

A UTILIZAÇÃO DE CLASSIFICAÇÃO FUZZY EM IMAGENS DE SATÉLITE COMO SUBSÍDIO À CARTOGRAFIA AMBIENTAL

Margareth SIMÕES

Pesquisadora da Área de Geoprocessamento e Planejamento Ambiental da Embrapa Solos

Rua Jardim Botânico, nº 1024, CEP 22460-000, Rio de Janeiro – RJ

Margaret@cnps.embrapa.br

RESUMO

As imagens de satélites podem ser ferramentas valiosas na avaliação da paisagem, não somente devido a sua visão sinóptica, mas também, devido a possibilidade de utilização da dimensão temporal, graças a repetibilidade na obtenção das mesmas.

Uma descrição estatística, como a utilizada nos processos convencionais de classificação de imagens, proporciona um resultado razoável para áreas homogêneas. No entanto, quando uma cena apresenta uma porcentagem alta de heterogeneidade, como é caso, de áreas com grande variabilidade de classes de cobertura, uma abordagem não estatística, baseada na lógica *fuzzy*, parece fornecer uma melhor descrição da paisagem. Este trabalho visa discorrer sobre novas técnicas de classificação de imagens baseadas na lógica *fuzzy*.

ABSTRACT

Satellite imagery may be an important tool for the landscape evaluation, not only due to its synoptic view, but also to the possibility of working with a temporal scale, mainly because of the repeatability in acquisition imagery.

A statistical description, as used in the conventional process of image classification, leads to a reasonable result for homogeneous areas. However, when a scene has a great percentage of heterogeneity, as occurs in areas with a great variability of cover classes, a not statistical approach, based on fuzzy logic, seems to give a better description of the landscape. This work aims at presenting new techniques for image classification based on fuzzy logic.

1. INTRODUÇÃO

As imagens de satélites, devido a sua visão sinóptica, podem servir de subsídio à análise ambiental. Atualmente, considerando-se os satélites disponíveis, devido as limitações existentes em relação à resolução espacial, é possível trabalhar com segurança numa escala máxima de 1:100.000.

CHAVEZ *et al.* (1991) apresentam uma comparação entre métodos de composição das imagens do Satélite francês SPOT, que possui uma resolução espacial maior, com as imagens do satélite americano Landsat-TM, que possui uma resolução espectral maior.

Através desta composição, procura-se utilizar as vantagens de cada um na tentativa de se conseguir trabalhar com uma escala maior, da ordem de 1:50.000. Entretanto, nem sempre os resultados são aceitáveis, o que faz com que a escala espacial de trabalho de 1:100.000 seja mais confiável.

Além disto, o uso de imagens de satélite também deve considerar outras limitações inerentes a esta tecnologia, tais como: o tratamento de áreas com presença de nuvens e a presença de sombras em áreas muito íngremes, o que muitas vezes restringe a utilização destas imagens para a classificação de áreas muito montanhosas ou em áreas que estejam grande parte do tempo coberta por nuvens.

No entanto, ao se considerar uma escala de trabalho adequada e uma região que não possua tais características limitantes, a utilização das técnicas de Sensoriamento Remoto em imagens de satélite poderá contribuir com o estudo e classificação integrada da paisagem, principalmente quando se deseja realizar o monitoramento de uma determinada região. Este trabalho é possível devido a repetibilidade na obtenção destas imagens, o que permite trabalhar-se com a escala temporal.

Os recursos disponibilizados pelas imagens geradas diariamente pelos satélites que se encontram em órbita, não devem ser desprezados. A distinção de padrões da paisagem, a partir da textura, cor e características espectrais podem ser facilitadas por tais imagens.

Esta pode, portanto, ser uma primeira ferramenta que juntamente com os demais recursos e informações históricas, culturais, sociais e sobre o meio físico, permitirão estabelecer comparações entre áreas vizinhas, auxiliando a compreender e analisar as questões de espaço e causalidade. Uma vez que, os padrões espaciais observados nas paisagens resultam de interações complexas entre forças físicas, biológicas e sociais.

Nos últimos anos um número significativo de melhorias no conteúdo da informação das imagens de

satélite tem sido alcançado. Este fato se deve principalmente ao aumento da resolução espacial, radiométrica e temporal advindas da disponibilidade de sensores de alta *performance*, tais como os dos satélites Landsat TM, Spot e SAR. Além disto, os Sistemas de Informação Geográfica (SIGs), capazes de manipular sofisticadas bases de dados geográficos juntamente com os dados advindos destes sensores remotos, vêm se utilizando das vantagens obtidas através da descrição detalhada e confiável da superfície da Terra que estas plataformas proporcionam.

No entanto, para se explorar estas possibilidades de forma completa, faz-se necessário que cada vez mais novas metodologias e novas tecnologias sejam estudadas.

