

Influência das Incertezas nas Análises de Mudanças de Uso do Solo a partir de Classificações de Imagens multiespectrais

Mauro José Alixandrini ¹

Hans-Peter Bähr ²

¹ Universidade de Karlsruhe (TH)
76128 Karlsruhe/Alemanha
Mauro.Alixandrini@ipf.uni-karlsruhe.de

² Universidade de Karlsruhe (TH)
76128 Karlsruhe/Alemanha
Hans-Peter.Baehr@ipf.uni-karlsruhe.de

Resumo: Com a popularização do GIS, dados geográficos são frequentemente utilizados como suporte a decisões. Portanto terminam por influir cada vez mais na tomada de decisões. Por outro lado a informação disponível para o GIS é frequentemente dissociada de informações a respeito de sua qualidade, caso que é comum às classificações de imagens multiespectrais, pois os avaliadores globais não relacionam de forma direta com a imagem o seu resultado. A proposta é criar uma avaliação que possa ser associada à resposta (imagem classificada) na forma de uma banda adicional. Neste estudo, o foco é a acurácia temática. Serão apresentados testes que associam a mudança de uso do solo baseando-se numa imagem de incerteza derivada da classificação de máxima verossimilhança. Serão avaliadas as implementações desta metodologia em pequenas áreas derivadas de imagens multiespectrais do satélite Landsat ETM.

Palavras chaves: Classificação, Imagens multiespectrais, Mudanças de uso do solo.

Abstract: With the increasing popularity of GIS, geographic data in GIS are often being used to support policy decisions. Since no information about quality of the data is normally available, it is assumed that the data are free of errors. In a GIS, the data is usually stored in terms of objects instead of individual pixels. To this end, the classification result has to be segmented. An important aspect of this research is the propagation of the uncertainty of a pixel belonging to a class to the uncertainty of the pixel belonging to a region. Different approaches for uncertainty evaluation will be presented, that take the thematic uncertainty of the pixels into account. They will be applied and verified to a small test area. The comparison among the statistical methods was performed by controlling the classification process, that is, using deterministic samples for the training of discriminant functions and test images of Landsat ETM sensor.

Keywords: Classification, Multispectral images, Land-use change.

1 Introdução

O GIS (*Geographic Information System*), em português SIG (Sistema de informação geográfica), se difunde atualmente pelas mais diversas áreas de conhecimento que utilizam dados geográficos como suporte à decisões. Por sua vez, influenciam cada vez mais na tomada de decisões (FOODY, CURRAN, 1994). Por outro lado, os dados disponíveis para os GIS são frequentemente dissociados de informações a respeito de sua qualidade, caso que é comum às classificações de imagens multiespectrais, pois os avaliadores globais não relacionam de forma direta a imagem ao seu resultado. Uma avaliação que pudesse ser associada à resposta (imagem classificada) na forma de uma banda adicional seria uma alternativa interessante para tal problema. Quando não se consideram tais informações a respeito da qualidade, assume-se que essas estão isentas de erros (BASTIN, FISHER, WOOD, 1992) o que acarreta efeitos negativos às decisões apoiadas nestes dados. Isto coloca o estudo dessas incertezas, um tópico de relevância à tomada de decisões.

Qualidade ou acurácia pode ser dividida dentro da classificação de imagens multiespectrais, em termos de posição e temática (TJAN/NANDY, 2006).

A acurácia posicional diz respeito aos erros quadráticos *root-mean-square* (RMS), que se refere à qualidade da retificação aplicada à imagem. Já a acurácia temática diz respeito ao relacionamento do valor da assinatura espectral de um pixel à uma classe correspondente. O foco deste trabalho diz respeito à acurácia temática que é omitida em diversos estudos.

Para a exatidão temática existe uma série de métodos empregados na avaliação global: como índice kappa e gamma (TJAN/NANDY, 2006). Outra possibilidade é a avaliação da classificação feita através da chamada matriz dos erros ou matriz de confusão. Esta relaciona os pixels amostrados às classes que foram definidas. A avaliação nesse caso é feita por classe. Em ambos os casos, os índices utilizam amostras de avaliação para as quais são conhecidas as realidades de campo, escolhidas independentemente das amostras de treinamento (BLOOM/REED, 1997). No entanto, estes índices são globais, ou seja, valem para todo o mapa e não refletem as incertezas espacialmente distribuídas. Essa avaliação global, por exemplo, não resulta num grau de informação suficiente para a avaliação individual de áreas. Uma alternativa pode ser encontrada na associação da incerteza obtida através da classificação pelo método MV (de Máxima Verossimilhança) à cada um dos pixels na imagem. Para isso se distinguirá a acurácia temática em termos de incerteza.

