

Funções discriminantes para diferenciação de agricultura e floresta em imagem multiespectral adquirida com câmara baseada no Interferômetro de Fabry-Perot

Gabriela Takahashi Miyoshi^{1,2}
Vilma Mayumi Tachibana²
Nilton Nobuhiro Imai²
Enner Herênio de Alcântara²
Antonio Maria Garcia Tommaselli²

¹Programa de Pós Graduação em Ciências Cartográficas - PPGCC

²Departamento de Cartografia

Universidade Estadual Paulista - Unesp

Rua Roberto Simonsen, 305 – 19060-900 – Presidente Prudente - SP, Brasil

takahashi.gabi@gmail.com, {vilma,nnimai,enner,tomaseli}@fct.unesp.br

Abstract. The objective of this work is present the potential of the novel hyperspectral camera based on Fabry-Perot Interferometer applying multivariate statistical techniques. This camera was developed to be used in unmanned aerial vehicles and differs of the others hyperspectral sensors for being a frame sensor instead of a linear sensor, also is possible to configure the number and resolution for the spectral bands. An image from Evo, in Finland, was provided by Finnish researchers this image has 24 spectral bands from 500 – 780 nm with a ground sample distance of 15 cm approximately. Due to lack of information and noise in some spectral bands, only 16 spectral bands were used for cluster and principal components analysis followed by discriminant analysis to separate targets present in the image, agriculture and forest. The spectral bands were matched and 41 samples of the targets had their digital number collected in the spectral bands and were used to calculate discriminant functions, validated with 18 other samples of the image. About the validation, only one sample was misclassified, one target from the class agriculture was classified as forest, representing only 5.56% of confusion. This experiment shows the potential for discriminate targets and moreover, the use of multivariate statistical techniques in the images acquired with this camera.

Palavras-chave: hyperspectral camera, unmanned aerial vehicle, multivariate statistical techniques, câmara hiperespectral, veículo aéreo não tripulado, técnicas de estatística multivariada.

1. Introdução

Desenvolvida pelo VTT Centro de Pesquisa Técnico da Finlândia, a câmara hiperespectral baseada no Interferômetro de Fabry-Perot (FPI) tem como características principais a aquisição de imagens em diferentes comprimentos de onda configuráveis conforme a aplicação do usuário (Saari et al, 2009; Mäkynen et al., 2011). As bandas são definidas por meio da configuração do espaço entre os espelhos do interferômetro, controlado com acurácia nanométrica por meio de atuadores piezoelétricos selados hermeticamente em um recipiente metálico.

Tal câmara foi desenvolvida para ser acoplada em Veículos Aéreos Não Tripulados (VANTs) possuindo um sistema relativamente leve, menor que 700 g (Honkavaara et al., 2013). Ao contrário da maioria dos sensores hiperespectrais (Hyperion, Aviris, Casi-1500) que são lineares, esta câmara possui sensor de quadro, o que permite uma geometria mais estável nas imagens adquiridas.

Para extração de informação de imagens adquiridas com tal câmara, é possível a aplicação de diversas técnicas, dentre elas a análise discriminante, uma técnica de análise multivariada muito empregada em sensoriamento remoto como, por exemplo, na diferenciação de tipos de solos (Nanni et al., 2005) e na discriminação de classes de vegetação (Freitas e Cruz, 2005).

O objetivo deste trabalho é avaliar o potencial da câmara hiperespectral do Centro de Pesquisa Técnico da Finlândia (VTT), em diferenciar classes de cobertura da terra.

2. Materiais e Métodos

A imagem utilizada neste trabalho foi obtida na cidade de Evo ($\varphi = 61^{\circ}11'10''$, $\lambda = 25^{\circ}07'08''$), localizada na Finlândia, sendo cortesia dos pesquisadores do Instituto Geodésico Finlandês (FGI). Tal imagem foi adquirida com a câmara hiperespectral baseada no Interferômetro de Fabry-Perot, sendo configuradas 24 bandas espectrais entre 500 – 780 nm com um tamanho de pixel no terreno (GSD - *Ground Sample Distance*) de aproximadamente 15 cm.

O fluxograma apresentado na Figura 1 apresenta as etapas da metodologia utilizada para realização do trabalho.




Figura 1 - Fluxograma de atividades.

Para seleção das bandas espectrais foi adotado o critério de presença de ao menos 95% da imagem sem pixels nulos e imagens com menor quantidade de ruídos.

