

REDUÇÃO DA DIMENSIONALIDADE DE DADOS HIPERESPECTRAIS PARA FINS DE CLASSIFICAÇÃO DIGITAL

Silva, C. R.¹, Botelho, M. F.¹ e Centeno, J. A. S.¹

1- UFPR, Universidade Federal do Paraná, www.ufpr.br - (crs, mosar, centeno) @ufpr.br

RESUMO - O objetivo deste estudo é verificar a transformada das componentes principais como redutor de dimensionalidade de dados hiperespectrais. Para tanto, foram comparadas as classificações da cobertura do solo realizadas por meio do classificador máxima verossimilhança e o módulo de classificação de imagem hiperespectral contido no pacote do ENVI 4.0. Duas alternativas foram verificadas: a aplicação da transformação das componentes principais ao conjunto total de bandas e a aplicação desta transformação por regiões espectrais. De posse destas CPs aplicou-se o classificador de máxima verossimilhança nos dois casos. Os produtos finais destes experimentos foram comparados com o produto gerado pelo SAM, do módulo de “Análise espectral” do ENVI 4.0. O estudo, em seus resultados, salienta que a extração do ruído de maneira visual, assim como a simples aplicação das CPs, reduziu a dimensionalidade dos dados hiperespectrais, de modo mais eficiente que o módulo “Análise espectral” do ENVI 4.0, o qual faz utilização de módulos complexos (classificação automática) para eliminar ruídos (MNF - Minimum Noise Transform), verificar a pureza de “pixels” (PPI - Pixel Purity Index) e extrair classes (SAM - Spectral Angle Mapper).

ABSTRACT - The objective of this study is to verify the principal components as reducing of dimensionality of hyperspectral data. So, the ground covering classifications carried through by means of the maximum likelihood classifier and the hyperspectral image classification module of ENVI 4.0 had been compared. Two alternatives had been verified: the application of the principal components transformation to the total set of bands and the application of this transformation for spectral regions. With this CPs, the maximum likelihood classifier, in the two cases, was applied. The final products of these experiments had been compared with the product generated for the SAM, spectral analysis module of ENVI 4.0. This study salient that the extraction of the noise visually, as well as the simple application of the PCs, that reduced the dimensionality of the hyperspectral data, was more efficient than the spectral analysis module, although it makes use of complex modules (automatic classification) to eliminate noises (MNF – Minimum Noise Transform), to verify the pureness of "pixels" (PPI - Pixel Purity Index) and to extract classes (SAM - Spectral Angle Mapper).

PALAVRAS CHAVE: Imagem Hiperespectral, Classificação, Sensoriamento Remoto

1 INTRODUÇÃO

A identificação de objetos e o mapeamento da superfície da terra usando sensoriamento remoto se baseia principalmente na hipótese da existência de diferenças espectrais entre objetos e de que estas diferenças são visíveis nas imagens captadas pelos sensores. Utilizando sensores multiespectrais, com um número restrito de bandas espectrais, esta situação nem sempre pode ser atingida, ficando o problema da impossibilidade de discriminar com base no restrito número de leituras do contador digital. Uma maneira de contornar esta limitação consiste no aumento de bandas espectrais, ou seja, o uso de sensores hiperespectrais. Um sensor hiperespectral possui uma grande quantidade de

intervalos espectrais, o que possibilita distinguir pequenas diferenças nas reflectâncias de objetos semelhantes.

No entanto, o aumento do número de bandas espectrais está associado ao aumento da redundância contida no conjunto de dados. Bandas espectralmente próximas tendem a ser altamente correlacionadas, motivo pelo qual uma grande quantidade das bandas de um sensor hiperespectral podem ser descartadas para determinadas finalidades. A vantagem é que através de bandas estreitas é possível analisar, com melhor qualidade, as diferenças espectrais entre objetos e assim separá-los (Fukunaga, 1990).

Busca-se neste trabalho distinguir cobertura do solo com variação espectral semelhante, através do processo de classificação máxima verossimilhança,

verificando a eficácia da transformada de Karhunen-Loeve como redutor de dimensionalidade de uma imagem hiperespectral e através do módulo de classificação do ENVI 4.0. Este redutor tem como meta compactar as bandas de forma a otimizar a informação contida em um grande conjunto de dados em poucas bandas (CPs), o que facilita o processo de classificação.

