

CLASSIFICAÇÃO DE IMAGENS HIPERESPECTRAIS POR MEIO DE ABORDAGEM BASEADA NO MAPEAMENTO POR ÂNGULO ESPECTRAL E MÁQUINAS DE VETORES DE SUPORTE

Luiz E. Christovam, Milton H. Shimabukuro, M. Lourdes B. T. Galo, Franciele M. Tolentino

Universidade Estadual Paulista Júlio Mesquita Filho – Unesp/FCT, Rua Roberto Simonsen, 305, Centro Educacional – 19060-900 – Presidente Prudente-SP, Brasil
{luiz.christovam; milton.h.shimabukuro; trindade.galo; franciele.tolentino}@unesp.br

RESUMO

O sensoriamento remoto por meio da classificação de imagens permite construir mapas de cobertura da terra que podem ser utilizados por diversas aplicações. Apesar da importância desses mapas não há abordagem única de classificação definida como ideal, visto que diversos fatores podem exercer influência na qualidade dos resultados. Diante disso, este trabalho foi concebido com o propósito de analisar a qualidade de duas abordagens de classificação de imagens hiperespectrais, uma baseada no mapeamento pelo ângulo espectral (SAM) e outra combinando o SAM com as máquinas de vetores de suporte (SVM). Essas estratégias de classificação foram utilizadas para construir mapas de cobertura da terra para imagens hiperespectrais pertencentes ao conjunto de dados HyRANK. O mapa produzido por meio do SAM atingiu um valor de exatidão global de 48%, enquanto que o mapa gerado por meio da abordagem combinada SAM/SVM apresentou exatidão global de 88%, o que evidencia a superioridade do método combinado.

Palavras-chave - SAM, SVM, HyRANK.

ABSTRACT

Remote sensing image classification allows building land cover maps that can be used by different studies. Despite the importance of these maps, there is no single approach to image classification defined as the ideal, since several factors may influence the quality of the results. This work was conceived with the purpose of analyzing the quality of two hyperspectral image classification approaches, one based on spectral angle mapper (SAM) algorithm and another combining SAM with the support vector machine (SVM). These classification strategies were used to build land cover maps for hyperspectral images belonging to the HyRANK dataset. The map produced through SAM achieved an overall accuracy of 48%, while the map generated using the combined SAM/SVM approach achieved overall accuracy of 88%, which shows the superiority of the combined method.

Keywords - SAM, SVM, HyRANK.

1. INTRODUÇÃO

Informações relacionadas ao uso e cobertura da terra são essenciais para atividades de gerenciamento de recursos naturais, desenvolvimento de práticas sustentáveis, monitoramento de mudanças climáticas e planejamento urbano [1].

O sensoriamento remoto por meio da classificação de imagens é reconhecido como uma forma eficiente de gerar mapas da cobertura da terra, visto que permite mapear o planeta de forma contínua, consistente e com recobrimento superior ao possível a partir da perspectiva terrestre [2, 3].

Em razão da importância dos mapas da cobertura da terra para diversas aplicações, a comunidade científica de sensoriamento remoto tem direcionado esforço para melhorar a acurácia desses produtos, já que a classificação de imagens é um processo não trivial, em que diversos fatores exercem influência na qualidade dos produtos [4].

Fatores como tipo de imagem, algoritmo de classificação, resoluções espectral, radiométrica e geométrica, entre outros, tornam o processo de construção de mapas por meio da classificação de imagens uma tarefa complexa. Portanto, fomentam o estudo e desenvolvimento de modelos de classificação de imagens de sensoriamento remoto.

Com base no exposto, este trabalho foi concebido com o propósito de comparar duas abordagens de classificação supervisionada, para tanto foram utilizadas imagens hiperespectrais pertencentes ao conjunto de dados HyRANK. Na primeira abordagem foi adotado o método de mapeamento pelo ângulo espectral (*Spectral Angle Mapper* - SAM), já na segunda estratégia o SAM foi utilizado para a extração de atributos e as máquinas de vetores de suporte (*Support Vector Machine* - SVM) para a classificação.

