



# USO DE ÍNDICES DE VEGETAÇÃO EM IMAGENS HIPERESPECTRAIS ADQUIRIDAS COM USO DE VARP PARA CLASSIFICAÇÃO DE ESPÉCIES DE MATA ATLÂNTICA DE INTERIOR

*G. T. Miyoshi<sup>1</sup>, G. G. Pessoa<sup>1</sup>, A. C. Carrilho<sup>1</sup>, N. N. Imai<sup>1,2</sup>*

Universidade Estadual Paulista (UNESP), Brasil  
Faculdade de Ciências e Tecnologia – FCT

<sup>1</sup> Programa de Pós-Graduação em Ciências Cartográficas – PPGCC

<sup>2</sup> Departamento de Cartografia

**Comissão IV - Sensoriamento Remoto, Fotogrametria e Interpretação de Imagens**

## RESUMO

Sensores hiperspectrais acoplados a veículos aéreos remotamente pilotados (VARP) vem ganhando destaque nas últimas décadas. Dentre suas aplicações, destacam-se aquelas voltadas para o mapeamento florestal. No entanto, um dos desafios ao utilizar imagens de Sensoriamento Remoto para tal finalidade, consiste na similaridade espectral entre espécies de vegetação. Considerando que índices de vegetação podem realçar diferenças espectrais, este trabalho tem o objetivo de verificar a similaridade espectral entre espécies arbóreas e utilizar índices de vegetação para auxiliar a discriminação de espécies. Desta forma, a partir de imagens hiperspectrais obtidas por meio de câmara acoplada em VARP, foi verificada a similaridade entre quatro espécies de árvores utilizando a análise de agrupamento. Posteriormente foram realizadas duas classificações, a primeira utilizando todas as bandas espectrais adquiridas e a segunda utilizando os índices de vegetação NDVI, REP, PRI e PSRI. Os resultados indicam que, embora o índice kappa resultante não seja considerado como excelente, o uso dos índices melhorou a classificação inicial.

**Palavras-chave:** VARP, Análise de Agrupamento, Índices de Vegetação.

## ABSTRACT

The use of hyperspectral sensors attached to remotely piloted aircrafts (RPA) have been gaining prominence in the recent years. Among its applications, the one used to forest monitoring is highlighted. However, one of the challenges in use images acquired by Remote Sensing for this objective is the spectral similarity between the vegetation species. Considering that vegetation indexes can enhance spectral differences, this work has the objective of verify the spectral similarity between tree species and the use of vegetation indexes to improve the tree species discrimination. In this sense, hyperspectral images acquired with camera attached to RPA, were used to verify the spectral similarity between four tree species using clustering analysis. Then, two classifications were performed, the first one using all the spectral bands acquired and the second one, using the NDVI, REP, PRI and PSRI vegetation indexes. The results show that, even with a not excellent kappa coefficient, the use of vegetation indexes increased the accuracy of the classification.

**Keywords:** RPA, Clustering Analysis, Vegetation Indexes.

### 1- INTRODUÇÃO

O uso de sensores hiperspectrais fornece informação detalhada acerca de alvos da superfície terrestre e, quando utilizados em Veículos Aéreos Remotamente Pilotados (VARP), podem fornecer dados com resolução espacial centimétrica. Dentre as aplicações de tais sensores acoplados em VARP, é

possível citar aquelas voltadas para o mapeamento florestal (Näsi et al., 2016; Nevalainen et al., 2017).

Um dos desafios de realizar análise de florestas utilizando imagens de Sensoriamento Remoto consiste na variabilidade espectral pois, em um dossel, a resposta espectral é influenciada pela mistura de folhas dos indivíduos arbóreos, de mesma espécie e de diferentes espécies, pela presença de sub-bosque, entre

outros fatores (Ferreira et al., 2016). Sendo assim, o mapeamento de espécies arbóreas, tanto em florestas tropicais quanto em florestas coníferas, com o uso de sensores hiperespectrais, torna-se um assunto interessante para a comunidade científica (Fassnacht et al., 2016; Zhang et al., 2017).

Desta forma, o objetivo deste trabalho é verificar a similaridade espectral de espécies de Mata Atlântica de Interior e aplicar o uso de índices de vegetação para auxiliar a discriminação entre espécies.

