

Classificação de dados hiperespectrais AVIRIS baseada na codificação binária

Mario Ernesto Jijón Palma ¹
Jorge Antonio Silva Centeno ¹
Álvaro Muriel Lima Machado ¹

¹ Universidade Federal do Paraná – UFPR
Setor de Ciências da Terra – Departamento de Geomática, Programa de Pós-Graduação em
Ciências Geodésicas.
Caixa Postal 19001, 81.531-990 - Curitiba - PR, Brasil.
majijpa@hotmail.com
centeno@ufpr.br
alvaroml@ufpr.br

Abstract. Hyperspectral sensors provide images in hundreds of spectral bands that allows to discriminate objects with more details. But, the number of available training samples is limited. Thus, the dimensionality reduction is very important for the classification of high dimensional data. The approach developed in this work was the binary coding that was applied in hyperspectral data for dimensionality reduction. This encoding is based on a simple code and applied to a spectrum of reflectance pixel by pixel. Furthermore it seeks to develop a spectral representation that facilitates the identification of classes and their separability through the establishment of spectral libraries that stocks a number of spectra. For that, several experiments that allow the comparison of land cover classifications were tested. The alternatives that were performed on binary encoding were applied to a number of spectral regions (spectral libraries). Each alternative has been tested to a binary code through one to various thresholds. The results of these experiments show that the use of the binary encoding based on three thresholds and by regions allow the thematic mapping image classification and also reduce the dimensionality of hyperspectral data, being then more efficient than the use of one threshold for all the bands.

Palavras-chave: remote sensing, image processing, classification, binarization, sensoriamento remoto, processamento de imagens, classificação, binarização.

1. Introdução

O surgimento de imagens de satélite com grande número de bandas espectrais e com intervalo entre bandas muito estreito (imagens hiperespectrais) trouxe novos desafios no processamento e interpretação de imagens que não foram experimentados com os dados multiespectrais. Por um lado, o aumento da variedade espectral de bandas aumenta potencialmente a possibilidade de discriminar as classes ou objetos de interesse e também a acurácia na classificação (Benediktsson e Ghamisi, 2015). Porém, o crescimento da acurácia da classificação não é proporcional ao incremento de bandas. Ele cresce inicialmente até um ponto máximo, a partir do qual o aumento de novas bandas não traz maiores contribuições, pelo contrário, a partir desse ponto a acurácia diminui devido ao aumento da dimensão. Este problema é conhecido como fenômeno de Hughes (Fauvelet et al., 2012 apud Hughes, 1968), e ocorre pelo limitado número de amostras frente à alta dimensionalidade da imagem.

Este fenômeno, junto com as limitações impostas pelo custo computacional para a classificação, gerou o interesse por técnicas para redução das bandas usadas na classificação digital. Segundo Serpico et al. (2003) existem duas abordagens para a redução de dimensionalidade: a seleção de feições ou seleção do subconjunto mais relevante de bandas, e a extração de feições, baseada na transformação ou combinação das variáveis do conjunto original. Ao conjunto original correspondem trabalhos como os de Su et al. (2016), Yuan et al. (2015), Fauvel et al. (2015), Asl et al. (2014), Yang et al. (2012). Já no segundo grupo podem ser incluídos os trabalhos de Zabalza et al. (2016), Zhong et al. (2015), Ren et al. (2014), Zhang et al. (2013). A redução de dimensionalidade explora a inerente estrutura de baixa dimensão, reduz a complexidade computacional, e melhora o desempenho de análise de dados.

Uma opção para a extração de feições é a codificação binária (Mazer et al 1988, Jia e Richards 1993). Esta abordagem é conhecida como um algoritmo de análise eficaz e com pequena carga computacional para a classificação (Xie et al., 2011 apud Mazer et al., 1988). Como descreve Schowengerdt (2007) na codificação binária espectral o valor do pixel em cada banda espectral é representado por um estado binário (0 ou 1) usando um método de binarização e o valor de um pixel em cada imagem pode ser tratado como um bit. A combinação de vários bits permite gerar novos valores e codificar o conjunto de leituras em todas as bandas espectrais.