2 Dados

Foram utilizados nos experimentos dois conjuntos de dados. Recortes derivados de cenas do sensor Landsat7 ETM correspondentes à órbita 224 ponto 78, na região do oeste do Estado do Paraná no Brasil.

O primeiro conjunto A de dois pequenos recortes é correspondente aos anos de 06/07/2000 e 05/08/1999. As duas imagens foram adquiridas durante os meses de julho e agosto para minimizar a possibilidade de identificação de mudanças devido diferenças em estágios fenológicos da vegetação. Mesmo com essa precaução, devem-se prever variações de propriedades de reflectância entre mesmas classes, como pode ser observado em Gates in IPF (2003). O gráfico é exibido (figura 1), e mostra as diferentes curvas de reflectância durante o ano, o caso abordado na figura é para uma espécie de Carvalho.




Figura 1 : variações da assinatura espectral durante o ano. (Fonte: Gates in IPF 2003)

Foram diferenciadas para esses recortes do primeiro conjunto de dados, apenas 3 classes distintas: área florestada, área cultivada e corpos d'água. Para facilitar as comparações, as imagens foram corregistradas, isto é, elas foram geometricamente ajustadas uma em relação a outra, com uma média de RMS menor que um pixel.

O segundo conjunto B de recortes possuem uma área aproximada de 13.000 hectares. Suas cenas datam de 03/03/2001, 06/07/2000, 05/08/1999. Foram diferenciadas em cada uma das imagens, um total de 9 classes. Dentre elas, 4 classes de área cultivada e pasto que correspondem à diferentes estágios de crescimento vegetativo. Ainda são diferenciadas as classes de área urbanizada, hidrografia, área florestada ou bosque, regiões de solo exposto ou arado e uma classe da mistura de solo e calcário que é resultado da prática de incorporação de rocha calcária moída ao solo para a correção de sua acidez.

3 Método de Máxima Verossimilhança

A classificação por máxima verossimilhança (MV) é uma das técnicas de classificação supervisionada mais utilizadas em dados de sensoriamento remoto. Técnica a qual utiliza uma matriz de Covariância para cada uma das classes, este método tem base na estatística Bayesiana. A regra Bayesiana descreve pertinência de um pixel x a uma classe ω_j . Ela afirma que a probabilidade de um pixel x pertencer a uma classe ω_j é igual à distribuição de x na classe ω_j , multiplicado pela probabilidade a-priori da classe ω_j ocorrer e dividido pela probabilidade de ocorrência do pixel x . Descreve-se a partir disso a probabilidade a-posteriori, dada por (BÄHR&VÖGTLE, 1998):

$$p(\omega_j | x) = \frac{p(x | \omega_j) \cdot p(\omega_j)}{p(x)} \quad (1)$$

com

$$p(x) = \sum_{i=1}^m p(x | \omega_i) \cdot p(\omega_i), \text{ sendo "m" o índice do numero total de classes.} \quad (2)$$

Substituindo (2) em (1) tem-se a regra Bayesiana:

$$p(\omega_j | x) = \frac{p(x | \omega_j) \cdot p(\omega_j)}{\sum_{i=1}^m p(x | \omega_i) \cdot p(\omega_i)} \quad (3)$$

Um pixel x é atribuído a classe ω_j , segundo a seguinte lei de classificação:

$$p(\omega_j | x) \cdot p(\omega_j) > p(\omega_i | x) \cdot p(\omega_i) \quad (4)$$

Assumindo uma distribuição normal ou gaussiana para a ocorrência de um pixel na imagem e utilizando a função de distribuição de probabilidade a-priori, tem-se:

$$p(\omega_j | x) \propto \frac{1}{\sqrt{2\pi^n |C_j|}} e^{-\frac{1}{2}(x - \mu_j)^T C_j^{-1} (x - \mu_j)} \cdot p(\omega_j) \quad (5)$$

sendo a média μ_j e a matriz covariância C_j dadas respectivamente por:

$$\mu_j = \frac{\sum_{i=1}^n x_i}{n-1}, \quad C_j = \frac{\sum_{i=1, x \in \omega_j}^n (x_i - \mu_k) \cdot (x_i - \mu_l)}{n-1}, \text{ com "i" sendo índice dos pixels da amostra de treinamento e "l" e "k" índices das classes.}$$

O classificador MV utiliza o logaritmo natural para obter o máximo da função de verossimilhança (5), pois maximizar o logaritmo natural de uma função é em geral mais simples e produz os mesmos resultados da maximização da função original.