## 2- ÁREA DE ESTUDO

A área de estudo é um transecto de dimensão aproximada 400 m por 50 m, localizado no oeste do Estado de São Paulo, próximo ao município de Euclides da Cunha Paulista. É uma área de floresta estacional semidecidual, também conhecida como Mata Atlântica de Interior. A área (Figura 1) está localizada dentro da gleba Ponte Branca, área de reserva florestal pertencente à Estação Ecológica Mico Leão Preto.

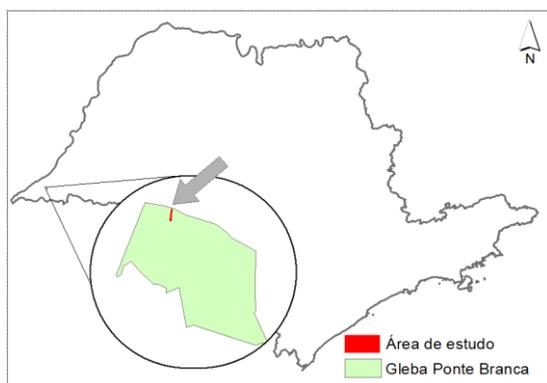


Fig. 1 – Área de estudo

## 3- AQUISIÇÃO E PROCESSAMENTO DAS IMAGENS

Para o desenvolvimento do trabalho foram adquiridas imagens com o modelo de 2014 da câmara hiperespectral baseada no Interferômetro de Fabry-Perot (FPI) (Figura 2). Tal câmara é desenvolvida e comercializada pela Senop Ltd. (<http://senop.fi/>) e se diferencia da maioria dos sensores hiperespectrais por apresentar sensor de quadro ao invés de sensor linear. Possuindo dois sensores, a câmara FPI permite registrar até duas bandas espectrais de forma simultânea no intervalo compreendido entre 500 nm e 900 nm. Adicionalmente, a aquisição das bandas é realizada de forma sequencial, sendo que o comprimento de onda registrado é dependente do espaçamento do FPI. A bandas espectrais adquiridas com respectivos valores de *full width at half maximum* (FWHM) são apresentadas na Tabela 1.

TABELA 1 – CONFIGURAÇÃO ESPECTRAL DA CÂMARA FPI

$\lambda$ (nm)	FWHM (nm)	$\lambda$ (nm)	FWHM (nm)	$\lambda$ (nm)	FWHM (nm)
506.07	15.65	629.23	12.84	719.99	20.76
520.00	17.51	650.28	15.85	729.56	21.44
535.45	16.41	660.27	24.11	740.45	20.64
550.16	15.18	669.96	21.70	749.65	19.43
564.71	16.60	680.06	21.00	770.46	19.39
580.08	15.14	689.56	21.67	780.16	18.25
592.78	14.81	699.62	21.89	790.21	18.50
609.79	13.77	709.71	20.78	819.74	18.17
619.55	14.59	$\lambda$ = comprimento de onda central da banda			

A câmara foi acoplada em plataforma VARP, modelo SX8 (Figura 2), desenvolvida pela Sensormap (<http://www.sensormap.com.br/>). Esse VARP possui carga útil de no máximo 5 kg, apresentando autonomia de 30 min dependendo das condições climáticas, do estado das baterias e da quantidade de equipamentos acoplados. Além da câmara integrou-se ao equipamento um receptor de sistema de posicionamento global por satélites (GNSS) e uma unidade de medida inercial (IMU), que juntos compõem o sistema de navegação inercial (INS).



Fig. 2 – Câmara FPI acoplada ao VARP SX8

As imagens foram adquiridas em agosto de 2015 utilizando o VARP SX8 a uma altura de voo de 160 m, gerando imagens com *ground sample distance* (GSD) médio de aproximadamente 10 cm. Em seguida, fez-se a correção da corrente escura e correção radiométrica das imagens utilizando uma imagem escura adquirida antes do voo e arquivo de calibração fornecido pelo fabricante, respectivamente. Para tal, foi utilizado o *software* Hyperspectral Imager v1.1.