Jia e Richards (1993) apresentam uma forma de determinar automaticamente os limiares para imagens hiperespectrais. Nesse trabalho é proposto o uso de um ou três limiares T_1 , T_2 , e T_3 (limiares inferior, médio e superior) para codificar a banda em 1 bit ou 2 bits. Inicialmente escolhe-se T_2 como o valor médio dentro de uma região espectral especificada. Como o uso de apenas um limiar parece insuficiente, é proposto derivar os outros dois (inferior e superior) analisando a variação dos espectros dos diferentes tipos de cobertura. Jia e Richards (1993) fizeram o cálculo do percentual do limiar para um grupo de seis classes de vegetação, resultando aproximadamente um sexto. Desta forma, T_1 e T_3 ficaram iguais respectivamente a $5/6$ e $7/6$ do valor médio (T_2).

O critério de binarização é alvo de discussão, pois ele influencia de grande maneira o resultado da representação e, por conseguinte da classificação. Neste artigo é descrito um método, baseado naquele proposto por Jia e Richards (1993), para a seleção do critério de binarização, adaptado para as imagens do sensor AVIRIS.

2. Metodologia de Trabalho

Para a implementação da metodologia de codificação binária para redução de dimensionalidade em imagens hiperespectrais, utilizou-se dados do sensor AVIRIS (Airborne Visible/Infrared Imaging Spectrometer), obtidos através do site do repositório de pesquisa da Universidade de Purdue.

A seguir, aplicou-se a técnica de codificação binária por meio de um e três limiares. Os resultados foram 190 bandas com um ou dois bits por pixel. Estas bandas foram combinadas para gerar 168 imagens de 8 ou 16 bits, combinando grupos de 8 imagens de bandas contíguas no espectro. Com as novas imagens realizou-se a classificação e análise da separabilidade entre classes. Finalmente os resultados obtidos foram comparados e avaliados com a verdade terrestre da zona de estudo.

2.1 Codificação Binária

A regra de codificação binária mais geral consiste em separar os valores digitais de uma imagem em dois grupos, um abaixo e outro acima de um limiar pré-estabelecido (T), conforme descreve a equação 1.

$$\begin{aligned} h(n) &= 0 \quad \text{se } x(n) \leq T \\ &= 1 \quad \text{se } T < x(n), \end{aligned} \tag{1}$$

Na Equação 1 $x(n)$ é o valor do brilho de um pixel em uma determinada banda, T é o limiar especificado pelo usuário para a formação do código binário, e $h(n)$ é o símbolo de código binário resultante para o pixel na banda espectral de ordem n . Normalmente T é escolhido como o valor digital médio do espectro (Figura 1); tal processo de codificação binária irá produzir um pixel vetor de igual tamanho em bits ao número original das bandas espectrais.

Outra forma envolve o uso de vários limiares. A metodologia para escolher os limiares consiste em determinar o brilho médio (limiar médio) como descrito acima e, a partir deste, obter os limiares inferior e superior. Desta forma, obtém-se três limiares (inferior, médio e superior) e conseqüentemente 4 regiões (ver Figura 1). Esta codificação divide os possíveis valores em quatro regiões e por isso utiliza dois bits (00, 01, 10, 11). Assim cada pixel será representado através da Equação 2:

$$\begin{aligned}
 h(n) &= 00 \text{ se } x(n) \leq T_1 \\
 &= 01 \text{ se } T_1 < x(n) \leq T_2 \\
 &= 10 \text{ se } T_2 < x(n) \leq T_3 \\
 &= 11 \text{ se } T_3 < x(n)
 \end{aligned}
 \tag{2}$$