Dessa forma, a máxima verossimilhança pode ser expressa por:

$$D \propto \ln(|C_j|) + (x - \mu_j)^T C_j^{-1} (x - \mu_j) + \ln(p(\omega_j)) \quad (6)$$

onde D é Verossimilhança.

4 Indicador de Incerteza

Observa-se que o Classificador MV atribui o pixel x a classe ω_i , que satisfaz a condição de máximo valor de $D_i(x)$, independentemente do valor de $D_i(x)$. Este estudo propôs agregar além dos pixels, um valor gerado em função das probabilidades de pertinência $D_i(x)$.

$$f(x_i) = \frac{D(x_i)_{max}}{\sum D_n(x_i)}, \quad (7)$$

Os valores da função dependerão do máximo valor de $D_i(x)$ e da diferença entre os valores atribuídos as outras classes. Com isso, ter-se-ia para duas classes com funções normais descritas pelas curvas na figura 2a valores de $f(x_i)$ apresentados na figura 2b:




Figura 2 : distribuição de probabilidade para duas classes em uma banda espectral.

No gráfico da figura 2b mostra valores tendendo a 1 quando uma das probabilidades de pertinência é muito superior a outra e valores tendendo a um valor mínimo, no caso de duas classes, valores tendendo a meio, quando a diferença entre a probabilidade de pertinência for mínima.

Essa variação no valor de $f(x_i)$ leva a não correspondência de valores muito baixos de uma classe. Pixels que onde a diferença desta função é semelhante a outra, não devem ser simplesmente agregados à classe. Apesar disto, ser apenas um critério de decisão é possível avaliar efetivamente regiões na imagem que tem valores baixos nesta função e são efetivamente resultados de mistura de classes ou revelam regiões de uma possível nova classe. Esses erros já são previstos, a chamada “Teoria da influência dos erros causados pela mistura de sinais em imageamentos” era abordada já nos anos 80. Podendo-se citar Bähr (1984), que no estudo de dados oriundos de imageadores multispectrais como: Landsat e Spot foram estimadas as quantidades de misturas de assinaturas espectrais e a sua influencia nas classificações de sensoriamento remoto. Esse estudo comprova a relação da mistura das assinaturas espectrais com a resolução do sensor, bem como com o tamanho dos objetos imageados, aumentando sua influência no resultado final a partir da variação desses parâmetros.

5 Resultados

Na figura 3 são apresentados os resultados das classificações, realizadas para as duas épocas onde o resultado final é interpretado como uma alteração de uso as margens do reservatório.




Figura 3 : Classificação supervisionada método de máxima verossimilhança.

A figura 4 mostra os resultados dessa implementação para cada classificação. É gerada uma imagem correspondente à incerteza. Todavia, a incerteza está diretamente correlacionada com a amostra de treinamento. Isto indica que os valores fazem relação à amostragem ótima e não somente a acurácia temática.




Figura 4 : Incerteza associada ao pixel.

Problemas que não podem ser solucionados nessa relação entre a amostragem e as classes desejadas geram resultados inconsistentes, que podem nesse sentido, ser representados na forma de uma imagem de incertezas. Ilustrando isso, pode se observar a classe 3 na classificação da época 2000 que é completamente exposta com valores baixos de $f(x_i)$, indicando dificuldades na sua delimitação. Os valores baixos nas bordas indicam a mistura de classes que acontece na geração desses pixels. Os valores indicados na parte inferior direita da classificação de 1999 indicam que a diferença entre as classes 2 e 3 não podem ser bem definidas. Desta forma, uma terceira classe mista entre as duas citadas geraria uma outra análise.

Um outro exemplo é observado no recorte de uma imagem Landsat de 03/03/2001. Com o auxílio de uma ortofoto de 1996 foram definidas 9 classes de uso do solo. Aplicando-se a mesma metodologia acima apresentada.



Figura 5 – Recorte 3.

