

Análise multivariada de imagens hiperespectrais na plataforma R

Marcelo Damasceno¹
Talita Perciano Costa Leite²
Alejandro César Frery¹
Marcelo Almirón³
Adrián Muract³

¹Universidade Federal de Alagoas – UFAL
BR-104 Norte km 97 – 57072-970 Maceió – AL, Brasil
marcelodamasceno@gmail.com, acfrery@pesquisador.cnpq.br

²Universidade Federal de São Carlos – UFSCar
Rodovia Washington Luis (SP-310) km 235, 13565-905 São Carlos – SP, Brasil
talita_leite@dc.ufscar.br

³Universidad Nacional de Río Cuarto – UNRC
Ruta 36 Km 601 – X5804ZAB Río Cuarto – Córdoba, Argentina
almiron.marcelo@gmail.com, amuract@dc.exa.unrc.edu.ar

Abstract. R is a free, flexible, extensible system for graphics and statistical computing that is available for the most known computer platforms. However, it does not have resources for multivariate analysis of image data. This paper presents and describes the design, implementation and use of a new package of functionalities that allows the use of R for hyperspectral data analysis. The package `rHiper` offers tools to visualize, process and make multivariate analysis of AVIRIS images. This package produces various graphics and is totally extensible.

Palavras-chave: remote sensing, hiperespectral images, multivariate analysis, sensoriamento remoto, imagens hiperespectrais, análise multivariada.

1. Introdução

As imagens hiperespectrais (ver Tsai e Philpot (1998); Wang et al. (2006); Lira Chávez (2002); Jain (1989)) são captadas por sensores hiperespectrais, os quais estão na órbita da Terra obtendo, a todo momento, imagens da superfície do planeta. Estas imagens possuem mais do que 100 bandas, chegando a demandar mais de 140 MB de espaço de armazenamento. AVIRIS (Vane et al. (1993)), por exemplo, é um sensor hiperespectral que fornece informações em 224 bandas.

Dentre as inúmeras utilidades deste tipo de imagem, uma das mais importantes é o reconhecimento de materiais (Debba et al. (2005)). Devido ao grande volume de dados, a análise de imagens hiperespectrais demanda muitos recursos computacionais e ferramentas que mostrem informações relevantes para realizar qualquer tipo de estudo. A necessidade de analisar grandes conjuntos de dados é cada vez mais acentuada nas mais variadas áreas do conhecimento (ver Everitt et al. (2001); Figueira (1998); Kaufman e Rousseeuw (1990)). A análise descritiva multivariada oferece técnicas e métodos utilizados na correlação, manipulação, simplificação e visualização de informações relevantes de um grande volume de dados.

O ambiente R (Hornik (2002)) é um software estatístico livre, isto é, segue os termos descritos na licença GPL. Ele é disponibilizado para vários ambientes computacionais, dentre eles: Microsoft Windows, Linux e Apple MacOS. R é utilizado nos meios acadêmico e profissional, pois fornece diversas ferramentas para a análise e manipulação de dados e construção de

gráficos de qualidade. O ambiente R é composto de um núcleo e de pacotes, dentre eles podemos citar o `rImage`, um pacote para a leitura e manipulação de imagens no formato JPEG.

Neste trabalho foi desenvolvido um novo pacote para o sistema R que oferece ferramentas para a leitura, processamento e análise descritiva multivariada de imagens hiperespectrais. Este pacote, `rHiper`, foi totalmente desenvolvido utilizando a linguagem R. O `rHiper` oferece ao usuário diversas ferramentas de fácil utilização para a análise descritiva multivariada de dados oriundos de imagens hiperespectrais.

2. Notações e Definições

Uma imagem hiperespectral é uma função $f: S \rightarrow K^p$, onde a grade euclidiana finita $S = \{0, \dots, m-1\} \times \{0, \dots, n-1\}$ é o suporte, $K \in \mathbb{R}$ é algum subconjunto finito da reta e $p \in \mathbb{N}$ com $p \geq 100$ é o número de bandas.

