

Aplicação do Algoritmo SAM (*Spectral Angle Mapper*) Via Linguagem Espacial de Geoprocessamento Algébrico (LEGAL) do Spring.

Sidney Geraldo Silveira Velloso¹
José Marinaldo Gleriani¹
Vicente Paulo Soares¹
Júlio César de Oliveira²
Carlos Antonio Alvares Soares Ribeiro¹

¹ Universidade Federal de Viçosa - UFV
Depto. Eng. Florestal
36570-000 - Viçosa - MG, Brasil

² Universidade Federal de Viçosa - UFV
Depto. Eng. Agrimensura e Cartográfica
36570-000 - Viçosa - MG, Brasil
{sidney.velloso, gleriani, vicente,oliveirajc,cribeiro} @ufv.br

Abstract. In this study the spectral classification of Rapideye sensor data using the SAM (*Spectral Angle Mapper*) algorithm implemented in commercial packages was compared to the programmed algorithm via Algebraic Geoprocessing Spatial Language implemented in Spring software. Results showed that the Land Use/Land Cover classification in seven thematic classes reached a 99.81% match rating between the algorithms through cross tabulation. Although the results were well-accurate, execution via LEGAL is 17 times more time consuming than commercial packages.

Key words: feature space, Spectral Classification, RapidEye, espaço de atributos, classificação espectral, RapidEye

1. Introdução

Os classificadores espectrais supervisionados, pixel a pixel, são bem descritos na literatura (Lillesand e Kiefer, 1994; Richards e Jia, 1999; Jensen, 2000; Schowengerdt, 2007), com as respectivas funções matemáticas e os limites de decisões ilustrados no espaço de atributos.

O classificador de paralelepípedo, por exemplo, embora quase nunca utilizado e implementado em pacotes livres ou comerciais, é sempre descrito porque que é de fácil compreensão e didático. Outros algoritmos, como o de Máxima Verossimilhança, chega a ser citado como o classificador de uso mais comum para os dados de sensoriamento remoto (Richards e Jia, 1999).

A maioria dos classificadores espectrais delimitam, segundo determinada função, limites rígidos e booleanos (paralelepípedo), condicionais (distância mínima) ou probabilísticos (MaxVer) no espaço de atributos. O classificador SAM ("*Spectral Angle Mapper*") rotula pixels pela similaridade angular entre o vetor padrão para uma determinada classe e o vetor de um pixel candidato (Yuhás et al., 1992; Kruse et al., 1993, Shafri et al., 2007; Petropoulos et al., 2010). Quanto menor o ângulo, maior a similaridade espectral, enquanto que maior o ângulo, mais distintas são as classes (Figura 1).

