de Mahalanobis, SAM: Mapeador de ângulo espectral, PL: Paralelepípedo

4. Conclusões

Para a classificação de imagens de lavouras de cana-de-açúcar obtidas com VANT, sugere-se o uso do método da Distância Mínima disponível no software ENVI 5.1, com seleção de regiões de interesse (ROIs) que representem as classes estudadas. As amostras devem ser coletadas de maneira mais representativa possível, contendo os mais variados níveis de refletância de uma mesma classe, existentes na imagem.

Referências bibliográficas

Crósta, A. P. **Processamento Digital de Imagens de Sensoriamento Remoto**. Campinas: Unicamp, 1992. 170p.

ENVI. **Guia do ENVI em Português**. Classificação, Guia F.

Honkavaara, E.; Saari H.; Kaivosoja, J.; Polonen, I; Hakala T.; Litkey, P; Makynen J.; Pesonen L. Processing and assessment of Spectrometric, Stereoscopic Imagery Collected Using a Lightweight UAV Spectral Camera for Precision Agriculture. **Remote Sensing**, 5:5006-5039, 2013.

Jensen, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: Parêntese, 2009. 4-29 p.

Cohen, J.A. Coefficient of agreement for nominal scales. **Educational and Psychological Measurement**, 20:37-46, 1960.

Luiz, A.J.B.; Oliveira, J.C.; Epiphanyo, J.C.N.; Formaggio, A.R. Auxílio das imagens de satélite aos levantamentos por amostragem em agricultura. **Agricultura em São Paulo**, 49:41-54, 2002.

Richards, J.A. **Remote Sensing Digital image analysis – an introduction**. 2nd ed. Springer-Verlag, Berlin, 1993.

Soil Survey Staff. **Keys to Soil Taxonomy**. 12th ed. USDA-Natural Resources Conservation Service, Washington, DC., 2010. 338 p.