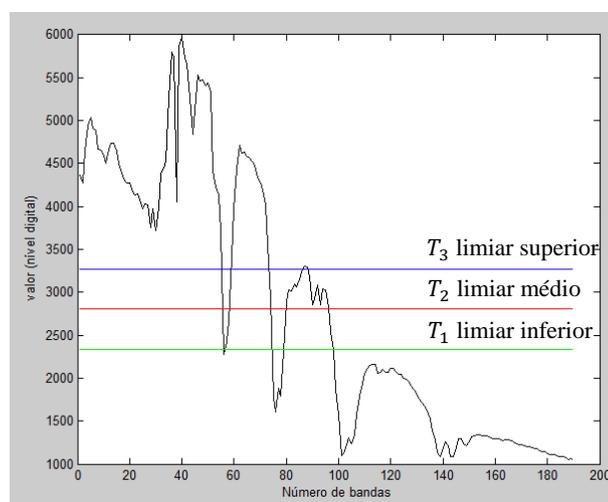


Figura 1. Espectro do sensor AVIRIS que mostra a formação de um código binário baseado em três limiares (inferior, médio e superior).

De posse das imagens resumidas à forma binária procedeu-se a agregar bandas consecutivas do espectro para formar novas imagens de 8 bits. Na Tabela 1 são mostrados os intervalos espectrais considerados para esta agregação. Como existe um número maior de bandas na região do infravermelho médio e próximo, a agregação de bandas nestas regiões resultou em uma quantidade maior de imagens.

Tabela 1. Criação de imagens agregadas por regiões.

Região	Bandas	Imagens obtidas
Azul	8	1
Verde	8	1
Vermelho	8	1
Infravermelho próximo	8 x 8	8
Infravermelho médio	10 x 8	10

Após a codificação binária da imagem hiperespectral por meio de um ou três limiares se aplica a binarização destas imagens com a finalidade de obter uma nova imagem que resumirá toda a informação contida na biblioteca espectral, com valores do pixel binarizados. Através da equação 3 e 4 pode-se determinar o novo valor de pixel binarizado da imagem para um limiar e três limiares respectivamente.

$$B_{i,j} = \sum_{t=1}^n V(t) * 2^{(t-1)} \quad (3)$$

onde, $B_{i,j}$ é o novo valor do pixel, t é a imagem binária e V é o valor binário proveniente do pixel de dois estados da imagem t .

$$B_{i,j} = \sum_{t=1}^n V_e(t) * 2^{(2t-1)} + V_d(t) * 2^{(2t-2)} \quad (4)$$

onde, $B_{i,j}$ é o novo valor do pixel, t é a imagem binária, V_e é o valor do bit mais significativo (esquerdo) e V_d é o valor do bit menos significativo (direito), ambos provenientes do pixel de quatro estados da imagem t .

2.2 Experimento

Para a realização dos experimentos através da codificação binária para redução de dimensionalidade em imagens hiperespectrais, utilizou-se dados do sensor AVIRIS. Esta imagem está composta por 224 bandas espectrais, mas inclui regiões do espectro com ruídos existentes em função da interferência do vapor de água da atmosfera. Este ruído pode causar inconvenientes no momento da análise e processamento dos dados. Por este motivo, é necessário realizar uma fase preliminar de exclusão e eliminação das bandas ruidosas. A eliminação das bandas espectrais foi feita de maneira visual, sendo identificadas as bandas com ruído e aquelas menos perturbadas. Neste contexto, das 224 bandas que tem o sensor AVIRIS apenas 190 serão utilizadas.