Pode ser conveniente utilizar a notação explícita $f = \{f(s) = (f^1(s), \dots, f^p(s))\}$ com $s \in S$. O par $(s, f(s))$, com $s \in S$, chama-se pixel, e pode ser conveniente deixar em evidência as componentes da coordenada, isto é, usar (i, j) no lugar de $s \in S$.

Na análise de imagens muitas vezes é necessário escolher uma região de interesse da imagem, visto que a quantidade de dados é grande e não totalmente necessária para o estudo. Assim, um subconjunto $A \subset S$ não vazio é escolhido para representar a região de interesse. O número de elementos de A é denotado por $\#A$. Desta forma, f_A é a notação para $\{f(s) = (f^1(s), \dots, f^p(s)), s \in A\}$. Se $\#A = 1$, usaremos $A = s$ ou $A = (i, j)$.

A restrição das observações a uma banda específica k , com $1 \leq k \leq p$, será denotada f^k , significando $f^k = f^k(s)$, $s \in S$.

Se L é um conjunto de bandas, isto é, $L \subset \{1, \dots, p\}$, podemos definir $f^L = \{f^\ell: \ell \in L\}$ como sendo a restrição da imagem às bandas do conjunto L . Consequentemente a restrição da imagem a algumas bandas em uma região de interesse é definida por f_A^L como $f_A^L = \{f^\ell(s), \ell \in L, s \in A\}$.

As seguintes quantidades, chamadas ‘momentos’, serão de interesse neste trabalho:

Média amostral: O vetor de médias amostrais das bandas $L \subset \{1, \dots, p\}$ calculado sobre a região A é o vetor $\overline{f_A^L} = n^{-1}(\sum_{s \in A} f(s)^\ell)_{\ell \in L}$.

Desvio padrão amostral: O desvio padrão amostral da banda ℓ na região A é dado por $\hat{\sigma}_A^\ell = (\sum_{s \in S} (f(s)^\ell - \overline{f_A^\ell})^2)^{1/2}$.

Valores ordenados: Os valores ordenados em forma não decrescente da banda ℓ na região A são denotados $(f_{A,1:n}^\ell, \dots, f_{A,n:n}^\ell)$, isto é, $f_{A,1:n}^\ell \leq \dots \leq f_{A,n:n}^\ell$. Os quartis da amostra são o primeiro $f_{A,[n/4]:n}$, o segundo ou mediana $f_{A,[n/2]:n}$ e o terceiro $f_{A,[3n/4]:n}$.

Outliers: Definindo IQ como o intervalo interquartil $(f_{A,[n/4]:n} - f_{A,[3n/4]:n})$. Os *outliers* são observações que estão $3 * IQ$ ou mais acima do terceiro quartil $f_{A,[n/4]:n}$ ou $3 * IQ$ ou mais abaixo do primeiro quartil $f_{A,[3n/4]:n}$, isto é, são observações que apresentam um grande afastamento das observações restantes.

Em todos os casos, $\#A = n$.

3. Análise descritiva gráfica

A análise descritiva gráfica de dados tem por objetivo fornecer um “resumo” da informação sem compromisso nenhum com a modelagem dos dados. Descreveremos a seguir os recursos oferecidos pelo pacote `rHiper`.