O registro de imagens foi realizado no programa ArcMap 10.0, por meio de uma transformação afim 2D. A banda 6 foi utilizada como banda de referência por se tratar da banda que corresponde ao tempo médio da aquisição das imagens (Oliveira et al., 2014). Foi utilizado o mínimo de cinco pontos em cada imagem sendo que o critério de aceitação da transformação foi baseado num erro médio quadrático menor do que 1 pixel. A equação da transformação afim que relaciona os pixels (x, y) da imagem a ser registrada com os pixels (x', y') da imagem de referência é apresentada em (1) (Andrade, 1998):

$$\begin{bmatrix} x' \\ y' \end{bmatrix} = \begin{bmatrix} a & b \\ c & d \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} + \begin{bmatrix} e \\ f \end{bmatrix} \quad (1)$$

Onde a, b, c e d são parâmetros que combinam dois fatores de escala (um para cada eixo do sistema de coordenadas imagem que será transformado), uma rotação e um fator de não ortogonalidade entre os eixos deste sistema de coordenadas. Os parâmetros e e f correspondem às translações entre os eixos dos sistemas da imagem de referência e o transformado.

Após o registro das imagens, foi realizado o recorte da área de interesse com o intuito de evitar erros na análise de agrupamento e componentes principais caso áreas com pixels nulos restassem nas imagens.

Devido à alta correlação e sobreposição entre as bandas espectrais, foi aplicada a análise discriminante a partir de observações feitas por dois métodos: o primeiro a partir da média dos valores de ND de bandas espectrais selecionadas por meio da análise de agrupamento, e o segundo a partir dos valores de ND das componentes principais mais significativas do conjunto de dados.

Para o agrupamento das bandas espectrais, foi utilizada como medida de similaridade a matriz de correlação entre elas, calculada pelo programa Envi 5.1; sendo então, aplicado o método de Ligação Simples para formação dos grupos (clusters). Neste método, os elementos mais semelhantes são agrupados, ou seja, os elementos que possuem menor distância entre si formam um novo grupo e uma nova matriz de distância é calculada a cada passo do algoritmo (Mingoti, 2005; Johnson e Wichern 2007). A determinação do número de grupos utilizados para a análise discriminante seguiu o critério descrito por Mingoti (2005). O número de grupos é definido quando a variação do coeficiente de fusão, distância ou semelhança entre os grupos, não apresenta mudança significativa conforme o aumento do número de grupos.

Outra forma de aplicação da análise discriminante foi baseada numa imagem gerada pela análise de componentes principais (PCA - *Principal Component Analysis*) que segundo Johnson e Wichern (2007) tem como objetivo explicar a estrutura da matriz de variância covariância de p variáveis aleatórias e permite a interpretação destas a partir de k ($k < p$) componentes principais.

Os componentes principais são combinações lineares que relacionam os autovetores (e) da matriz de variância covariância (Σ) dos dados originais com as respectivas observações (X), e que também podem ser calculados a partir da matriz de correlação das variáveis. O cálculo dos componentes principais é apresentado a seguir (Johnson e Wichern, 2007):

$$\begin{aligned} Y_1 &= e_{11}X_1 + e_{12}X_2 + \dots + e_{1p}X_p \\ Y_2 &= e_{21}X_1 + e_{22}X_2 + \dots + e_{2p}X_p \\ &\vdots \\ Y_p &= e_{p1}X_1 + e_{p2}X_2 + \dots + e_{pp}X_p \end{aligned} \quad (2)$$

Para a escolha do número de componentes principais a serem utilizados na análise discriminante foi adotado o critério da análise do *scree plot* (Mingoti, 2005). Esse critério de decisão é similar ao critério de decisão do número de elementos da análise de agrupamento onde se analisa graficamente a porcentagem de variância explicada por cada componente principal *versus* cada autovalor, o componente principal cujo valor passa a ter valor próximo do eixo das abcissas representa a linha de corte, ou seja, qual o número de componentes a ser utilizado.

A análise discriminante é uma técnica que permite a separação de objetos pertencentes a diferentes populações ou amostras. Diferente da análise de agrupamento, as classes são determinadas previamente e a partir de elementos amostrais conhecidos sendo possível calcular uma função discriminante para diferenciar, classificar, novos objetos (Mingoti, 2005; Johnson e Wichern, 2007).