Esta imagem do sensor AVIRIS (Figura 2a) cobre uma área agrícola e está localizada no noroeste do estado de Indiana nos Estados Unidos. Também se dispõe da verdade terrestre (Figura 2b) composta de 7 classes com características espectrais muito similares entre si. As classes utilizadas para esta zona de estudo são: 1. Vegetação, 2. Milho plantio direto, 3. Milho cultivo mínimo, 4. Grama/pastagem, 5. Grama arvores, 6. Soja plantio direto, 7. Soja cultivo mínimo

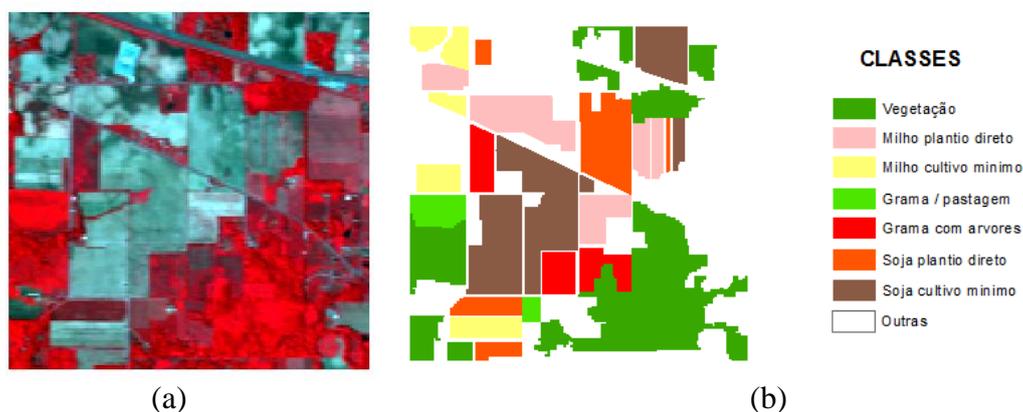


Figura 2. Imagem Hiperespectral do sensor AVIRIS e verdade terrestre

Baseado na metodologia utilizada por Jia e Richards (1993) determinou-se os valores do porcentual dos limiares para a imagem hiperespectral do sensor AVIRIS. Inicialmente optou-se por aplicar a metodologia proposta por estes autores, utilizando limiares inferior e superior de 5/6 e 7/6 do limiar médio.

Nos experimentos, descritos na seguinte seção, foi constatado que a adoção dos valores propostos por Jia e Richards não podem ser aplicados a outras imagens ou regiões sem uma adaptação. Eles são fortemente afetados pela resolução radiométrica do sensor e por isso os limiares inferior e superior devem ser adaptados. Assim sendo, procedeu-se a analisar os valores médios das classes de interesse para adotar um conjunto de limiares mais apropriados para o caso.

Desta forma, a seguir se apresenta os procedimentos para determinar os valores dos limiares: em primeiro lugar, escolhe-se T_2 como o valor médio dentro de uma região espectral especificada. Depois, analisam-se os espectros dos diferentes tipos de cobertura. Com isto obtém-se um valor médio para cada classe V_i , levando em consideração as diferentes áreas de treinamento. Em seguida, determina-se para cada uma das classes a diferença absoluta entre a média de cada classe (V_i) e T_2 , e calcula-se a média da diferença absoluta de todas as classes (porcentual do limiar). Depois de obter o porcentual do limiar, calcula-se o limiar inferior (T_1) e o limiar superior (T_3) em função de T_2 . Assim, para esta zona de estudo se utilizou sete classes, as mesmas que permitiram determinar o valor de 97/100 para o limiar inferior e 103/100 para o limiar superior.

3. Resultados e Discussão

As medidas de avaliação do algoritmo de codificação binária que se utilizaram na classificação foram: a média de classe específica, matriz de erros, coeficiente kappa e separabilidade de classes baseado no algoritmo de divergência transformada.

Experimento 1: Classificação utilizando bibliotecas espectrais com um limiar

Para este experimento realizou-se a codificação binária baseada em um limiar utilizando bibliotecas espectrais. O resultado de este experimento foi a classificação da imagem hiperespectral nas classes de cobertura (Figura 3).