A face de Chernoff é o mapeamento de f_s^L , com $2 \leq \#L \leq 15$, em um objeto gráfico que lembra um rosto. Denotando $f_s^L = (v_1, \dots, v_{\#L})$, cada coordenada deste vetor será identificada com um atributo da face: altura do rosto, largura do rosto, forma do rosto, altura da boca, largura da boca, curva do sorriso, altura dos olhos, largura dos olhos, altura do cabelo, largura do cabelo, estilo do cabelo, altura do nariz, largura do nariz, altura das orelhas e largura das orelhas. Cada atributo da face é desenhado proporcionalmente aos valores dos vetores f_s^L . Na **Figura 1** temos a representação dos seguintes vetores:

1. $f_1^L = \{-10000, -10000, -10000, -10000, -10000, -10000, -10000, -10000, -10000, -10000, -10000, -10000, -10000, -10000, -10000\}$,
2. $f_2^L = \{0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0\}$,
3. $f_3^L = \{10000, 10000, 10000, 10000, 10000, 10000, 10000, 10000, 10000, 10000, 10000, 10000, 10000, 10000, 10000\}$,
4. $f_4^L = \{1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1\}$.

As faces 1, 2, 3 e 4 são as representações dos vetores f_1^L , f_2^L , f_3^L e f_4^L respectivamente. Podemos perceber que as faces 1 e 3 são simetricamente inversas uma da outra e a face 2 tem todos os seus atributos “padrões”, onde os valores de f_2^L estão no “meio” de f_1^L e f_3^L . Podemos também perceber que a face 4 não difere muito da face 2.




Figura 1. Gráfico faces para uma área de interesse A .

O *Z-profile* é uma representação gráfica de um único pixel, isto é, dado $f(s)$ desenhamos $(\ell, f^\ell(s))$. Este gráfico é utilizado, na cor vermelha, nas visualizações mostradas nas figuras **Figura 5** e **6**.

O gráfico de barras de erro (ver **Figura 5**) requer a definição de uma área de interesse A com pelo menos duas coordenadas, e de uma coordenada pivotal $s \in A$. Desenha-se o *Z-profile* do pixel $f(s)$, e em cada ponto $(\ell, f^\ell(s))$ acrescenta-se uma barra vertical centrada no ponto estendendo-se uma distância $\alpha \hat{\sigma}_A^\ell$ em cada sentido, sendo $\alpha > 0$ estipulado pelo usuário e $\hat{\sigma}_A^\ell$ o desvio padrão amostral de f_A^ℓ .

O *box plot* (ver **Figura 4**) é uma representação gráfica similar à anterior, porém mais completa. É um gráfico em formato de caixa, cujos limites são o primeiro quartil $f_{A, [n/4]:n}$ e o terceiro quartil $f_{A, [3n/4]:n}$, com uma linha na posição da mediana $f_{A, [n/2]:n}$. Existem também

dois eixos ligados à caixa estendendo-se aos extremos, isto é, ao menor e ao maior valor dos dados, excluindo os valores discrepantes (*outliers*).

Uma variante do *box plot* com mais informações é o *box percentile plot*. O *box percentile plot* exibe nas suas laterais a mesma informação exibida pelo *percentile plot*. O *percentile plot* exibe as informações obtidas pela função de distribuição cumulativa empírica. O *box percentile plot* apresenta duas vantagens sobre o *box plot*, a primeira é que não é necessário determinar como o gráfico deverá ser desenhado, pois a configuração é dada pela distribuição empírica dos dados. Outra vantagem é que o *box percentile plot* usa a largura da caixa para mostrar informações sobre a distribuição dos dados. Assim como no *box plot*, o *box percentile plot* também exibe a mediana $f_{A, [n/2]:n}$, o primeiro quartil $f_{A, [n/4]:n}$ e terceiro quartil $f_{A, [3n/4]:n}$. O *box percentile plot* pode ser visto na **Figura 4**.

O diagrama de estrelas (*stars*) é uma representação gráfica do pixel f_s^L que consiste em desenhar segmentos coloridos radiais uniformemente espaçados, sendo que o comprimento de cada um deles é proporcional a uma banda. Uma representação do gráfico estrela pode ser vista na **Figura 3**. Geralmente o diagrama de estrelas é usado para examinar o comportamento das bandas do pixel f_s^L .