Para a reconstrução da geometria da câmara, realizou-se a calibração geométrica do conjunto de lentes utilizando o método *on-job* no *software* Agisoft Photoscan. O mesmo *software* foi utilizado para o refinamento dos parâmetros de orientação exterior (POE) das imagens, por meio da triangulação (*Bundle Block Adjustment*). Os POE iniciais foram obtidos a partir dos dados do INS, que foram processados no *software* Inertial Explorer. Ressalta-se que as bandas centradas em 564.71 nm, 680.06 nm e 770.46 nm foram as utilizadas no processo de triangulação pois se

localizavam em posições intermediárias dos dois sensores.

Em seguida gerou-se um modelo digital de superfície (MDS) utilizando correspondência das imagens da área de estudo, de modo a permitir a ortoretificação das imagens e elaboração do mosaico de imagens hiperespectrais. Considerando que a aquisição de imagens está sujeita à variações de iluminação devido ao desocamento do VARP e às mudanças na geometria de iluminação e aquisição, fez-se a correção da função de distribuição da reflectância bidirecional (BRDF) e ajustamento radiométrico utilizando o método proposto por Honkavaara et al. (2013).

O método de Honkavaara et al. (2013) consiste em um ajustamento radiométrico em bloco nas imagens hiperespectrais utilizando *tie points* radiométricos e correção da BRDF. Honkavaara et al. (2013), Hakala et al. (2013) e Näsi et al. (2016) apresentam detalhes sobre o ajustamento radiométrico.

#### 4- EXPERIMENTOS E RESULTADOS

Dando continuidade ao trabalho, foi necessária a realização de trabalho de campo para identificação das mais de 20 espécies presentes na área (Berveglieri et al., 2016). Porém, apenas quatro foram consideradas neste trabalho, visto que possuíam o maior número de amostras, por espécie, identificadas em campo. As espécies utilizadas foram: *Platypodium elegans* (Pe), *Copaifera langsdorffii* (Cl), *Apuleia leiocarpa* (Al) e *Hymenaea courbaril* (Hc).

Com base nos dados coletados em campo, os indivíduos de cada espécie foram identificados e manualmente delineados no mosaico de imagens hiperespectrais. A Tabela 2 mostra a quantidade de polígonos identificados para cada espécie e a quantidade média de pixels por copa.

TABELA 2 – QUANTIDADE DE ÁRVORES IDENTIFICADAS EM CAMPO E UTILIZADAS COMO AMOSTRA DE TREINAMENTO

Espécie	Qtd. de árvores indentificadas	Média de pixels por copa	Qtd. de árvores utilizadas para treinamento
Pe	3	3.770	1
Al	7	3.849	2
Cl	15	3.059	5
Hc	6	6.456	1

Posteriormente, calculou-se o espectro de referência de cada espécie a partir da média da resposta espectral de cada. Tais espectros foram utilizados para verificação da similaridade entre respostas espectrais das espécies. Desta forma, foi realizada uma análise de agrupamento utilizando a correlação como medida de distância. O *software* Minitab foi utilizado para tal

análise sendo que a Figura 3 apresenta o dendrograma resultante, onde pode-se observar similaridade maior que 99% entre todas as espécies.

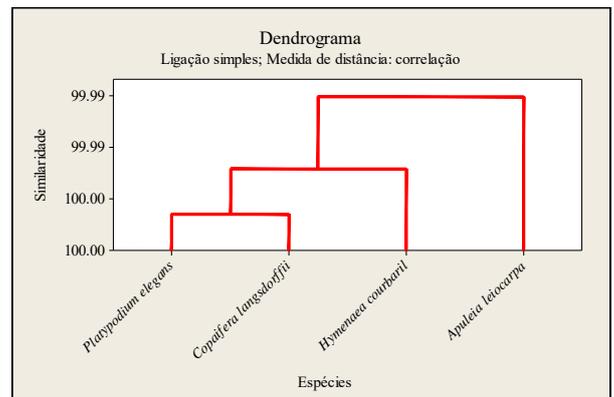


Fig. 3 – Dendrograma da análise de agrupamento considerando as 25 bandas espectrais

Quatro índices de vegetação foram calculados para atenuar a correlação entre as respostas espectrais das espécies e melhorar a distinção entre as espécies. Os índices utilizados foram: i) o Índice de Vegetação por Diferença Normalizada (NDVI) (Rouse et al., 1974); ii) o Índice de Reflectância Fotoquímica (PRI) (Sims e Gamon, 2002); iii) o Índice de Reflectância da Senescência de Plantas (PSRI) (Merzlyak et al., 1999); e, iv) a Posição da Borda do Vermelho (REP) (Clevers, 1994).