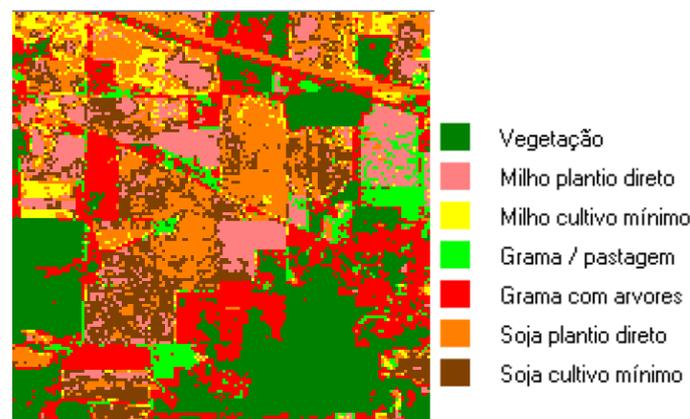


Figura 3. Classificação bibliotecas espectrais com um limiar

Através das amostras de treinamento das classes pode-se estimar a separabilidade entre elas. Assim, baseado no algoritmo de divergência transformada pode-se identificar que existe sobreposição entre varias classes. As principais sobreposições surgiram entre as classes: milho plantio direto e milho cultivado mínimo com valor de 1611, milho plantio direto e soja cultivado mínimo com valor de 1571, milho cultivado mínimo e soja cultivado mínimo com valor 1476 e soja plantio direto e soja cultivado mínimo com valor de 1667. Estes valores são baixos em comparação com as demais classes que tem valores iguais a 2000, o que indica que estas últimas classes não tem problemas de separabilidade.

Experimento 2: Classificação utilizando bibliotecas espectrais com três limiares (porcentual baseado em 1/6)

A variação deste experimento consiste em utilizar três limiares (inferior, médio e superior) para um porcentual de um sexto. Os resultados deste experimento permitem identificar que quando se trabalha com três limiares com bibliotecas espectrais podem dar origem a espectros codificados altamente separáveis. Através da Figura 4 pode-se mostrar a classificação utilizando a bibliotecas espectrais com três limiares.

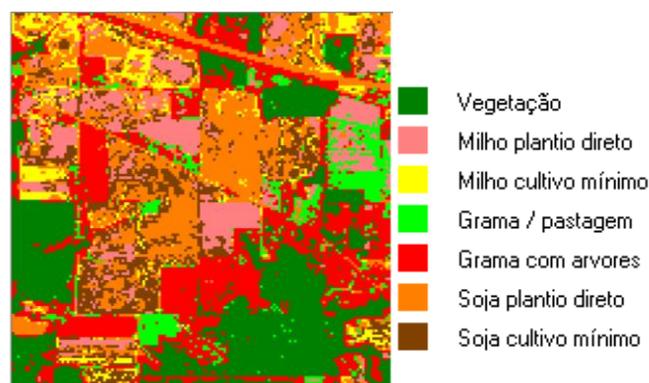


Figura 4. Classificação bibliotecas espectrais com três limiares (porcentual baseado em 1/6)

Realizou-se a análise da separabilidade em função das amostras de treinamento das classes. Os resultados permitiram identificar as mesmas confusões entre classes mostradas no experimento 1. A diferença pode-se perceber nos valores do algoritmo da divergência transformada, por exemplo: a separabilidade de milho plantio direto e milho cultivo mínimo variou de 1611 para 1701, milho plantio direto e soja cultivo mínimo mudou de 1571 para 1639, milho cultivo mínimo e soja cultivo mínimo modificou-se de 1476 para 1621, e soja plantio direto e soja cultivo mínimo variou de 1667 para 1642. Estes resultados permitem concluir que a separabilidade aumentou nos três primeiros itens e só no ultimo diminuiu.