2. MATERIAIS E MÉTODOS

2.1. Conjunto de dados

Foi utilizado neste trabalho o conjunto de dados aberto denominado como HyRANK, o qual trata-se de uma iniciativa científica da ISPRS, Comissão III, grupo de trabalho III/4 e que tem como o propósito disponibilizar imagens hiperespectrais e verdade terrestre para a validação de novos métodos de classificação [5].

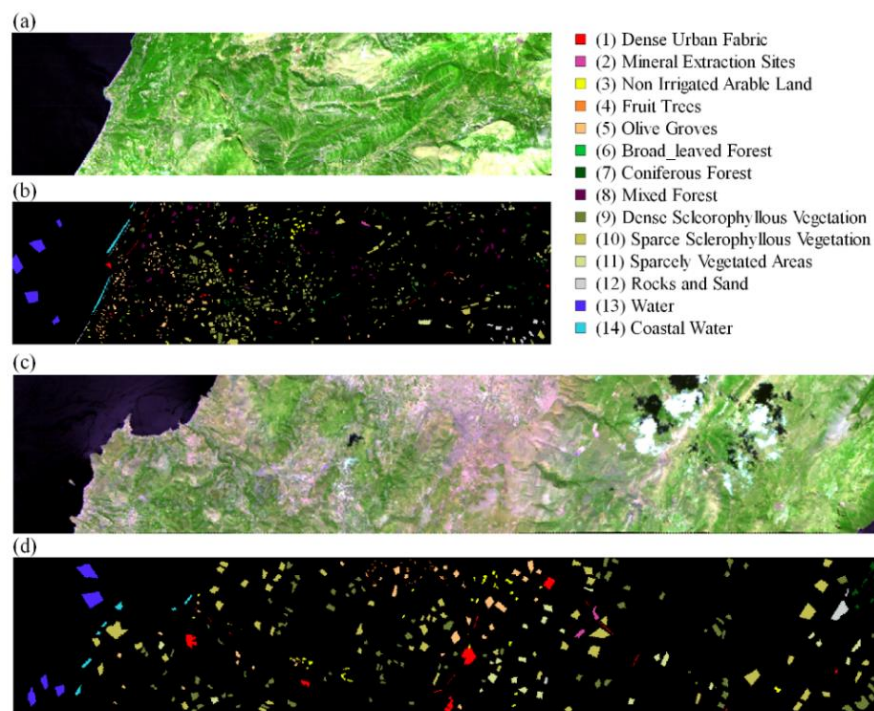


Figura 1. (a) Imagem Dioni composição B25G90R160 (b) Verdade terrestre para a imagem Dioni (c) Imagem Loukia composição B25G90R160 (d) Verdade terrestre para a imagem Loukia

O conjunto de dados HyRANK é composto por cinco imagens hiperespectrais adquiridas com o sensor Hyperion. Duas imagens (Loukia e Dioni) correspondem ao conjunto de treinamento, e portanto apresentam verdade terrestre, já as três imagens (Erato, Nefeli, Kiriki) compõe o conjunto de validação. As cinco imagens que compõe o conjunto de dados tratam-se de imagens de reflectância de superfície e apresentam 176 bandas espectrais cada, foram anotadas 14 classes de tipo de cobertura da terra na verdade terrestre dessas imagens.

HyRANK além de ser um conjunto de dados, trata-se de uma plataforma na qual será possível carregar os mapas produzidos para o conjunto de validação. Nessa plataforma *online* será calculada a exatidão global do modelo que também será disponibilizada para todos os usuários. Apesar de as imagens já estarem disponíveis a plataforma de avaliação *online* ainda não está. Em razão disso, neste trabalho 70% da verdade terrestre das imagens Loukia e Dioni foi utilizada para treinamento da classificação, 15% para validação e 15% para análise de qualidade. As imagens Loukia e Dioni, bem como as respectivas imagens de verdade terrestre são apresentadas na Figura 1.

2.2. Classificação

Neste trabalho foram selecionadas duas abordagens de classificação, uma que consiste na classificação por meio do SAM e outra que combina o SAM com o SVM.