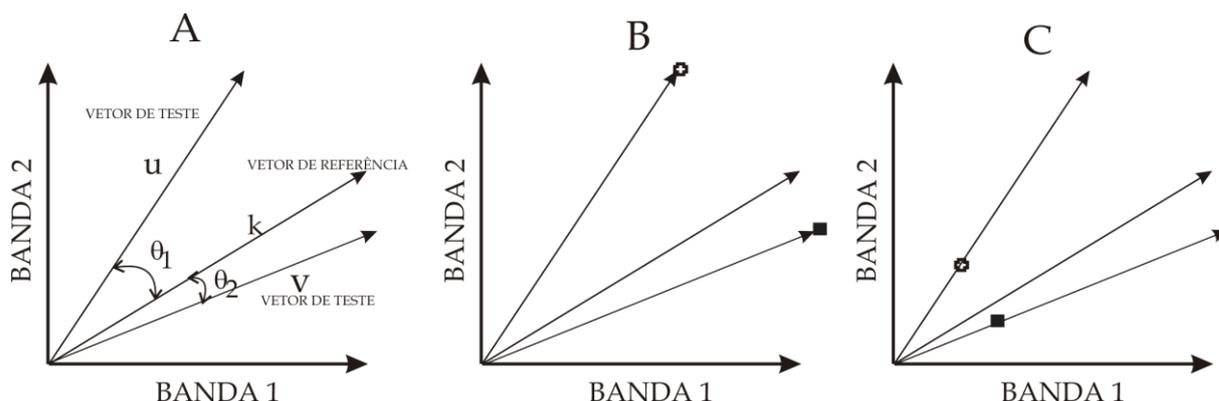


Figura 1 – Espaço de atributos ilustrando os ângulos (θ_1 e θ_2) formados entre os vetores de teste u (DN_1, DN_2) e v (DN_3, DN_4) de dois pixels pertencentes a duas classes distintas e o vetor de referência k . A dispersão hipotética e desejável para os pixels, nas condições de iluminação (B) e sombreamento (C) manteria o ângulo entre as classes.

Uma das vantagens do classificador, segundo Yuhas et al. (1992) é que para uma dada classe, em terreno acidentado, os pixels iluminados e sombreados seriam classificados, desde que os valores digitais (DN) iluminados/sombreados estivessem ao longo do vetor, mantendo a inclinação. Embora não fosse o fator sombreamento e sim a diferença de umidade e variações de tipos de solo, Huete (1988) mostra que os valores digitais dos pixels para cenas claras/escuras/secas/úmidas migram para um intercepto em eixo y (no espaço de atributos y -infravermelho vs x -vermelho) e não para a origem. Para dosséis com maior porcentagem de cobertura os valores tendem a migrar para a origem do sistema cartesiano.

A principal desvantagem do classificador SAM, segundo Girouard et al. (2004), é que os “endmembers” escolhidos para gerar o vetor representativo de cada classe, devem ser puros. No entanto, as resoluções dos sensores como os da família TM/ETM+/OLI do programa Landsat podem conter pixels impuros, o que levaria a sobre-estimação ou superestimação do valor espectral de uma dada classe.

1.1 Conceito teórico

De acordo com Reis e Silva (1983), o produto escalar entre dois vetores $u=(x_1, y_1)$ e $v=(x_2, y_2)$ é dado pela equação (1):

$$u \cdot v = x_1 x_2 + y_1 y_2 \quad (1)$$

Já o módulo de um vetor $u=(x_1, y_1)$ é dado por (2):

$$\|u\| = \sqrt{x_1^2 + x_2^2} \quad (2)$$

E o ângulo α , em radianos, entre os vetores u e v é dados por (3):

$$\theta = \arccos\left(\frac{u \cdot v}{\|u\| \|v\|}\right) \quad (3)$$

A Linguagem Espacial de Geoprocessamento Algébrico (LEGAL) embora presente na interface de programação somente as funções trigonométricas diretas, também possui

implementado as funções trigonométricas inversas, necessárias para implementação do algoritmo SAM o qual foi confrontado com o classificador SAM implementado no pacote ENVI.

2. Metodologia de Trabalho

Para realização do presente trabalho realizou-se a mosaicagem de quatro cenas do sensor RapidEye de 23 de fevereiro de 2010 as quais contemplavam toda a área do município de Viçosa (MG) (Figura 2) . O programa RapidEye é composto de uma constelação de cinco satélites os quais coletam imagens em cinco canais espectrais (440-510nm, 520-590nm, 630-685nm, 690-730nm e 760-850nm), com cinco metros de resolução espacial. Embora os sensores produzam imagens de 12 bits, elas são re-escaladas para 16 bits (Stoll et al., 2012).

No mosaico (UTM/WGS-84) foram definidos polígonos sobre sete classes de uso e cobertura da Terra – mata (M), pastagem (P), urbano (U), água (A), brejo (B), cultivado (C) - incluindo nessa classe agricultura e eucaliptocultura e solo exposto (SE). Foram extraídas, no plano de informação (PI) Numérico, a média zonal para cada classe, nas cinco bandas espectrais, cujos polígonos seriam posteriormente exportados em formato TIFF para serem convertidos em *Region of Interest* (ROI) em ambiente ENVI.