Considerando duas populações (π_1 e π_2) com matrizes de variância covariância (Σ_1 e Σ_2) e médias diferentes (μ_1 e μ_2), as funções quadráticas discriminantes para cada classe são (Johnson e Wichern, 2007) :

$$\begin{aligned} R_1: -\frac{1}{2}x'(\Sigma_1^{-1} - \Sigma_2^{-1})x + (\mu_1'\Sigma_1^{-1} - \mu_2'\Sigma_2^{-1})x - k &\geq \ln \left[\left(\frac{c(1|2)}{c(2|1)} \right) \left(\frac{p_2}{p_1} \right) \right] \\ R_2: -\frac{1}{2}x'(\Sigma_1^{-1} - \Sigma_2^{-1})x + (\mu_1'\Sigma_1^{-1} - \mu_2'\Sigma_2^{-1})x - k &< \ln \left[\left(\frac{c(1|2)}{c(2|1)} \right) \left(\frac{p_2}{p_1} \right) \right] \end{aligned} \quad (3)$$

$$k = \frac{1}{2} \ln \left(\frac{|\Sigma_1|}{|\Sigma_2|} \right) + \frac{1}{2} (\mu_1'\Sigma_1^{-1}\mu_1 - \mu_2'\Sigma_2^{-1}\mu_2) \quad (4)$$

Onde:

x é o vetor que contém as observações;

$c(1|2)$ é o custo esperado de classificar erroneamente o objeto pertencente à π_1 em π_2 ;

$c(2|1)$ é o custo esperado de classificar erroneamente o objeto pertencente à π_2 em π_1 ;

p_1 e p_2 são as probabilidades de se classificar corretamente as observações em suas

respectivas populações.

Considerando as funções quadráticas das populações 1 e 2, a observação x_0 é alocada em π_1 se:

$$-\frac{1}{2}x_0'(\Sigma_1^{-1} - \Sigma_2^{-1})x_0 + (\mu_1'\Sigma_1^{-1} - \mu_2'\Sigma_2^{-1})x_0 - k \geq \ln \left[\left(\frac{c(1|2)}{c(2|1)} \right) \left(\frac{p_2}{p_1} \right) \right] \quad (5)$$

Caso contrário, x_0 é alocada em π_2 .

Com o Envi 5.1 foram coletados os valores de número digital (ND) de 41 elementos amostrais de objetos pertencem às classes de agricultura e vegetação. As amostras foram escolhidas de forma que estivessem bem distribuídos em toda a imagem. Foram utilizados os mesmos pontos para as duas análises discriminantes para comparação dos resultados.

Para validação das funções discriminantes foram utilizados 12 elementos amostrais distribuídos aleatoriamente na imagem sendo única exigência que estivessem localizados em área de agricultura ou floresta para os erros no cálculo das funções fossem minimizados.

3. Experimentos e resultados

O cálculo da porcentagem dos pixels sem informação radiométrica foi realizado por meio de uma rotina no Matlab, sendo que os resultados são apresentados na Tabela 1.

Tabela 1 - Porcentagem de pixels nulos em cada banda espectral da imagem.

Banda	1	2	3	4	5	6	7	8	9	10	11	12
Pixels sem informação (%)	55,58	96,15	0	3,14	0	3,19	1,87	1,91	32,47	1,77	0,03	0,74
Banda	13	14	15	16	17	18	19	20	21	22	23	24
Pixels sem informação (%)	2,16	1,71	4,47	5,73	2,27	3,56	8,19	8,76	32,83	7,61	1,98	3,44

Desta forma, foram selecionadas as bandas apresentadas na Tabela 2, que também apresenta o comprimento de onda central e a resolução espectral referente à largura completa à metade do máximo (FWHM – Full Width Half Maximum) de cada banda. Apesar da banda 12 apresentar apenas 0,74% de pixels nulos, esta banda não foi utilizada devido à alta presença de ruídos como ilustrado na Figura 1.

Tabela 2- Bandas utilizadas e respectivos comprimentos de onda centrais e FWHM.

Banda	3	4	5	6	7	8	10	11
λ (nm)	509,40	516,20	521,20	526,30	527,00	538,90	549,60	551,60
FWHM (nm)	12,82	19,08	14,61	21,71	17,11	22,18	17,51	21,92
Banda	13	14	15	16	17	18	23	24
λ (nm)	571,00	593,80	608,40	614,70	628,00	699,50	726,70	757,80
FWHM (nm)	32,32	22,99	30,92	28,89	30,15	13,01	20,01	26,69




Figura 1 - Banda 12 da imagem multiespectral que não foi utilizada para a análise discriminante devido à alta presença de ruídos.