O SAM trata-se de uma técnica de classificação supervisionada apresentada em [6] e é amplamente adotada na classificação de imagens hiperespectrais. O algoritmo mede a similaridade entre o vetor (espectro) de um pixel a ser classificado, com o vetor que representa cada uma das classes de interesse, a dimensão desses vetores é definida pela quantidade de bandas da imagem.

A medida de similaridade realizada com o SAM consiste no ângulo entre dois espectros, e pode ser calculado por meio da equação 1, em que \vec{t} representa o espectro do pixel a ser classificado, e \vec{r} o espectro da classe de interesse.

$$\theta = \cos^{-1} \left(\frac{\vec{t} \cdot \vec{r}}{\|\vec{t}\| \cdot \|\vec{r}\|} \right) \quad (1)$$

A partir da verdade terrestre foi gerado um espectro de referência para cada um dos 14 tipos de cobertura da terra existentes no conjunto de dados. Os espectros de referência foram definidos por meio da média de todos os espectros pertencentes a cada uma das classes descritas na verdade terrestre.

As imagens Loukia e Dioni foram classificadas por meio do SAM, para tanto foi medida a similaridade do espectro de todos os pixels pertencentes as imagens, com os 14 espectros de referência. Logo, para cada um dos pixels existentes nas imagens foram produzidas 14 medidas de similaridade. A classe de cada pixel foi definida como sendo igual a do espectro de referência mais similar (menor ângulo).

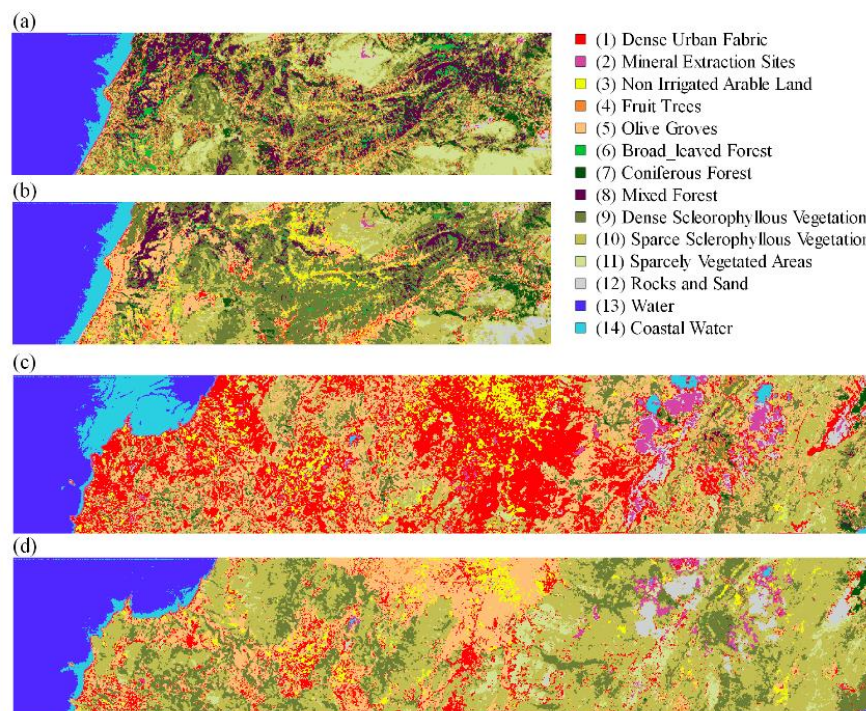


Figura 2. (a) Mapa de cobertura da terra para a imagem Dioni por meio do SAM (b) Mapa de cobertura da terra para a imagem Dioni por meio do SAM/SVM (c) Mapa de cobertura da terra para a imagem Loukia por meio do SAM (d) Mapa de cobertura da terra para a imagem Loukia por meio do SAM/SVM

A segunda abordagem de classificação tratou-se da combinação da técnica SAM com o SVM. O SAM contribuiu com as 14 medidas de similaridade (ângulos) gerados para cada uma das classes. Esses atributos serviram como dado de entrada para a definição do modelo de classificação com o SVM. Essa abordagem se mostra pertinente em razão de a classificação não se restringir ao menor ângulo, mas também por inserir como atributo o ângulo do pixel a ser classificado às demais classes.