Procedeu-se, no programa, a atribuição dos valores médios obtidos para cada classe:

$A1 = \text{valor média da classe água para a banda 1};$

$A2 = \text{valor média da classe água para a banda 2};$

....

$SE4 = \text{valor média da classe solo para a banda 4};$

$SE5 = \text{valor média da classe solo para a banda 5};$

Onde A é a classe água, SE é a classe solo exposto e os números de 1 a 5 descrevem as bandas espectrais.

Em seguida, criou-se a cinco matrizes derivadas do produto vetorial (u.v), as quais eram os resultados dos produtos do vetor médio de cada classe em cada uma das bandas espectrais pelas imagens, descrito na sintaxe:

$$UVA = \text{Numérico} (A1*b1 + A2*b2 + A3*b3 + A4*b4 + A5*b5);$$

Onde UVA é a variável a qual é atribuída a matriz numérica; e b1,...,b5 são os valores DN das bandas espectrais.

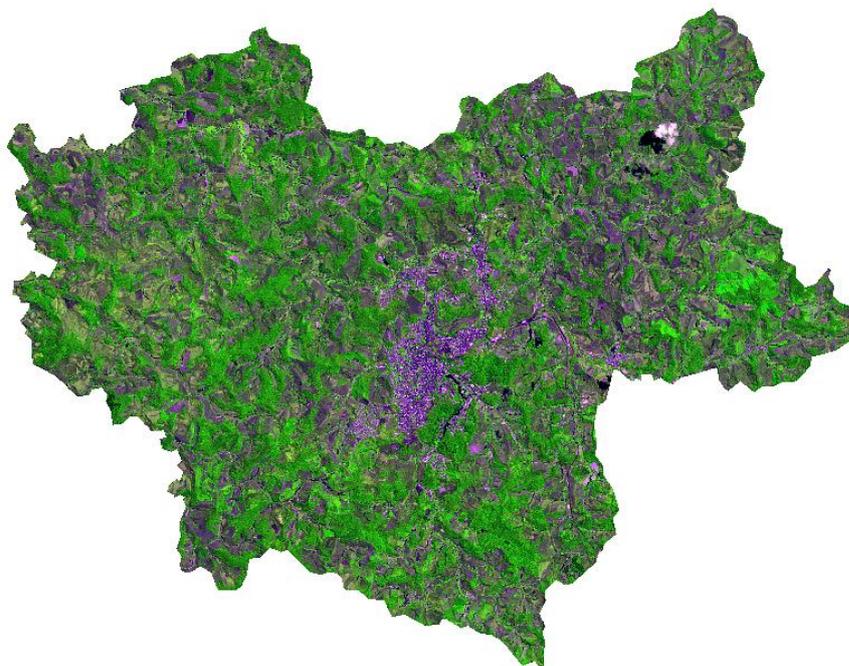


Figura 1 – Composição 4R5G3B das cenas mosaicas do sensor RapidEye para o município de Viçosa (MG).

Após o computo do produto vetorial, calculou-se o módulo de cada vetor (classe) descrito na seguinte sintaxe:

$$MODA = \text{sqrt}(A1^2 + A2^2 + A3^2 + A4^2 + A5^2);$$

Onde MODA é o módulo (vetor padrão) para a classe A, sqrt (função) raiz quadrada, e “^” a função potência.

Calculou-se também o módulo vetorial de cada pixel candidato. Módulo esse que será multiplicado pelo módulo de cada classe.

$$MODb = \text{sqrt}(\text{Numérico}(b1^2 + b2^2 + b3^2 + b4^2 + b5^2));$$

Em seguida computou-se, através da sintaxe *acos* as sete matrizes (teta1,...teta7) compostas dos ângulos cujos valores são os ângulos entre o vetor de cada pixel candidato e cada uma das sete classes.

$$teta1 = \text{acos} ((UVA / (MODA * MODb)));$$

$$teta7 = \text{acos} ((UVSE / (MODSE * MODb)));$$

Onde UVA e UVSE é o produto vetorial entre as classes A e SE. MODA e MODSE são os módulos para os vetores A e SE e, MODb, é o módulo de cada pixel candidato.