Após o registro das bandas da imagem, cujo RMSE foi menor do que 1 pixel, foi feito o recorte da área de interesse, pois algumas bandas apresentavam pixels sem informações do terreno, resultando em uma imagem com 821 x 521 pixels.

Os 41 pontos utilizados para cálculo das funções discriminantes e 18 pontos utilizados para validação são apresentados na Figura 3.




Figura 2 - Pontos amostrais utilizados para cálculo e validação das funções discriminantes.

Devido a alta correlação e sobreposição entre as bandas espectrais, foi aplicada a análise de agrupamento pelo método de Ligação Simples, utilizando a matriz de correlação como medida de similaridade, gerando 5 grupos (Figura 4). Em seguida foi realizada a análise de discriminante utilizando como variáveis as respostas médias dos ND das bandas pertencentes a cada grupo. Os resultados são sumarizados na Tabela 3, onde é possível observar que não houve confusão ente as classes.

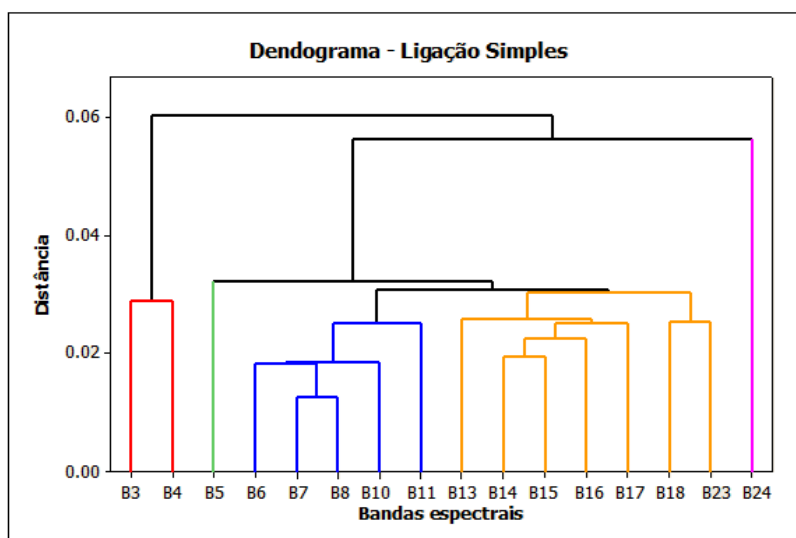


Figura 3 - Análise de agrupamento das bandas espectrais.

Tabela 3 - Resumo da análise discriminante feita a partir do conjunto de dados proveniente da análise de agrupamento.

		Classe verdadeira		
		Agricultura	Floresta	Total
Classificado na classe	Agricultura	26	0	26
	Floresta	0	15	15
	Total	26	15	41

A função discriminante para alocar a observação na classe agricultura considerando probabilidades e custo de erro de classificação equivocada iguais é apresentada em (8), onde é possível notar que a matriz de diferença das variâncias e covariâncias entre as classes é quase nula.

$$\frac{1}{2}x_0' \begin{bmatrix} -0,0048 & 0,0024 & 0,0009 & 0,0024 & 0,0013 \\ 0,0024 & -0,008 & 0,009 & -0,0011 & -0,0021 \\ 0,0009 & 0,0009 & 0,0019 & -0,0029 & 0,0004 \\ 0,0024 & -0,0011 & -0,0029 & 0,0009 & -0,0019 \\ 0,0013 & -0,0021 & 0,0004 & -0,0019 & 0,0031 \end{bmatrix} x_0 + \begin{bmatrix} 0,2057 \\ -0,0700 \\ 0,1955 \\ -0,1690 \\ 0,0391 \end{bmatrix}' x_0 - 0,1946 \geq 0 \quad (6)$$

Fazendo a validação desta função discriminante, foram utilizados 18 pontos, onde 12 destes pertencem à classe agricultura e o restante à classe floresta. O resumo da classificação é apresentado a seguir (Tabela 4), onde é apresentada a probabilidade do objeto ser classificado nas classes agricultura e floresta e a classe real do objeto. Verifica-se que apenas um ponto pertencente à classe agricultura foi classificado como floresta.