Obteve-se então o seguinte conjunto de resultado da classificação, apresentado na figura 6. Uma imagem que mostra as classes associadas ao pixel e uma segunda imagem que mostra os valores a-posteriori da máxima verossimilhança normalizados. Observa-se, na figura 6, que os valores mínimos estimados por volta de 0,239 encontram-se principalmente nos limites da classe Corpos d'água onde os pixels misturados não são classificados de forma ideal.




Figura 6 : Classificação do Recorte 3.

Na figura 7 são apresentados as classificações para as imagens de 2000 e 1999 respectivamente em classes de uso do solo. As classes de corpos d'água, mata, e área urbana são as que mantêm uma constante delimitação. As culturas em seus diferentes estágios, por outro lado, apresentam variabilidade mesmo quando comparam-se épocas semelhantes como: maio e junho.




Figura 7 – Classificação dos Recortes 4 e 5.

Nesses últimos dois recortes obtiveram-se resultados aparentemente diferentes para a chamada imagem de incerteza. No recorte de 2000 verificam-se que os valores obtidos para os pixels em algumas classes de culturas e na classe de mata obtêm valores comparáveis aqueles obtidos nos pixels misturados na fronteira da classe Corpos d'água, podendo-se atribuir esses resultados ao ruído na imagem 2000.




Figura 8 : Imagem de Incertezas dos Recortes 4 e 5.

6 Análise

Observando as tabelas 1 a 3, verificam-se valores compatíveis para as três classificações nas épocas 2001, 2000 e 1999. Existe uma maior correlação entre as classes de culturas na época 2000 e menores acurácias na diferenciação entre área urbana e solo exposto nas outras duas épocas. A acurácia global nas três classificações está situada por volta de 90 % e o coeficiente kappa com valores entre 0,87 e 0,93 demonstram que as classificações são aceitáveis.

Tabela 1 – Avaliação recorte 2001/Recorte 1

Classe	CA	M	AU	SE	C1	C2	C3	C4	C5	Total	Acurácia do usuário(%)
CA	255	0	0	0	1	0	0	0	0	256	99,7
M	0	213	0	0	0	0	0	0	0	213	100,0
AU	0	0	316	16	27	0	28	11	0	398	79,4
SC	0	0	2	254	27	0	0	1	0	284	89,4
SA	0	0	14	20	127	0	0	0	0	161	78,9
C1	0	0	0	0	0	281	7	0	0	288	97,6
C2	0	0	11	0	0	10	389	20	0	430	90,5
C3	0	0	4	4	0	0	0	187	0	195	95,9
C4	0	0	0	0	0	0	0	0	40	40	100,0
Total	255	213	347	294	182	291	424	219	40	2265	
Acurácia do produtor(%)	100,0	100,0	91,1	86,4	69,4	96,6	91,7	85,4	100,0		

Acurácia global=91,7% ; índice Kappa=0,9099

Tabela 2 – Avaliação recorte 2000/Recorte 2

Classe	CA	M	AU	SE	C1	C2	C3	C4	C5	Total	Acurácia do usuário(%)
CA	458	0	1	0	0	0	0	0	0	459	99,8
M	1	366	1	0	0	96	1	0	0	465	78,7
AU	0	3	196	53	101	2	0	15	3	373	52,5
SC	0	0	26	333	3	0	0	0	7	369	90,2
SA	0	1	41	11	254	5	0	31	4	347	73,2
C1	0	59	0	0	1	502	4	0	2	568	88,4
C2	0	0	0	0	0	3	376	0	1	380	98,9
C3	0	0	0	0	0	1	0	22	2	25	88,0
C4	0	0	0	1	0	0	1	49	51	51	96,1
Total	459	429	265	398	359	609	381	69	68	3037	
Acurácia do produtor(%)	99,8	85,3	74,0	83,7	70,8	82,4	98,7	31,9	72,1		

Acurácia global=81,8% ; índice Kappa=0,8456

Tabela 3 – Avaliação recorte 1999/Recorte 3

Classe	CA	M	AU	SE	C1	C2	C3	C4	C5	Total	Acurácia do usuário(%)
CA	407	0	0	0	0	0	0	0	0	407	100,0
M	0	309	0	0	0	41	4	0	0	354	87,3
AU	0	1	403	9	12	0	3	35	1	464	86,9
SC	0	0	3	302	0	0	0	6	0	311	97,1
SA	0	0	35	0	304	0	0	5	0	344	88,4
C1	0	20	2	0	0	372	23	0	0	417	89,2
C2	0	1	8	0	0	7	255	2	0	273	93,4
C3	0	0	25	4	0	0	8	759	0	796	95,4
C4	0	0	6	0	0	0	1	0	207	214	96,7
Total	407	331	482	315	316	420	294	807	208	3580	
Acurácia do produtor(%)	100,0	93,4	83,6	95,9	96,2	88,6	86,7	94,1	99,5		