Na última etapa executou-se a operação condicional sequencial através do operador booleano “e” através da sintaxe &&, gerando uma matriz numérica a qual foi posteriormente fatiada, resultando em um PI Temático.

$$\text{mapNum} = ((\text{teta1} < \text{teta2}) \&\& (\text{teta1} < \text{teta3}) \&\& (\text{teta1} < \text{teta4}) \&\& (\text{teta1} < \text{teta5}) \&\& (\text{teta1} < \text{teta6}) \&\& (\text{teta1} < \text{teta7})) ? 1 :$$

$$\dots$$

$$((\text{teta6} < \text{teta1}) \&\& (\text{teta6} < \text{teta2}) \&\& (\text{teta6} < \text{teta3}) \&\& (\text{teta6} < \text{teta4}) \&\& (\text{teta6} < \text{teta5}) \&\& (\text{teta6} < \text{teta7})) ? 6 : 7;$$

A classificação gerada no pacote ENVI™ foi importada no Spring onde procedeu-se a operação de tabulação cruzada, para verificar a coincidência de classificação.

3. Resultados e Discussão

O procedimento descrito obviamente não é dos mais eficientes. O mesmo demandou, durante o processo de classificação, aproximadamente 14 minutos em uma CPU com processador Intel Core (TM) 2 Duo de 2,1 GHz e 4Gb RAM. O mesmo mosaico, com aproximadamente 25M pixels, demorou 48 segundos para ser classificado com o pacote comercial ENVI. O tempo é ainda maior uma vez que é necessário computar a média zonal para obter o “*endmember*” de cada classe além da operação de digitação dos valores médios de cada vetor (classe) no corpo do programa, assim como executar o fatiamento após a classificação.

O resultado da tabulação cruzada entre os dois procedimentos de classificação é descrito na Tabela 1

Tabela 1 – Tabulação cruzada entre o resultado da classificação com o algoritmo SAM do pacote comercial ENVI (referência) e a implementação do mesmo algoritmo via linguagem LEGAL do Spring.

SAM	SAM ENVI							C
	M	B	A	P	U	SE		
M	3184828	1958	0	92	0	0	31820	
B	4711	1636856	0	4615	0	0	3113	
A	0	0	26730	0	156	0	0	
P	0	0	0	5556927	0	24	0	
U	0	0	184	0	215954	8	0	
SE	0	0	33	2	2	13434355	0	
C	22	0	0	0	0	0	372522	

Onde: M-mata, B-brejo, A-água, P-pastagem, U-urbano, SE-solo exposto e C-cultivado

A tabulação cruzada mostrou que houve 99,81% de concordância entre as classificações, embora seja difícil identificar as causas das variações observadas, como arredondamentos internos ou outras particularidades computacionais. Visualmente, o resultado foi bem semelhante, como pode ser observado na Figura 2.

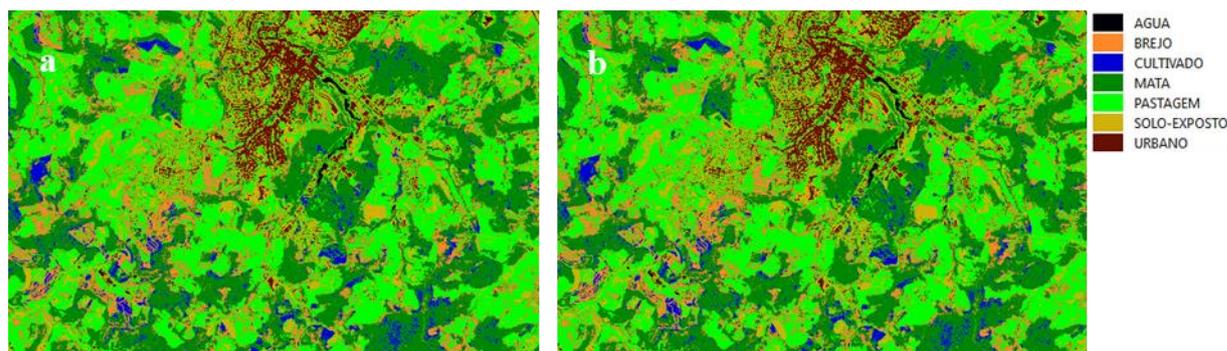


Figura 2 – Resultado da classificação temática da imagem RapidEye utilizando todos os cinco canais com o classificador SAM no ENVI (a) e com o classificador SAM implementado no Spring (b).