Outro gráfico utilizado em nosso trabalho foi o dendograma (ver **Figura 7**). Este gráfico é utilizado para exibir agrupamentos hierárquicos de dados. Os agrupamentos hierárquicos de dados têm como objetivo agrupar indivíduos de acordo com os atributos em comum, de acordo com uma métrica de similaridade previamente selecionada. Restringindo uma região da imagem f_A , com $\#A > 1$, teremos um conjunto de pixels $f(s)$, assim, os métodos hierárquicos não constroem uma única partição com k grupos, mas lidam com todos os valores de k dentro do intervalo $1 \leq k \leq n$, onde n é o número de pixels $f(s)$. Isto é, a partição com $k = 1$ (todos os pixels $f(s)$ no mesmo grupo) é parte do resultado geral do algoritmo, como também a situação com $k = n$ (cada objeto forma um grupo separado com um único elemento). Todos os valores de $k = \{2, 3, 4, \dots, n-1\}$ passam por uma transição gradual. O agrupamento de dados aplicado a imagens é também conhecido como segmentação de imagens.

Neste trabalho usamos seis tipos de gráficos: barras de erros, *box plot*, *box percentil plot*, diagrama de estrelas (*stars*), *faces* e dendograma. Nas seções seguintes apresentamos o pacote `rHiper` e o seu uso.

4. O pacote `rHiper`

O pacote `rHiper` foi proposto devido a necessidade e a escassez de ferramentas de análise descritiva multivariada em imagens hiperespectrais em plataformas computacionais livres.

Nosso pacote implementa os gráficos mais utilizados na análise descritiva multivariada. Os gráficos implementados foram citados e comentados na seção 1. O `rHiper` foi desenvolvido utilizando a linguagem R, uma linguagem não tipada que oferece as principais estruturas de programação utilizada no paradigma estruturado. O pacote foi desenvolvido seguindo os padrões de interação observados em vários softwares de análise multivariada de imagens multiespectrais e hiperespectrais, dentre eles o ENVI (SulSoft (2006)) e o MultiSpec (Biehl e Landgrebe (2002)). Essa analogia entre interfaces é comumente adotado em novos softwares que visam refazer ou complementar funcionalidades já existentes no mercado. O objetivo deste método é minimizar o impacto da utilização de um software familiarizado para um novo software.

5. Uso do Pacote e Exemplos

O pacote `rHiper` é manipulado através de uma interface gráfica e por modo texto. Através destas interfaces é possível usufruir de todas as ferramentas implementadas no pacote.

A visualização de imagens AVIRIS (ver **Figura 2**) é constituída de apenas 2 passos: a leitura da imagem através da função `limage` e a leitura da cena a ser visualizada utilizando a função `lscene`. Nosso pacote oferece duas formas de visualizar as imagens hiperespectrais, uma em tons de cinza e outra em RGB (Red, Green, Blue). Para a visualização da imagem em tons de cinza é necessário a leitura de apenas uma banda e para a visualização em RGB é necessária a leitura de 3 bandas. Para a leitura de uma imagem AVIRIS utilizamos o seguinte trecho de código:

```
>library(rHiper)
>moffet<-limage("f970620t01p02_r03.a", "reflectance")
>moffetScene2<-lscene(moffet, 2)
```

A primeira linha carrega o nosso pacote. A segunda linha é utilizada para a leitura da imagem AVIRIS, através da função `limage`, que recebe como parâmetros o nome e o tipo da imagem. A terceira linha chama a função `lscene` cujo objetivo é carregar a cena 2 da imagem anteriormente lida. Como citado anteriormente, podemos visualizar a imagem de duas maneiras, em tons de cinza e em RGB. Para a visualização da imagem em RGB utilizamos as seguintes linhas de código:

```
>b25<-lband(moffetScene2, 25)
>b15<-lband(moffetScene2, 15)
>b5<-lband(moffetScene2, 5)
```

A leitura das bandas é implementada através da função `lband`, onde o nome da cena e a banda a ser carregada são recebidos como parâmetros. Para a visualização das bandas carregadas é necessário apenas o uso da função `plot`.

```
>plot(b5, b15, b25)
```

Para a construção dos gráficos utilizados na análise multivariada é utilizado a função `analysis`.

```
>analysis(moffetScene2, band=c(5,15,85,48), interval=c(25,50)
)
```

Através da chamada desta função é construída uma interface gráfica, onde é possível fazer a seleção de quais gráficos devem ser plotados utilizando as bandas selecionadas através do parâmetro `band` ou estipulando um intervalo de bandas determinado pelo parâmetro `interval`.