Acurácia global=93,1% ; índice Kappa=0,9267

Afim de se comparar os valores obtidos das matrizes de confusão com as imagens de incerteza, é possível basear-se na probabilidade de se estar atribuindo erroneamente o pixel x_i a uma determinada classe ω_n . Esta probabilidade é complementar à probabilidade de atribuir corretamente o pixel x_i a esta determinada classe, que por sua vez, é calculada a partir da razão entre a probabilidade de se classificar este pixel x_i a esta classe ω_n e a probabilidade de se classificar este pixel x_i à qualquer uma das outras classes de estudo. Ou seja, é a incerteza associada ao pixel x_i e, por conseguinte à classe n , de forma a ser definida pelo complemento do valor dado, como grau de pertinência do pixel x_i a classe ω_n em relação às outras classes. Para tanto deve-se definir um valor limite para a probabilidade de fronteira, no experimento no qual foi adotado o valor de 50% ou 0,5. A tabela 4 mostra o resultado para o grupo A de recortes.

Tabela 4 – Resultados

	Classificação 2000	Desvio Padrão Estimado	Matriz dos Erros	Classificação 1999	Desvio Padrão Estimado	Matriz dos Erros
Classe 1	716 pixel	0,85%	98,46 %	783 pixel	0,23%	100%
Classe 2	323 pixel	13,62%	92,30 %	383 pixel	1,05%	77%
Classe 3	392 pixel	0,11%	100 %	317 pixel	1,06%	100%

A avaliação feita através da matriz de confusão, indica valores diferentes dos estimados pela inferência quanto à pertinência. Isso acontece, por que os valores da matriz de confusão utilizam os valores de pertinência apenas como critério de seleção e não para gerar seus resultados em si. Já o desvio padrão gerado, baseia-se na incerteza associada à classificação para criar valores que podem, por exemplo, ainda ser agregados à objetos por exemplo.

Pode-se observar diferenças entre esses dois procedimentos de avaliação, principalmente na classe 2, que mostra resultados mais incertos na época 2000. Porém, com um valor satisfatório na matriz de confusão e na época 1999 com um valor baixo na matriz de confusão. Apesar de um desvio estimado

baixo. Essa situação é explicada pela variação alta dos valores digitais (*Digital Number*) dentro da mesma classe.

A tabela 5 mostra a mesma metodologia de avaliação aplicada ao conjunto B de recortes.

Tabela 5 – Resultados

	Classif. 1999 (mil m ²)	Desvio Padrão Estimado	Matriz dos Erros	Classif. 2000 (mil m ²)	Desvio Padrão Estimado	Matriz dos Erros	Classif. 2001 (mil m ²)	Desvio Padrão Estimado	Matriz dos Erros
CA	24983,08	24,548	100,0%	25961,13	77,843	99,8%	25848,08	25,84	99,7%
M	11504,94	70,091	87,3%	10925,80	266,798	78,7%	13625,43	43,282	100,0%
AU	6054,96	62,339	86,9%	3901,84	232,237	52,5%	6920,28	86,241	79,4%
SC	5575,95	0	97,1%	4453,20	117,249	90,2%	4748,75	0,969	89,4%
SA	4837,25	283,917	88,4%	8378,94	64,6	73,2%	3570,77	139,536	78,9%
C1	5078,21	0	89,2%	14928,09	70,091	88,4%	8886,70	0	97,6%
C2	14441,98	0	93,4%	10233,29	171,19	98,9%	16685,53	0	90,5%
C3	14613,17	0	95,4%	3718,70	318,801	88,0%	6546,89	0	95,9%
C4	490,31	0	96,7%	4515,86	96,254	96,1%	474,49	0	100,0%

Pode-se observar que os desvios acontecem em apenas algumas classes e não tem relação aparente com a avaliação feita através da matriz de confusão. Em especial, os valores da classe CA chamam a atenção por ser uma classe muito bem definida segundo a matriz de confusão e correspondem provavelmente à uma classe não prevista no processo de classificação. Esta seria a de uma estreita faixa de areia às margens do reservatório, observadas com maior facilidade nas imagens de incertezas das épocas de 2001 e 1999.