2 REVISÃO LITERÁRIA

Segundo Moreira (2003), um sensor hiperespectral permite registrar a radiação refletida pelos alvos em 200 ou mais bandas espectrais, nas unidades mínimas de resolução (pixel). Os sistemas hiperespectrais podem ser aerotransportados e terrestres, sendo que no mapeamento da cobertura da terra os sensores aerotransportados são os mais relevantes. Neste grupo se enquadram o AVIRIS (Airborne Visible/Infrared Imager Spectroradiometer) e o HYDICE (Hiperespectral Digital Imagery Collection Experiment).

O sensor AVIRIS opera em 224 bandas espectrais, na faixa reflectiva do espectro eletromagnético que varia de 400 a 2500nm. Esse sensor foi desenvolvido pela NASA em 1983, como o primeiro sistema de imageamento para adquirir dados numa faixa contínua do espectro reflectivo, ou seja, de 380 a 2500nm. Tornou-se operacional em 1989 e é grandemente utilizado nas Américas do norte e central. Produz um arquivo de 140MB a cada cena (512 linhas escaneadas) representativa de aproximadamente 10Km de comprimento no terreno.

As imagens dos sensores hiperespectrais estão sujeitas a uma grande redundância de dados. Este fator torna-se um problema na fase de classificação digital, quando a dimensão do vetor de entrada cresce proporcionalmente ao número de bandas. Por exemplo, para classificar uma imagem AVIRIS, com 224 bandas pelo método da Máxima Verossimilhança Gaussiana, é necessário multiplicar e inverter matrizes 224x224. Além disso, estas matrizes podem conter linhas similares em função da correlação entre variáveis. Solução para este problema são a seleção de variáveis representativas ou a composição de novas bandas pela combinação de um subconjunto de bandas originais, por exemplo, aplicando uma transformação espectral como as componentes principais.

A análise de componentes principais tem como objetivo determinar a correlação existente entre conjuntos de dados, e posteriormente, removê-la, gerando um novo conjunto de variáveis, combinações lineares das originais, que apresentam um grau mínimo de correlação, mas que representam a mesma informação que o conjunto original. Moreira (2003) resume em

poucas palavras que o uso de componentes principais visa a redução da dimensionalidade dos dados e a compactação das informações espectrais dos alvos armazenadas em várias bandas, num número reduzido de componentes, sem perda significativa de informações.

Erbert e Haertel (2003) buscaram uma solução aplicando o classificador Máxima Verossimilhança para diferenciar culturas agrícolas em imagens hiperespectrais. Estes autores recomendam a realização de experimentos usando a transformada de Karhunen-Loeve (Componentes Principais), que é baseada na matriz covariância, como um redutor de dimensionalidade.

3 MATERIAIS

Neste trabalho foram utilizados dados do sensor hiperespectral AVIRIS (doação da Universidade de Purdue), cobrindo uma área agrícola localizada no Estado de Indiana – EUA (Figura 1). Esta região é uma área de testes de dados em alta dimensionalidade, sendo coberta por culturas agrícolas que apresentam um comportamento espectral muito semelhante entre si, fato que impossibilita sua discriminação a partir de dados multiespectrais. Informações detalhadas a respeito da região também foram levantadas, simultaneamente à passagem do sensor. A “verdade terrestre” pode ser vista na Figura 2. Estas informações permitem uma análise precisa dos resultados dos testes realizados (Figura 2).



Figura 1. Imagem hiperespectral.




Figura 2. Verdade terrestre (modificada de Moraes et. al. 2004).

Foi utilizado o programa ENVI para o processamento da imagem, mais especificamente, o redutor de dimensionalidade (componentes principais), o classificador máxima verossimilhança e o módulo de “Análise espectral para dados hiperespectrais”.

4 MÉTODO

O conjunto de 224 bandas espectrais inclui regiões do espectro onde a perturbação da atmosfera é intensa e prejudica os dados. Por este motivo, numa fase inicial, estas bandas foram eliminadas. Para isto, o conjunto de imagens foi analisado visualmente, sendo identificadas as bandas com ruído e aquelas menos perturbadas. Conjuntos de bandas das regiões do visível, (verde e vermelho) e o infravermelho (próximo e médio), foram assim escolhidos. A Tabela 1 mostra os conjuntos selecionados.