Como exemplo, iremos fazer uma análise com os dados coletados nas regiões *A* e *B* com intervalo de bandas [5 : 20]. As regiões *A* e *B* têm dimensão 3×3 . Na **Figura 2** podemos visualizar a imagem AVIRIS com as regiões *A* e *B* selecionadas. A **Figura 3** mostra o gráfico de estrelas para as regiões *A* (ver Figura 3(a)) e *B* (ver Figura 3(b)) utilizando o intervalo de bandas [5 : 20]. Podemos perceber que as duas regiões tem valores de banda bem diferentes em seus 9 pixels.

Foram utilizados também na análise os gráficos *box plot*, *box percentile plot* e o gráfico de barras de erro utilizando o intervalo $[5, 20]$ de bandas. O *box plot* e o *box percentile plot* das regiões *A* e *B* são representados através das **Figuras 4 e 6** respectivamente. Os gráficos de barras de erro das regiões *A* e *B* são representados respectivamente pelas **Figuras 5(a) e 5(b)**.

Outro gráfico também utilizado na nossa análise foi o dendograma. O dendograma representado pela **Figura 7** mostra o quanto cada pixel presente na região *A* é próximo a outro pixel, cuja métrica de similaridade utilizada foi a euclidiana.



Figura 2. Imagem AVIRIS com as regiões *A* e *B* selecionadas



(a) Gráfico de estrelas da região *A*

(b) Gráfico de estrelas da região *B*

Figura 3. Gráfico de estrelas das regiões *A* e *B*

6. Conclusões

Através da análise multivariada podemos correlacionar, controlar, visualizar e medir todas as bandas presentes em uma imagem hiperespectral. Para satisfazer esses requisitos foi proposto um pacote para o ambiente R que implementa ferramentas utilizadas na análise multivariada

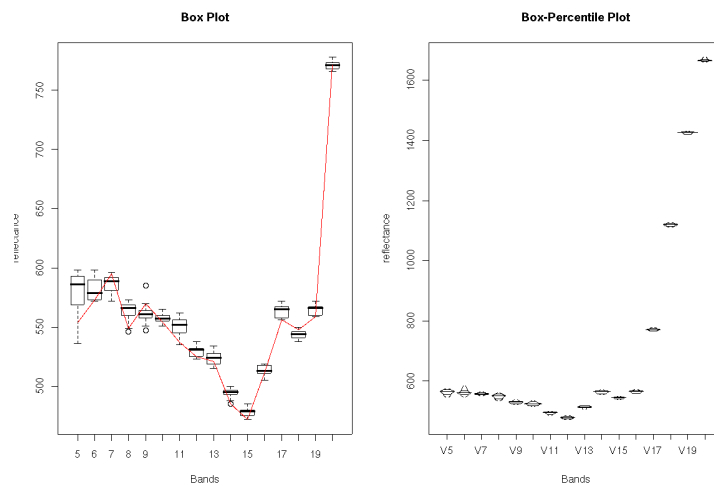
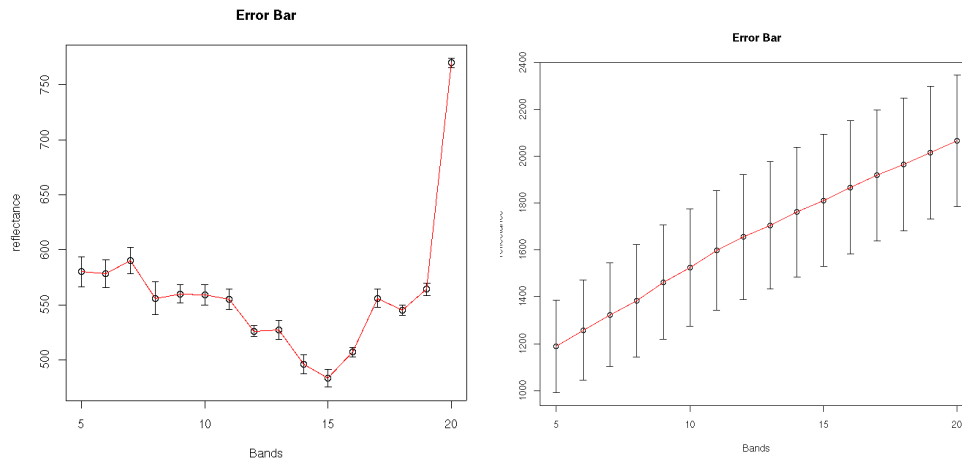