Por utilizar diferentes grandezas, os índices foram padronizados pela média e desvio padrão. Em seguida, foi aplicada nova análise de agrupamento resultando em valores de similaridade menores, como é possível observar na Figura 4.

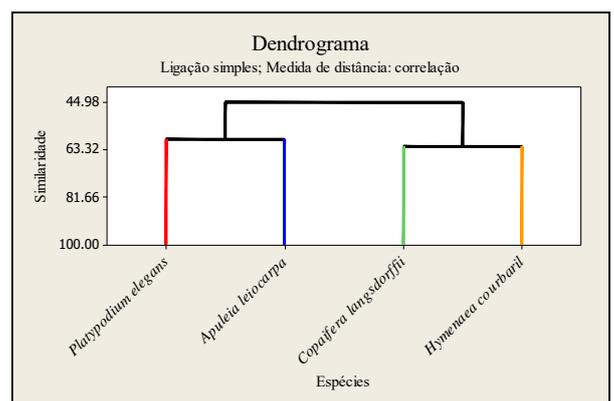


Fig. 4 – Dendrograma da análise de agrupamento considerando os índices de vegetação

A fim de verificar o uso dos índices de vegetação para aumentar a acurácia da identificação de espécies arbóreas, foram realizadas duas classificações de imagens. A primeira considerou todas as bandas espectrais e a segunda considerou apenas a junção de camadas (*layer stacking*) dos índices de vegetação padronizados.

O classificador utilizado foi o *Spectral Information Divergence* (SID) proposto por Chang (1999). Tal classificador utiliza a entropia para cálculo de probabilidade de distinção das classes. Como amostras de treinamento foram escolhidos parte dos polígonos delimitados nas imagens. Ressalta-se que os polígonos restantes foram utilizados para avaliação da classificação e cálculo da matriz de confusão e índice kappa (Cohen, 1960; Landis e Koch, 1977). A Tabela 2 apresenta a quantidade de polígonos utilizados para treinamento e validação e a Tabela 3 apresenta a matriz de confusão de cada classificação.

Ao analisar os resultados da Tabela 3 para a classificação do mosaico com 25 bandas espectrais, nota-se confusão entre todas as classes. O índice kappa de tal classificação obteve um valor de -0,64%, valor mostrando que não há concordância entre as áreas de referência e as áreas classificadas. Tal resultado pode ser justificado pela alta similaridade entre as respostas espectrais. Ainda tem-se que em florestas, as folhas de diferentes indivíduos arbóreos podem se misturar, além da influência da resposta espectral do sub-bosque. Outro fator a ser citado é o uso de classificador baseado em pixel, que pode produzir resultados ruidosos (Zhang et al., 2017).

TABELA 3 – MATRIZ DE CONFUSÃO DAS CLASSIFICAÇÕES

Imagem - 25 bandas espectrais						
		Classe de referência (%)				Soma (%)
		Pe	Cl	Al	Hc	
Classe mapeada (%)	Nc	0,00	0,98	0,04	3,54	1,64
	Pe	19,73	19,45	8,91	14,96	15,51
	Cl	36,21	42,25	46,99	50,40	45,73
	Al	9,47	9,15	18,72	9,04	11,23
	Hc	34,59	28,17	25,33	22,05	25,90
Soma (%)		100	100	100	100	100
Índices de vegetação - NDVI, REP, PSRI e PRI						
		Classe de referência (%)				Soma (%)
		Pe	Cl	Al	Hc	
Classe mapeada (%)	Nc	0,60	2,84	1,76	4,60	3,04
	Pe	10,03	10,08	9,15	10,23	9,93
	Cl	20,90	11,51	27,3	12,71	16,33
	Al	12,23	13,93	20,35	13,32	14,93
	Hc	56,25	61,65	41,44	59,14	55,77
Soma (%)		100	100	100	100	100