Tabela 4 - Resultado da classificação dos dados para validação da análise discriminante feita a partir da análise de agrupamento.

Probabilidade de ser classificado como		Classe verdadeira	Probabilidade de ser classificado como		Classe verdadeira
Agricultura	1,00	Agricultura	Agricultura	1,00	Agricultura
Floresta	0,00		Floresta	0,00	
Agricultura	0,97	Agricultura	Agricultura	1,00	Agricultura
Floresta	0,03		Floresta	0,00	
Agricultura	0,04	Agricultura	Agricultura	1,00	Agricultura
Floresta	0,96		Floresta	0,00	
Agricultura	0,98	Agricultura	Agricultura	0,02	Floresta
Floresta	0,02		Floresta	0,98	
Agricultura	1,00	Agricultura	Agricultura	0,00	Floresta
Floresta	0,00		Floresta	1,00	
Agricultura	1,00	Agricultura	Agricultura	0,00	Floresta
Floresta	0,00		Floresta	1,00	
Agricultura	1,00	Agricultura	Agricultura	0,00	Floresta
Floresta	0,00		Floresta	1,00	
Agricultura	1,00	Agricultura	Agricultura	0,13	Floresta
Floresta	0,00		Floresta	0,88	
Agricultura	0,99	Agricultura	Agricultura	0,01	Floresta
Floresta	0,01		Floresta	0,99	

A análise de componentes foi feita a partir da matriz de correlação das imagens (Almeida e Meneses, 2012) resultando nos autovalores apresentados em 5.

Tabela 5 – Autovalores e variância acumulada das bandas espectrais.

Nº. do autovalor	1	2	3	4	5	6	7	8
Autovalor	14,82	0,61	0,13	0,09	0,09	0,06	0,04	0,03
Var. acumulada	92,64%	96,47%	97,28%	97,84%	98,37%	98,74%	98,97%	99,16%
Nº. do autovalor	9	10	11	12	13	14	15	16
Autovalor	0,02	0,02	0,02	0,02	0,02	0,01	0,01	0,01
Var. acumulada	99,31%	99,46%	99,59%	99,70%	99,80%	99,88%	99,94%	100%

A análise discriminante foi utilizada nas três primeiras componentes principais, que representam 97,28% da variabilidade total dos dados, com os mesmos pontos utilizados anteriormente, porém com os respectivos valores das imagens resultantes da análise de componentes principais, os resultados são apresentados na Tabela 7.

Tabela 6 - Resumo da análise discriminante feita a partir do conjunto de dados proveniente da análise de componentes principais.

		Classe verdadeira		
		Agricultura	Floresta	Total
Classificado na classe	Agricultura	26	2	28
	Floresta	0	13	13
	Total	26	15	41

Diferente da primeira função discriminante (8) nota-se que nesta função (9) a diferença entre as matrizes de variância covariância das classes é maior. A função calculada para alocar uma nova observação na classe agricultura considerando probabilidades de ocorrência e custos iguais considerando a análise discriminante a partir de componentes principais da imagem é:

$$-\frac{1}{2}x_0'10^{-3} \begin{bmatrix} 0,0333 & -0,1221 & -0,1281 \\ -0,1221 & -0,6626 & -0,3975 \\ -0,1281 & -0,3975 & 0,4110 \end{bmatrix} x_0 + [-0,0309 \quad -0,0422 \quad 0,0297]x_0 - 2,4865 \geq 0 \quad (7)$$

Para validação da função discriminante, 18 pontos amostrais distribuídos entre as classes de agricultura e floresta na imagem foram utilizados e os resultados são apresentados na Tabela 8. Novamente é observado que apenas um ponto foi alocado na classe diferente a qual realmente pertence e que se trata do mesmo ponto classificado erroneamente na primeira análise discriminante.

Tabela 7 - Resultado da classificação dos dados para validação da análise discriminante feita a partir da análise de componentes principais.

Probabilidade		Classe verdadeira	Probabilidade		Classe verdadeira
Agricultura	Floresta		Agricultura	Floresta	
1,00	0,00	Agricultura	Agricultura	1,00	Agricultura
0,98	0,02	Agricultura	Agricultura	1,00	Agricultura
0,12	0,88	Agricultura	Agricultura	1,00	Agricultura
0,83	0,17	Agricultura	Agricultura	0,01	Floresta
1,00	0,00	Agricultura	Agricultura	0,00	Floresta
1,00	0,00	Agricultura	Agricultura	0,14	Floresta
1,00	0,00	Agricultura	Agricultura	0,00	Floresta
1,00	0,00	Agricultura	Agricultura	0,27	Floresta
0,90	0,10	Agricultura	Agricultura	0,01	Floresta

Para as duas funções discriminantes, a porcentagem de erro na validação das mesmas foi de 5,56%, pois dos 18 alvos utilizados para validação, apenas um foi classificado equivocadamente.