7 Conclusão

Existem inúmeras possibilidades para esse tipo de análise. A associação dos valores nos testes mostrados é inerente ao valor do pixel, mas pode também ser associado ou baseado no objeto. Entretanto, para qualquer um desses casos, é necessária a investigação da influencia na propagação dos índices propostos.

Outra questão que diz respeito à adoção de testes estatísticos para avaliação classificações como a proposta baseia-se na distribuição de probabilidade, onde os testes de hipóteses podem delinear os limites onde os pixels que podem ser atribuídos a uma única classe.

É importante salientar que este tipo de mapa de incerteza está mais relacionado ao algoritmo de classificação e as amostras de treinamento escolhidas, do que ao fenômeno em estudo propriamente dito. Então, um valor baixo num mapa de incerteza demonstra que as amostras foram bem classificadas e não o fenômeno. Isto é, a classificação obrigatoriamente pode não corresponder à verdade, mas no caso de um valor alto. Conclui-se que exista mistura entre classes amostradas ou subclasses que foram omitidas no processo de classificação.

Os resultados mostram ainda que a chamada imagem de incerteza não substitui a avaliação através da matriz de confusão. Por estar dependente das amostras de treinamento, enquanto a avaliação pela matriz de confusão utiliza amostras independentes. Porém, a imagem revelou-se uma ferramenta útil na avaliação da qualidade temática, adicionalmente à matriz de confusão. Novos estudos devem ser empregados no sentido de se condensar as avaliações da qualidade temática da imagem a fim de se obter uma banda de avaliação do resultado de classificações de imagens multiespectrais para fins de GIS.

8 Referências Bibliográficas

BÄHR, H.-P.: *Abschätzung einiger geometrischer Fehlerkomponenten bei der multispektralen Klassifizierung.* Bildmessung und Luftbildwesen 1/1984.

BÄHR, H.-P.; VÖGTLE, T. (Hrsg): *Digitale Bildverarbeitung Anwendungen in Photogrammetrie, Kartographie und Fernerkundung.* Beiträge von H.-P. Bähr: Bildaufnahme (S. 3 B 7) Von der realen Welt zum digitalen Bild (S. 15 B 28) Erderkundungssatelliten und ihre Produkte (S. 30 B 43) 3. Auflage Heidelberg 1998.

BASTIN, Lucy; FISHER, Peter F.; WOOD, Jo. *Visualizing uncertainty in multi-spectral remotely sensed Imagery* Computers & Geosciences 28, 2002. pág. 337–350.

BLOOM, Jeffrey A REED, Todd R. *An Uncertainty Analysis of Some Real Functions for Image Processing Applications*. Proceedings of International Conference on Image Processing (ICIP '97) 3-Volume Set-Volume 3 IEEE, 1997, pág. 670-673.

DIXON, B.; CANDADE, N. *Multispectral landuse classification using neural networks and support vector machines:ones or the other or both?* International Jurnal of Remote Sensing. 2008

FOODY, Giles; CURRAN, Paul. Environmental. *Remote Sensing From Regional to Global Scales*. England,1994. pág. 16-44.

IPF – Institut für Photogrammetrie und Fernerkundung/Uni-Karlsruhe. *Lernmodule 6- Fernerkundung*. www.geoinformation.net. Projeto Geoinformation/Alemanha, acessado em 15.05.2007 publicado: 15.11.2003.

KONDRATZEV, K. YA.; BUZNIKOV, A. ; POKROVSKY, O. M. *GLOBAL Change and Remote Sensing*. England, John Wiley & Sons Ltd. Pág. 269-321.1996.

RICHARDS, John A. *Remote sensing digital image analysis: an introduction*. 3. ed. Berlin, Springer Verlag, 1999. pág. 95.

SOARES, João Viane, et al. *An investigation on the selection of texture features for crop discrimination using SAR imagery*. Remote Sensing of Environment, v. 59, n. 2, 1997. pág. 236.

TJAN, Bosco S.; NANDY, Anirvan S. *Classification images with uncertainty*. Journal of Vision, Volume 6, Number 4, 2006. pág. 387-413