Figura 4. Box Plot e Box Percentile Plot da região A



(a) Gráfico de barras de erro da região A

(b) Gráfico de barras de erro da região B

Figura 5. Gráfico de barras de erro das regiões A e B

com o uso em imagens hiperespectrais. Utilizando o pacote `rHiper` podemos ler imagens AVIRIS e construir de forma fácil e intuitiva os mais diferentes gráficos utilizados na análise descritiva multivariada.

7. Agradecimentos

Agradecemos a Natália Soares, colaboradora do projeto VATAPA e ao CNPq.

Referências

- Biehl, L. e Landgrebe, D. MultiSpec: a tool for multispectral-hyperspectral image data analysis, **Computers & Geosciences** v.28(10), 1153–1159, 2002.
- Debba, P., van Ruitenbeek, F., van der Meer, F., Carranza, E. e Stein, A. Optimal field sampling for targeting minerals using hyperspectral data, **Remote Sensing of Environment** v.99, 373–386, 2005.
- Everitt, B. S., Landau, S. e Leese, M. **Cluster Analysis**, 4 ed., Arnold, 2001.
- Figueira, R. **Mineração de Dados e Bancos de Dados Orientados a Objetos**, 1998, Dissertação (Mestrado), Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ. Disponível em: <http://www.cos.ufrj.br/~rafael/mestrado/bdnc/monografia.pdf%range>.




Figura 6. Box Plot e Box Percentile Plot da região B




Figura 7. Dendrograma da região B

Hornik, K. (2002), The R Project for Statistical Computing. Disponível em: <http://www.r-project.org>, última consulta em outubro de 2006.

Jain, A. K. **Fundamentals of Digital Image Processing**, Prentice-Hall International Editions, Englewood Cliffs, NJ, 1989.

Kaufman, L. e Rousseeuw, P. J. **Finding Groups in Data**, Wiley & Sons, New York, 1990.

Lira Chávez, J. **Introducción al Tratamiento Digital de Imágenes**, Ciencia de la Computación, Instituto Politécnico Nacional, México, DF, 2002.

SulSoft (2006), Environment for Visualizing Images. Disponível em: <http://www.envi.com.br>, última consulta em outubro de 2006.

Tsai, F. e Philpot, W. Derivative analysis of hyperspectral data, **Remote Sensing of Environment** v.66, 41–51, 1998.

Vane, G., Green, R. O., Chrien, T. G., Enmark, H. T., Hansen, E. G. e Porter, W. M. The Airborne Visible Infrared Imaging Spectrometer (AVIRIS), **Remote Sensing of Environment** v.44(2-3), 127–143, 1993.

Wang, Q., Shu, J. e Yin, Q. DSGF method on detecting and removing spectral noise of hyperspectral image, **Journal of Infrared and Millimeter Waves** v.25, 29–32, 2006.