TOWSHEND (1980) demonstrou que as técnicas de classificação convencionais de imagens não levam a resultados melhores quando se utiliza o sensor TM em relação ao MSS. O aumento da resolução espacial e espectral do TM, em relação ao MSS, não foi acompanhada do correspondente aumento na precisão das classificações geradas. Este paradoxo pode ser explicado se considerarmos que uma melhor resolução de um determinado tema, por um lado, reduz o número de pixels híbridos, logo, a heterogeneidade intrínseca, ou seja, o ruído da cena por outro lado é aumentado, conseqüentemente, produzindo um aumento na variação da assinatura espectral, o que leva a algumas sobreposições entre classes distintas (LATTY *et al.*, 1981).

Pode-se afirmar que informações mais detalhadas, utilizadas como dado de entrada, fornecem uma precisão maior somente se a metodologia de classificação incorpora um modelo mais poderoso, que leve em consideração a complexidade dos dados que caracterizam uma dada classe.

Surge, conseqüentemente, a necessidade de se analisar dados de sensores remotos baseados na descrição detalhada dos alvos detectados e nos relacionamentos entre eles.

Sob este aspecto, pode-se afirmar que os métodos de classificação das imagens de sensores remotos, seguem a mesma evolução tecnológica que o processamento de imagens baseados no desenvolvimento de *sistemas inteligentes* para o entendimento das imagens (BROOKS, 1983). Esta evolução é caracterizada por uma mudança contínua de interesse no estudo de algoritmos aplicados a imagens, e o desenvolvimento de um conhecimento *a priori* do mundo real obtido nas imagens (LACAZE e DEBUSSCHE, 1984). Isto é conseguido através de ferramentas de representação e de gerenciamento do conhecimento desenvolvidas no campo da Inteligência Artificial (IA).

A crescente atenção ao uso de técnicas de Inteligência Artificial em Sensoriamento Remoto é demonstrada pelo número de trabalhos relativos a estas técnicas encontrados na literatura. MATSUYAMA (1987) apresenta uma revisão detalhada sobre o assunto.

Outros tipos de sistemas disponíveis atualmente podem ser agrupados na categoria dos Sistemas de Informação Geográfica Inteligentes (SIGI). Normalmente, os SIGIs contém regras para a integração da base de conhecimento de imagens com mapas cartográficos (McKEOWN 1985).

2. Novas Técnicas de Classificação de Imagens de Satélite

Até então, observou-se que, os valores da reflectância dos pixels obtidos através do Sensoriamento Remoto, são geralmente gerados por mais de um fenômeno do terreno, ou seja, um pixel deveria representar a heterogeneidade das características de uso/cobertura existentes na sua área de abrangência.

Apesar do aumento na resolução espacial das imagens de satélite, esta dificuldade de representação da heterogeneidade do solo pelo pixel, tornou-se um problema na precisão dos mapas de uso/cobertura do solo gerados a partir destas imagens.

Pesquisadores em Sensoriamento Remoto têm se preocupado em encontrar um meio de aumentar a precisão das informações sobre uso/cobertura do solo extraídas a partir de imagens de satélites.

Diversos estudos têm examinado a acurácia de vários classificadores de imagens e comparado os resultados destes diversos algoritmos (HIXSON et al., 1980; STORY et al., 1984). Dentre os problemas a serem considerados, destacam-se: tempo de CPU e a quantidade de informação sobre a área que se deve ter a priori para se utilizar no processo de classificação.

Uma alternativa para estes problemas é a utilização de um classificador fuzzy para a determinação dos componentes constituintes do uso/cobertura do solo a partir de imagens de satélite. O classificador fornece um valor da função de pertinência do pixel em relação a cada classe de uso/cobertura. Os resultados demonstram que o classificador fuzzy possibilita a extração de informações sobre pixels individuais e sobre sub-pixels, o que não é possível de se verificar com outros classificadores (BLONDA, 1991).

3. Sistema de Classificação de Imagens Baseada em Linguagem de Comunicação e Lógica Fuzzy

Para se determinar uma base de conhecimentos *a priori* para a análise de imagens de sensores remotos, deve-se estudar as regras espectrais utilizadas por um especialista de campo, que examina visualmente as imagens. Uma forma de se fazer isto é através do *desenvolvimento de uma linguagem de interface entre o sistema e o especialista* para se definir as regras para a classificação temática. A indeterminação do conhecimento pode ser resolvida através da utilização de lógica fuzzy.

A base de conhecimento do sistema consiste em um conjunto de regras que descrevem cada classe de uso/cobertura do solo. Na construção destas regras o sistema adota descritores linguísticos tais como as expressões: baixo, alto, muito baixo, ou qualquer combinação lógica destes predicados como interface entre a linguagem de comunicação do usuário e o sistema de classificação de imagens.

Num dado sistema, o conhecimento relativo a um determinado problema é dado através de regras (BLONDA et al., 1991). Cada regra é representada por uma expressão do tipo - ATRIBUTO (objeto, valor), tal como:

Intensidade-Banda-1 (Floresta, valor-X)

Dois aspectos devem ser considerados quando um conjunto de regras é utilizado juntamente com a definição espectral das classes. O primeiro é que nem sempre é possível se definir um valor ou um conjunto de valores que sejam representativos de uma dada classe univocamente. O segundo é que um especialista irá utilizar expressões imprecisas, típicas da linguagem natural, para definir as características de uma dada classe.