Intervalo espectral	bandas	total
Verde (0,45 a 0,5 μ m)	6 a 15	10
Vermelho (0,5 a 0,72 μ m)	16 a 25	10
Infra Vermelho próximo (0,72 a 0,78 μ m)	27 a 36	46
(0,84 a 1,3 μ m)	40 a 76	
Infra Vermelho médio (1,38 a 1,56 μ m)	84 a 102	128
(1,67 a 2,01 μ m)	113 a 147	
(2,21 a 2,67 μ m)	167 a 213	

Tabela 1- Bandas selecionadas

A seguir, aplicou-se a transformação das componentes principais com o objetivo de reduzir a dimensionalidade, eliminando a correlação entre as bandas. Com as novas bandas, resultado da transformação foi realizada a classificação utilizando o algoritmo de máxima verossimilhança. Finalmente os resultados obtidos foram comparados com o produto gerado pelo ENVI 4.0 em seu módulo de “Análise espectral”, o qual subdividiu-se em: (MNF - Minimum Noise Transform) na eliminação de ruídos, (PPI - Pixel Purity Index) na verificação da pureza dos “pixels” e (SAM - Spectral Angle Mapper) na extração das classes.

4.1 Componentes Principais (CPs)

A análise das componentes principais consiste na rotação do sistema original (conjunto de variáveis) de forma que as bandas resultantes tenham correlação mínima. Se cada variável original pode ser considerada como um eixo de um sistema ortogonal, estando usualmente correlacionada com outras variáveis, esta

análise transforma os dados de tal modo a descrever a mesma variabilidade total existente, com o mesmo número de eixos originais, porém não mais correlacionados entre si. Na Figura 3, o sistema de eixos hipotético CP(u,v) - (B), ilustra uma possível rotação dos eixos eliminando a correlação existente no par de variáveis originais Banda(i,k) - (A). Nota-se que não existe mais correlação na nuvem de pontos (variáveis) após a rotação.




Figura 3. Gráfico ilustrativo da rotação por CPs

A análise das componentes principais inicia-se com o cálculo dos autovalores e correspondentes autovetores da matriz de variâncias-covariâncias do conjunto de observações em todas as bandas originais. A transformação gera um número igual de bandas resultantes, as quais podem ser ordenadas, segundo o conteúdo de informação em relação ao conjunto original. O tamanho do autovalor associado a cada componente principal corresponde à porcentagem da variabilidade total presente nela. Geralmente os dois ou três primeiros autovalores encontrados explicam a maior parte da variabilidade original.

4.2 Máxima Verossimilhança

A probabilidade condicional descrita pelo Teorema de Bayes (Richards e Jia, 1999) serve para estimar a probabilidade de uma classe ocorrer.

O elemento x , pertence à classe w_i se

$$P(x \in w_i) > P(x \in w_j) \quad i \neq j$$

ou

$$P(w_i | x) > P(w_j | x) \quad \text{com} \quad P(w_i | x) = \frac{P(x | w_i)P(w_i)}{P(x)} \quad (1)$$

Assumindo uma distribuição gaussiana dos elementos dentro de cada classe tem-se para m -variáveis

$$P(x | w_i) = (2\pi)^{-\frac{m}{2}} |\Sigma_j|^{-\frac{1}{2}} \exp^{(-0,5(x-\mu_j)' \Sigma_j^{-1} (x-\mu_j))} \quad (2)$$

Para fins de facilitar os cálculos, na equação 2, os termos $P(x)$ e $P(w_i)$ são considerados constantes, do que resulta:

$$x \in w_i \text{ se } P(x | w_i) > P(x | w_j)$$

Substituindo (2) e fazendo os devidos cálculos e simplificações obtêm-se a equação 3 que expressa o critério de decisão do método

$$G(x) = \ln(|\Sigma_j|) + (x - \mu_j)' \Sigma_j^{-1} (x - \mu_j) \quad (3)$$

$$x \in w_j \text{ se } G_j(x) < G_i(x) \quad \forall j \neq i$$

onde

$|\Sigma_j|$ = Determinante da matriz de variância-covariância para a classe w_j ;

Σ_j^{-1} = Inversa da matriz de variância-covariância para a classe w_j ;

μ_j = Vetor médio da classe j .

4.3 Classificador SAM

O classificador SAM utiliza de um espectro de referência produzido em laboratório, campo ou extraído diretamente da imagem. O SAM mede a similaridade espectral calculando o ângulo entre os dois espectros, tratando-os como vetores no espaço n -dimensional. Os ângulos pequenos entre os dois espectros indicam uma similaridade elevada enquanto ângulos elevados indicam baixa similaridade (Kruse et al., 1993).