O SVM trata-se de um algoritmo de aprendizado de máquina supervisionado que pode ser utilizado para classificação e regressão, e é considerado o estado da arte para a classificação de dados, em conjunto com classificadores como o *random forest* (RF) e as redes neurais (RN) [4].

O SVM ajusta, no espaço de atributos, os hiperplanos que melhor separam as classes de interesse a partir da minimização dos erros. Para tanto, o SVM se apoia nas amostras de treinamento que se localizam no limite do espaço que as define (vetores de suporte), e em razão disso não exigem grandes amostras de treinamento, mas sim amostras que definam o limite da classe no espaço de atributos [7].

Como já mencionado, o modelo de classificação foi definido com o SVM a partir de 14 atributos, que correspondem aos ângulos calculados do espectro de interesse com relação aos espectros das 14 classes de referência. Além do mais, o modelo de classificação foi definido com um kernel polinomial e com valor de γ igual a 100.

3. RESULTADOS E DISCUSSÃO

Os mapas de cobertura da terra para as imagens Loukia e Dioni construídos a partir da classificação com a técnica SAM podem ser observados nas Figuras 2 (a) e (c) respectivamente, já os mapas para as imagens Loukia e Dioni gerados com a abordagem combinada SAM/SVM são apresentados nas Figuras 2 (b) e (d) respectivamente. Como já mencionado foi selecionado 15% da verdade terrestre para testes, e partir desse conjunto de dados foram produzidas métricas de exatidão global, acurácia do usuário e do produtor para análise da qualidade dos modelos de classificação. Detalhes relacionados às métricas utilizadas podem ser encontradas em [8]. As métricas produzidas para a acessar a qualidade dos modelos de classificação são apresentados na Tabela 1.

Como pode ser observado na Tabela 1, o modelo de classificação definido com o algoritmo SAM apresenta exatidão global de 48% enquanto que a combinação do SAM/SVM apresenta exatidão global de 88%. Consequentemente, resultados compatíveis podem ser observados nos valores de acurácia do produtor e do usuário, que atingiram valores superiores na segunda abordagem de classificação quando comparados com o primeiro método.

Os efeitos relacionados com o menor valor de acurácia para o método SAM também podem ser observados nos mapas de cobertura da terra, a partir dos quais é possível verificar principalmente no mapa da imagem Loukia Figura 2 (c) que há uma predominância da classe 1, o que não condiz

Tabela 1. Métricas de avaliação da qualidade dos mapas de cobertura da terra

Classe	SAM		SAM/SVM	
	Exatidão Global			
	0,483		0,883	
	Ac. Produtor	Ac. Usuário	Ac. Produtor	Ac. Usuário
1	0,577	0,145	0,850	0,774
2	0,834	0,294	0,895	0,895
3	0,663	0,655	0,871	0,892
4	0,489	0,107	0,806	0,714
5	0,229	0,193	0,916	0,923
6	0,771	0,332	0,643	0,711
7	0,774	0,463	0,880	0,792
8	0,676	0,304	0,665	0,618
9	0,481	0,768	0,861	0,863
10	0,365	0,792	0,883	0,916
11	0,251	0,287	0,866	0,833
12	0,350	0,425	0,963	0,935
13	0,888	0,967	1,000	1,000
14	0,892	0,691	1,000	1,000

com a real cobertura da terra como pode ser observado na composição colorida dessa imagem Figura 1 (c). Esse erro na classificação também é evidenciado pelo baixo valor de acurácia do usuário (0,145), o que indica que grande parte dos pixels que foram incluídos na classe 1 não correspondem a esse tipo de cobertura da terra. Esse mesmo problema ocorre para outras classes, que apesar de não ficar evidente no mapa como fica para a classe 1, é retratado na Tabela 1 por baixos valores de acurácia do usuário para as classes 2, 4, 5, 6, 8 e 11.