4. Conclusão

O cálculo das funções para diferenciar objetos pertencentes às classes agricultura e floresta de uma imagem multiespectral foi realizado com êxito, sendo que a técnica de análise discriminante se mostrou muito eficiente.

Devido a alta correlação entre as bandas espectrais não é possível a aplicação direta da análise discriminante utilizando todas as bandas sendo necessário o pré-processamento da imagem com as técnicas de agrupamento ou componentes principais para posterior análise discriminante.

Por fim, é possível afirmar o potencial desta câmara hiperespectral, além da geometria de quadro e possibilidade de configuração de bandas espectrais, para diferenciar tipos de cobertura da terra utilizando imagens de tal câmara aliadas com técnicas de análise multivariada.

Agradecimentos

Os autores agradecem ao *Finnish Geodetic Institute* pela cessão da imagem utilizada neste trabalho e ao CNPq pelo apoio a esta pesquisa em forma de uma bolsa de mestrado.

Referências

Andrade, J. B. **Fotogrametria**. Curitiba: SBEE, 1998. 258p.

Freitas, S, R; Cruz, C, B, M. Análise de Componentes Principais e Modelo Linear de Mistura na discriminação de classes de vegetação na Mata Atlântica. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 2005, Goiânia. **Anais...** São José dos Campos: INPE, 2005. Artigos, p. 1529-1536. Disponível em: <<http://marte.sid.inpe.br/col/ltid.inpe.br/sbsr/2004/11.04.11.55/doc/1529.pdf>>. Acesso em: 22 out. 2014.

Johnson, R. A.; Wichern, D. W. **Applied Multivariate Statistical Analysis**. Prentice Hall, 2007. 773p.

Honkavaara, E. Saari, H.; Kaivosoja, J.; Pölönen, I.; Hakala, T.; Litkey, P.; Mäkynen, J.; Pesonen, L. Processing and Assessment of Spectrometric, Stereoscopic Imagery Collected Using a Lightweight UAV Spectral Camera for Precision Agriculture. **Remote Sensing**, v. 5, n. 10, p. 5006–5039, 2013.

Mäkynen, J.; Holmlund, C.; Saari, H.; Ojala, K.; Antila, T. Unmanned aerial vehicle (UAV) operated megapixel spectral camera. **Proc. SPIE 8186, Electro-Optical Remote Sensing, Photonic Technologies, and Applications V**, v. 8186. 2011

Mingoti, S. A. **Análise de dados através de métodos de estatística multivariada: uma abordagem aplicada**. UFMG, 2005. 297p.

Nanni, M, R.; Demattê, J. A. M.; Fiorio, P. R. Resposta espectral na análise discriminante dos solos. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 2005, Goiânia. **Anais...** São José dos Campos: INPE, 2005. Artigos, p. 407 - 414. Disponível em: <<http://marte.sid.inpe.br/col/ltid.inpe.br/sbsr/2004/11.20.12.20/doc/407.pdf>>. Acesso em: 22 out. 2014.

OLIVEIRA, R, A; Tommaselli, A. M. G.; Imai, N. N.; Honkavaara, E.; Hyypä, H; Hakala, J.; Jaakkola, A. Avaliação do corregristo de imagens coletadas por uma câmara hiperespectral de quadro. In: Congresso Brasileiro de Cartografia (CBC), 2014, Gramado. **Anais...** Sociedade Brasileira de Cartografia, 2014. Disponível em: <http://www.cartografia.org.br/cbc/trabalhos/4/585/CT04-98_1404422611.pdf>. Acesso em: 22 out. 2014.

Saari, H.; Aallos, V.; Akujärvi, A.; Antila, T.; Holmlund, C.; Kantojärvi, U.; Mäkynen, J.; Ollila, J. Novel miniaturized hyperspectral sensor for UAV and space applications. **Proc. SPIE 7474, Sensors, Systems, and Next-Generation Satellites XIII**, v. 7474. 2009