O SAM é um classificador poderoso porque reprime a influência de efeitos acentuados, protegendo as características da reflectância do alvo (DeCarvalho e Meneses, 2000).

A desvantagem principal deste método é o problema espectral da mistura. Assim, a falha do SAM está em supor que os padrões escolhidos para classificar uma imagem, representam os espectros puros de um material de referência. Devido a heterogeneidade da superfície da terra, em muitos casos, torna-se incontestável a mistura de pixels. A confusão espectral nos pixels pode conduzir aos erros da subestimação e da superestimação para uma classe espectral. No general, o problema espectral da mistura deve diminuir com imagens de maior resolução, como Quickbird, mas em alguns casos, pode também aumentar o problema da mistura, porque variações mais locais na propriedade

espectral de uma superfície, mostram-se mais aparentes, tais como a umidade, elevação e outros (Gebbinck, 1998).

5 RESULTADOS E DISCUSSÕES

Nesta seção serão apresentados os resultados obtidos em cada etapa, sendo: Cálculo das CPs, Classificação com máxima verossimilhança e Classificação utilizando o ENVI.

5.1 Cálculo das CPs

De posse das bandas apresentadas na Tabela 1, iniciou-se o processo de cálculo das CPs, realizando-se dois experimentos. No primeiro, calculou-se a CP para cada subintervalo, sendo 10 bandas para o verde, 10 para o vermelho, 46 para o infravermelho próximo e 128 para o infravermelho médio. As CPs escolhidas foram aquelas que representaram mais de 99% dos dados originais. No verde e no vermelho, apenas uma componente principal foi necessária. A primeira componente principal do verde representa 99,24%, e a do vermelho 99,67%, isso pode ser explicado pelo fato das bandas desse intervalo serem muito correlacionadas. No conjunto do infravermelho próximo 99,59% é representado pelas três primeiras componentes e no infravermelho médio duas componentes são necessárias para representar 99,44%. Nestes dois últimos intervalos percebeu-se que foi necessário um número maior de bandas para representar mais de 99,00% dos dados originais, isso se explica devido uma menor correlação existente entre as respectivas bandas destes intervalos. A Tabela 2 mostra o número de bandas e a percentagem representada por cada uma delas, nos referidos intervalos.

Região	Componente Principal	(%)	Total (%)
Verde	1	99,24	99,24
Vermelho	2	99,67	99,67
IVP	1	76,77	99,59
IVP	2	21,92	
IVP	3	0,90	
IVM	1	84,31	99,44
IVM	2	15,13	

Tabela 2 bandas derivadas da aplicação da CP a cada subconjunto de dados.

No segundo experimento, calculou-se as CPs para todo o intervalo disponível, ou seja, para todas as 194 bandas mostradas na Tabela 1. Para obter um número de bandas novas igual ao conjunto obtido no primeiro experimento, foram escolhidas as sete primeiras

componentes principais, que representaram 99,78% dos dados originais, como pode ser observado na Tabela 3. Nota-se que as quatro primeiras componentes já representam quase 99,5% da informação original, o que pode ser indicio de redundância no conjunto selecionado no primeiro experimento.

Componente principal	(%)	Total (%)
1	73,40	99,78
2	24,02	
1	1,70	
2	0,37	
3	0,15	
1	0,12	
2	0,04	

Tabela 3 - bandas derivadas da aplicação da CP a todas as bandas.

5.1.1 Classificação com máxima verossimilhança

Nesta fase, com as CPs já calculadas, foram coletadas as amostras para treinamento como pode ser observado na Figura 4.a. Em seguida aplicou-se o classificador de máxima verossimilhança em ambos conjuntos de CPs dos experimentos 1 e 2, obtendo as imagens classificadas, mostradas respectivamente nas Figuras 4.b e 4.c.




Figura 4. Imagens classificadas: (a) Amostragem; (b) classificação usando CPs experimento 1; (c) classificação usando CPs experimento 2.

Comparando a “verdade terrestre” (Figura 2), com as Figuras 4.b e 4.c, obteve-se os valores de “kappa” apresentados na Tabela 4.

Experimento	Kappa
1	60.0
2	59.6

Tabela 4 Valores dos índices kappa

Observando a Tabela 4 nota-se que a acurácia obtida com o experimento 1 e 2 foram semelhantes devido a alta representabilidade das CPs diante dos dados originais.