Experimento 3: Classificação utilizando bibliotecas espectrais com três limiares (porcentual baseado em 0,03)

Jia e Richards (1993) calcularam o porcentual do limiar de um sexto baseado nos espectros correspondentes a seis diferentes tipos de cobertura (classes) em uma imagem diferente à utilizada para este trabalho. Assim, e necessário realizar o mesmo procedimento para a obtenção do porcentual do limiar para a imagem deste estudo e suas diferentes classes. Desta forma, realizou-se o cálculo do porcentual de limiar dando como resultado o valor de três centésimos. Na Figura 5 pode-se mostrar a classificação utilizando bibliotecas espectrais com três limiares e com três centésimos.

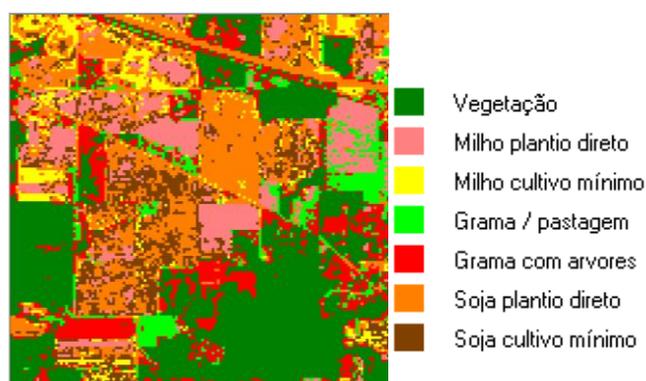


Figura 5. Classificação bibliotecas espectrais com três limiares (porcentual baseado em 3/100)

Após a análise de separabilidade deste experimento pode-se identificar que aumentaram os valores comparados com os valores do experimento 2. Assim, a separabilidade de milho plantio direto e milho cultivo mínimo variou de 1701 para 1767, milho plantio direto e soja cultivo mínimo mudou de 1639 para 1690, milho cultivo mínimo e soja cultivo mínimo modificou-se de 1621 para 1690, e soja plantio direto e soja cultivo mínimo variou de 1642 para 1903. Estes resultados confirmaram que separabilidade aumentou e as classes podem ser identificadas na classificação.

Finalmente, se avaliou a qualidade da cartografia temática obtida nos experimentos, Desta forma, foram calculadas as matrizes de confusão e os valores kappa para cada experimento (Tabela 2).

Tabela 2. Valores dos coeficientes kappa para os três experimentos.

Experimento	% Índice kappa
1	60.1
2	61.4
3	56.6

Comparando os valores dos coeficientes kappa pode-se perceber que são semelhantes, e estão dentro dos parâmetros aceitáveis baseado no desempenho da classificação.

4. Conclusões

Para este trabalho, propôs-se a utilização da codificação binária como alternativa para redução de dimensionalidade em imagens hiperespectrais. Neste algoritmo analisou-se a utilização de um e três limiares, identificando que o uso de três limiares é efetivo e eficiente na análise de separabilidade das classes e sua classificação.

A utilização de regiões espectrais para a redução de dimensionalidade apresentou resultados confiáveis, já que se realizou o cálculo dos três limiares baseado em cada região espectral, concluindo assim, que se deve analisar especificamente as regiões e não de forma geral para obter representatividade na classificação de cobertura.

Deve-se calcular o porcentual do limiar para cada zona de estudo Os resultados foram relevantes, já que os valores calculados por Jia e Richards (1993) não se adaptaram à nossa situação.

Agradecimentos

Os autores expressam seus agradecimentos aos colegas do curso de Pós-Graduação em Ciências Geodésicas (Universidade Federal do Paraná, Brasil) pelas valiosas discussões e debates sobre a pesquisa e pelo apoio prestado.

À CAPES pelo apoio financeiro à pesquisa.

A PURDUE University por disponibilizar a imagem.