A acurácia do produtor é uma métrica que retrata a omissão de pixels que realmente pertencem a classe. É possível observar na Tabela 1 que os valores de acurácia do produtor para a classificação com o SAM são superiores aos valores obtidos para a acurácia do usuário pelo mesmo método, entretanto valores baixos foram encontrados para as classes 5, 10, 11 e 12, o que indica que o modelo de classificação não ficou bem definido para essas classes, visto que pixels existentes na verdade terrestre e pertencentes a esses tipos de cobertura da terra deixaram de ser classificados.

Analisando os valores de acurácia do produtor e do usuário para o modelo de classificação produzido com a abordagem SAM/SVM é possível constatar que houve uma melhora significativa nos resultados quando comparados com o primeiro método. De maneira geral, os valores de acurácia do usuário e do produtor ficaram acima de 0,80, o que indica que esse modelo de classificação delimitou melhor as categorias no espaço de atributos.

4. CONCLUSÕES

Neste trabalho, foram definidos dois modelos de classificação um a partir da técnica SAM e outro combinando as técnicas

SAM/SVM. A partir dos modelos de classificação foi possível construir mapas de cobertura da terra para as imagens Dioni e Loukia que compõe o conjunto de dados HyRANK, por fim os mapas tiveram a qualidade analisadas por meio de métricas clássicas.

Os resultados obtidos evidenciam que a combinação da técnica SAM com o SVM para classificação dos tipos de cobertura da terra no conjunto de dados apresentado é superior a técnica SAM quando aplicada de maneira isolada. Isso decorre de que na abordagem SAM/SVM foram utilizados, para definir o modelo de classificação, os ângulos de cada espectro de interesse para cada uma das 14 classes existentes no conjunto de dados, diferente da técnica SAM que definiu a classe de cada espectro a partir do menor ângulo.

Apesar dos resultados obtidos para a abordagem SAM/SVM serem considerados bons, ainda há a possibilidade de melhorá-los incluindo outros atributos que minimizem a confusão na classificação. Outra possibilidade para trabalhos futuros é comparar os resultados obtidos utilizando o SVM com outros algoritmos de classificação como o RF e as RN.

5. REFERÊNCIAS

- [1] C. Gómez, J. C. White, and M. A. Wulder, "Optical remotely sensed time series data for land cover classification: A review," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 116, pp. 55-72, 2016.
- [2] G. J. Scott, M. R. England, W. A. Starns, R. A. Marcum, and C. H. Davis, "Training deep convolutional neural networks for land-cover classification of high-resolution imagery," *IEEE Geoscience and Remote Sensing Letters*, vol. 14, no. 4, pp. 549-553, 2017.
- [3] R. G. Congalton, J. Gu, K. Yadav, P. Thenkabail, and M. Ozdogan, "Global land cover mapping: A review and uncertainty analysis," *Remote Sensing*, vol. 6, no. 12, pp. 12070-12093, 2014.
- [4] R. Khatami, G. Mountrakis, and S. V. Stehman, "A meta-analysis of remote sensing research on supervised pixel-based land-cover image classification processes: General guidelines for practitioners and future research," *Remote Sensing of Environment*, vol. 177, pp. 89-100, 2016.
- [5] K. Karantzalos, Karakizi, Christina, Kandykakis, Zacharias, & Antoniou, Georgia, "HyRANK Hyperspectral Satellite Dataset I," ed, 2018.
- [6] F. A. Kruse *et al.*, "The spectral image processing system (SIPS)—interactive visualization and analysis of imaging spectrometer data," *Remote sensing of environment*, vol. 44, no. 2-3, pp. 145-163, 1993.
- [7] G. M. Foody and A. Mathur, "A relative evaluation of multiclass image classification by support vector machines," *IEEE Transactions on geoscience and remote sensing*, vol. 42, no. 6, pp. 1335-1343, 2004.
- [8] R. G. Congalton, "A review of assessing the accuracy of classifications of remotely sensed data," *Remote sensing of environment*, vol. 37, no. 1, pp. 35-46, 1991.