5.1.2 Classificação utilizando o ENVI 4.0

Utilizando-se dos mesmos intervalos espectrais, foram realizados vários experimentos considerando o mesmo número de classes, por meio do módulo de classificação de imagens hiperespectrais do ENVI 4.0 (SAM). O melhor resultado dessa classificação pode ser observado na Figura 5.

Comparando-se a “verdade terrestre” (Figura 2), com a Figura 5, foi obtido o valor de “kappa” igual a 47.1. Analisando os resultados obtidos com os experimentos 1 e 2 (Tabela 4), nota-se a superioridade destes experimentos em relação ao processo de classificação do ENVI. Isso ocorre devido a complexidade do módulo de classificação do ENVI em sua automação na exclusão dos ruídos (MNF), na verificação da pureza dos “pixels” (PPI) e na extração das classes (SAM).




Figura 5. Resultado da classificação do ENVI

6 CONCLUSÃO

Conclui-se com este trabalho que a utilização da transformada de Karhunen-Loeve (CP) é relevante na redução da dimensionalidade, uma vez que seus resultados produziram classificações semelhantes nos dois experimentos e foram mais eficientes que o método SAM, utilizado pelo ENVI 4.0, tanto na qualidade do resultado como no tempo de processamento.

A utilização da redução da dimensionalidade em subdivisões de intervalos das faixas espectrais (verde, vermelho, infravermelho próximo e médio) apresentou

resultado semelhante ao utilizado na faixa inteira, concluindo assim, que para a utilização de CP deve observar-se o percentual acumulado da representatividade das componentes escolhidas, sendo que para este trabalho, escolheu-se um percentual acima de 99%.

A aplicação da transformação das componentes principais a todo o conjunto de dados revelou que um conjunto menor de variáveis pode ser obtido. Isto pode residir no fato de que análises separadas, por região espectral, não eliminam a correlação ente variáveis de diferentes regiões espectrais. Por este motivo, recomenda-se a aplicação da transformação ao conjunto completo.

7 REFERÊNCIAS

- Erbert, M.; Haertel, V. Estudo sobre técnicas de regularização da matriz covariância no processo de classificação de dados em alta dimensionalidade. **Anais XI SBSR**, Belo Horizonte, Brasil, 05- 10 abril 2003, INPE, p. 1061-1068.
- Fukunaga, K., **Introduction to Statistical Pattern Recognition**, 2^a ed., School of Electrical Engineering, Purdue University, West Lafayette, Academic Press Inc. 1990.
- Moraes, D. A. O.; Haertel, V.; Clarke, R. T. Redução de dimensionalidade em imagens hiperespectrais por meio de classificadores de decisão em árvore. **XII Jornadas de Jovens Pesquisadores da AUGM**, Curitiba, 2004
- Moreira, M. A. **Fundamentos de Sensoriamento Remoto e Metodologia de Aplicação**. Editora: UFV, Universidade Federal de Viçosa: 2^a edição. Viçosa-MG, 2003. 307p.
- Richards, J. A.; Jia, X. **Remote sensing digital image analysis – an introduction**. 3^a Ed. Springer Austrália, 1999.
- De Carvalho, O.A. and Meneses, P.R. (2000). Spectral Correlation Mapper (SCM); An Improvement on the Spectral Angle Mapper (SAM). **Summaries of the 9th JPL Airborne Earth Science Workshop**, JPL Publication 00-18, 9 p.
- Gebbinck, M.S.K. (1998). Decomposition of Mixed Pixels in Remote Sensing Images to Improve the Area Estimation of Agricultural Fields. Ph.D. **thesis, Katholieke Universiteit Nijmegen, Veenendaal Universal Press**, 165 p.
- Kruse, F.A., Boardman, J.W., Lefkoff, A.B., Heidebrecht, K.B., Shapiro, A.T., Barloon, P.J., and Goetz, A.F.H. (1993). The Spectral Image Processing System (SIPS) – **Interactive Visualization and Analysis of Imaging Spectrometer Data. Remote Sensing of Environment**, Vol. 44, p.145-163.

Silva, C. R., Botelho, M. F. e Centeno, J. A. S.

8 AGRADECIMENTOS

Aos colegas do curso de Pós-Graduação em Ciências Geodésicas: Ângela Cristina, Juliana Moulin e Glauber A. Cunha pelo apoio prestado.

À CNPq pelo apoio financeiro à pesquisa.