Referências Bibliográficas

Asl, M. G.; Mobasheri, M. R.; Mojaradi, B. Unsupervised feature selection using geometrical measures in prototype space for hyperspectral imagery. IEEE transactions on geoscience and remote sensing, 52(7), 3774-3787, 2014.

Benediktsson, J.A.; Ghamisi P. Spectral-Spatial Classification of Hyperspectral Remote Sensing Images, 2015. 258 p.

Fauvel, M.; Chanussot, J.; Benediktsson, J. A. A spatial–spectral kernel-based approach for the classification of remote-sensing images. *Pattern Recognition*, 45(1), 381-392, 2012

Fauvel, M.; Dechesne, C.; Zullo, A.; Ferraty, F. Fast Forward Feature Selection of Hyperspectral Images for Classification With Gaussian Mixture Models. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(6), 2824-2831, 2015.

Goetz, A. F. H. Hyperspectral imaging: advances in a spectrum of applications, in *Proceedings of the 5th Australasian Remote Sensing Conference*, Perth, 8-12 October, 1990.

Hughes, G.F. On the mean accuracy of statistical pattern recognition. *IEEE Trans. Inform. Theory* IT 14, 55–63, 1968.

Jia, X.; Richards, J. A. Binary coding of imaging spectrometer data for fast spectral matching and classification. *Remote Sensing of Environment*, 43(1), 47-53, 1993.

Mazer, A. S.; Martin, M.; Lee, M.; Solomon, J. E. Image processing software for imaging spectrometry data analysis, *Remote Sensing of Environment*, 24:201-210, 1988.

Ren, J.; Zabalza, J.; Marshall, S.; Zheng, J. Effective feature extraction and data reduction in remote sensing using hyperspectral imaging [Applications Corner]. *IEEE Signal Processing Magazine*, 31(4), 149-154, 2014.

Schowengerdt, R. A. *Remote sensing: models and methods for image processing*, Academic press, Third Edition, 2007. 515 p.

Serpico, S. B.; D’Inca, M.; Melgani, F.; Moser, G. Comparison of feature reduction techniques for classification of hyperspectral remote sensing data, *International Symposium on Remote Sensing*, 4885, pp. 347–358, 2003.

Su, H.; Yong, B.; Du, Q. Hyperspectral Band Selection Using Improved Firefly Algorithm. *IEEE Geoscience and Remote Sensing Letters*, 13(1), 68-72, 2016.

Xie, H.; Heipke, C.; Lohmann, P.; Soergel, U.; Tong, X; Shi, W. A New Binary Encoding Algorithm for the Simultaneous Region-based Classification of Hyperspectral Data and Digital Surface Models, *Photogrammetrie - Fernerkundung - Geoinformation*, (1), pp. 17–33, 2011.

Yang, H.; Du, Q.; Chen, G. Particle swarm optimization-based hyperspectral dimensionality reduction for urban land cover classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(2), 544-554, 2012.

Yuan, Y.; Zhu, G.; Wang, Q. Hyperspectral band selection by multitask sparsity pursuit. *IEEE Transactions on Geoscience and Remote Sensing*, 53(2), 631-644, 2015

Zabalza, J.; Ren, J.; Zheng, J.; Zhao, H.; Qing, C.; Yang, Z.; Marshall, S. Novel segmented stacked autoencoder for effective dimensionality reduction and feature extraction in hyperspectral imaging. *Neurocomputing*, 185, 1-10, 2016.



Zhang, L.; Zhang, L.; Tao, D.; Huang, X. Tensor discriminative locality alignment for hyperspectral image spectral–spatial feature extraction. *IEEE Transactions on Geoscience and Remote Sensing*, 51(1), 242-256, 2013.

Zhong, Z.; Fan, B.; Duan, J.; Wang, L.; Ding, K.; Xiang, S.; Pan, C. Discriminant tensor spectral–spatial feature extraction for hyperspectral image classification. *IEEE Geoscience and Remote Sensing Letters*, 12(5), 1028-1032, 2015.