Em relação à classificação utilizando os índices de vegetação nota-se que ainda há confusão entre as classes. No entanto, tal classificação produziu índice kappa no valor de 1,37%, mostrando melhorias na acurácia da classificação. Tal melhoria é justificada

devido ao fato dos índices de vegetação ressaltarem diferenças que ocorrem principalmente na região do visível, borda do vermelho e infravermelho. Embora o valor de kappa ainda seja considerado como um nível de concordância mínimo em relação à verdade de campo, nota-se a melhoria na classificação. Além disso, ainda é ressaltado o uso da classificação pixel-a-pixel, que também pode ter afetado a acurácia da classificação.

#### 4- CONCLUSÕES

Neste estudo foi constatada a similaridade entre respostas espectrais de espécies de vegetação de Mata Atlântica de Interior. Adicionalmente verificou-se que embora os valores do índice kappa não tenham sido considerados como excelentes, os índices de vegetação melhoraram a classificação. Por fim, tem-se que o uso de segmentadores para aplicar a análise entre conjuntos de pixel podem auxiliar o aumento da distinção entre classes. O uso de diferentes índices de vegetação também podem contribuir para o aumento do grau de diferença entre classes.

#### AGRADECIMENTOS

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP - processo 2013/50426-4) e à *Academy of Finland* (AKA - processo 273806). Ainda, agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) (processo 153854/2016-2) pela bolsa de fomento.

#### REFERÊNCIAS BIBLIOGRÁFICAS

- Berveglieri, A. et al., 2016. Identification of Successional Stages and Cover Changes of Tropical Forest Based on Digital Surface Model Analysis. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(12), pp. 5385-5397.
- Chang, C. I., 1999. Spectral information divergence for hyperspectral image analysis. *In Geoscience and Remote Sensing Symposium, IGARSS'99 Proceedings*. IEEE International, Vol. 1, pp. 509-511.
- Clevers, J. G. P. W., 1994. Imaging spectrometry in agriculture-plant vitality and yield indicators. *Imaging spectrometry - A tool for environmental observations*. Springer, pp. 193-219.
- Cohen, J., 1960. A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, Vol. XX, N° 1, pp. 37-46.

Fassnacht, F. E. et al., 2016. Review of studies on tree species classification from remotely sensed data. Remote Sensing of Environment, Vol. 186, p. 64-87.

Ferreira, M. P. et al., 2016. Mapping tree species in tropical seasonal semi-deciduous forests with hyperspectral and multispectral data. Remote Sensing of Environment, 179, pp. 66-78.

Honkavaara, E. et al., 2013. Processing and Assessment of Spectrometric, Stereoscopic Imagery Collected Using a Lightweight UAV Spectral Camera for Precision Agriculture. Remote Sensing, Vol. 5, p. 5006-5039.

Landis, J. R. e G. G. Koch, 1977. The Measurement of Observer Agreement for Categorical Data. Biometrics, Vol. 33, N° 1, pp. 159-174.

Merzlyak, M. N. et al., 1999. Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening. Physiologia plantarum, Vol. 106, n. 1, p. 135-141.

Näsi, R. et al., 2016. UAS based tree species identification using the novel FPI based hyperspectral cameras in visible, NIR and SWIR spectral ranges, In : International Archives of the XXIII ISPRS Congress. Praga, Vol. XLI-B1 pp. 1143-1148.

Nevalainen, O. et al., 2017. Individual Tree Detection and Classification with UAV-Based Photogrammetric Point Clouds and Hyperspectral Imaging. Remote Sensing, 9(3), pp. 185.

Rouse, J. et al., 1974. Monitoring vegetation systems in the Great Plains with ERTS. NASA special publication, Vol. 351, p. 309.

Sims, D. A. e A. J. Gamon, 2002. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. Remote Sensing of Environment, Vol. 81, n. 2, p. 337-354.

Zhang, J. et al., 2017. Multiscale superpixel-based sparse representation for hyperspectral image classification. Remote Sensing, Vol. 9, n. 2, p. 139.