4. Conclusões

Embora existam outros classificadores supervisionados por pixel implementados no Spring, cuja exatidão temática seja maior, ou não, em relação ao classificador SAM, o mesmo é passível de implementação via linguagem LEGAL e a implementação do mesmo via GUI tornaria o procedimento muito mais simples.

Agradecimentos

Os autores agradecem o apoio FAPEMIG

Referências Bibliográficas

- Girouard, G.; Bannari, A.; El Harti, A.; Desrochers, A. Validated spectral angle mapper algorithm for geological mapping: comparative study between quickbird and landsat-tm, *Anais... ISPRS XX, Geo-Imagery bridging continents*, Istanbul, Turkey, pp.12-23, 2004.
- Huete, A. R. A soil adjusted vegetation index. *Remote Sensing of Environment*. v.25, n.3, pp.295-309, 1988.
- Jensen, R. J. *Introductory digital image processing- a remote sensing perspective*. Pearson Prentice Hall, New Jersey, 3ed, 526p., 2005.
- Jensen, J. R. *Introductory Digital Image Processing*. 3ed. Prentice Hall, 526p, 2005.
- Kruse, F.A.; Lefkoff, A.B.; Boardman, J. W; Heidebrecht, K.B.; Shapiro, A. T.; Barloon, P. J.; Goetz, A. F. H. The Spectral Image Processing System (SIPS) – interactive visualization and analysis of imaging spectrometer data. *Remote Sensing of Environment*, v.44, n.2 pp.145-163, 1993.
- Lillesand, T. M. ; Kieffer, R.W. *Remote sensing and image interpretation*. John Wiley and Sons, 3ed, New York, 749p., 1994.
- Petropoulos, G. P.; Vadrevu, K. P.; Xanthopoulos, G.; Karantounias, G.; Scholze, M. A comparison of spectral angle mapper and artificial neural networks classifiers combined with Landsat TM imagery analysis for obtaining burnt area mapping. *Sensors*, v.10, n.3, pp.1967-1958, 2010.
- Reis, G. L.; Silva, V. V. *Geometria Analítica*. LTC CEGRAF/UFG, Goiania, 1ed., 227p., 1984.
- Richards, J. A.; Jia, X. *Remote sensing digital image interpretation: an introduction*. Springer, 3ed., Alemanha, 363p., 1999.
- Schoengerdt, R. A. *Remote Sensing – models and methods for image processing*. Elsevier, San Diego, 3ed, 515p, 2007.
- Schowengerdt, A. R. *Remote sensing: models and methods for image processing*. 3ed. Elsevier, 515p., 2007.

Shafri, H. Z. M.; Suhaili, A. Mansor, S. The performance of maximum likelihood, spectral angle mapper, neural network and decision tree classifiers in hyperspectral image analysis. **Journal of Computer Science**, v.3, n.6, p.419-423, 2007.

Stoll, E.; Konstanski, H.; Anderson, C.; Douglass, K.; Oxfort, M. The RapidEye constellation and its data products. **Anais...IEEE Aerospace Conference, Big Sky, Montana**, pp.1-9, 2012.

Yuhas, R.H.; Goetz, A.F.H., Boardman, J.W. Discrimination among semi-arid landscape endmembers using the Spectral Angle Mapper (SAM) algorithm. **Anais... Summaries of the 4th JPL Airbone Earth Science Workshop, JPL Publication**, v.92, n.41, JPL, pp 147-149. 1992.