A abordagem paramétrica, usada tradicionalmente na classificação de imagens de sensores remotos, pode fornecer uma estimativa do nível de indeterminação em termos da distribuição espacial randômica, ou seja, a variabilidade entre uma classe é considerada um ruído imposto ao valor real (KANDEL et al., 1978). Entretanto, se a forma de uma função probabilística não é conhecida previamente, uma abordagem não-paramétrica pode ser utilizada. Isto, porém, é normalmente muito dispendioso porque requer a utilização de sistemas de reconhecimento muito complexos e um número muito grande de padrões de treinamento, como é o caso dos sistemas de

Inteligência Artificial baseado em redes neurais (SWAIN, 1978).

A abordagem sugerida por BLONDA *et al.* (1991), baseada em lógica *fuzzy* para contornar os problemas até então mencionados no processo de classificação de imagens, será detalhada neste trabalho, devido a sua simplicidade e excelente interface com o usuário,

Nesta metodologia a impossibilidade de, em princípio, se fornecer uma definição determinística para cada classe real e a dificuldade de se encontrar um conjunto de áreas de treinamento suficientemente representativas são consideradas.

Para solucionar estes problemas, serão utilizados os conhecimentos dos próprios usuários-especialistas na análise visual e na classificação de uso/cobertura do solo. Este conhecimento será aplicado em substituição à utilização de áreas de treinamento, usadas nos sistemas baseados em redes neurais, mencionados acima. Para facilitar esta interface será criada uma linguagem para desenvolver um formalismo entre o conhecimento do usuário e o sistema. Este objetivo é atingido através da utilização de funções de possibilidade *fuzzy*, que provê uma interface direta usuário-sistema.

Na prática, um especialista em Sensoriamento Remoto quando descreve sua interpretação visual sobre uma dada área, faz uso de termos qualitativos, acerca da resposta espectral de uma dada classe na imagem. Esta linguagem descreve as regras que associam a verdade terrestre às características da imagem.

A hipótese utilizada nesta metodologia é a de que as expressões lingüísticas utilizadas pelo especialista podem ser consideradas como uma função de pertinência dos conjuntos *fuzzy*, conforme a teoria apresentada no item anterior. Estes conjuntos *fuzzy* serão definidos no universo de valores espectrais para cada banda da imagem.

Utilizando-se o formalismo do subconjunto *fuzzy*, uma linguagem de interface foi desenvolvida baseada no trabalho de BLONDA (*op.cit.*), para descrever as características espectrais das classes. Esta linguagem tem como base a definição das funções de pertinência:

$$BAIXA(x) = \{(x, mb(x))\}$$

que representa o subconjunto *fuzzy* para resposta espectral baixa, e:

$$ALTA(x) = \{(x, ma(x))\}$$

que representa o subconjunto *fuzzy* para resposta espectral alta.

A variável x representa o valor DN (*Digital Number*) do pixel, ou seja, o nível de cinza representativo do grau de reflectância medido numa dada banda do satélite.

As funções pertinência $mb(x)$ e $ma(x)$ são definidas, de acordo com o intervalo $xmin$, $xmax$ da banda em estudo, como:

$$mb(x) = \begin{cases} S(X, X1, X3) & \text{se } X1 < X < X2 \\ S(X, X3, X1) & \text{se } X2 < X < X3 \\ 0 & \text{se } X3 < X < X5 \\ 0 & \text{se } X1 < X < X3 \end{cases}$$

$$ma(x) = \begin{cases} S(X, X3, X1) & \text{se } X3 < X < X4 \\ 1-S(X, X1, X3) & \text{se } X4 < X < X5 \end{cases}$$

onde:

$$\begin{aligned} X1 &= xmin \\ X3 &= (X5 - X1)/2 + X1 \\ X2 &= (X3 - X1)/2 + X1 \\ X4 &= (X5 - X3)/2 + X3 \\ X5 &= xmax \end{aligned}$$

$$S(X, XA, XB) = 2((X - Xa)/(XB - XA))^2$$

$ma(x)$ e $mb(x)$ são as funções de pertinência para "alto" e "baixo", respectivamente.

Estas funções matemáticas permitem a utilização dos operadores apresentados na Tabela 1, que servirão de *tradutores* entre a linguagem do especialista e o sistema:

Tabela 1 – Operadores *fuzzy* na representação da linguagem do intérprete da imagem

LINGUAGEM DO ESPECIALISTA	FUNÇÃO	FÓRMULA
Muito	MUITO (L(x))	$(mL(X))^2$
Ouase	OUASE (L(x))	$(mL(X))^{1/2}$
NÃO	NÃO (L(x))	$(1 - mL(X))$
E	L1(X) E L2(X)	$\text{Min}(mL1(X), mL2(X))$
OU	L1(X) OU L2(X)	$\text{Max}(mL1(X), mL2(X))$

$L(x)$ representa a função que expressa a forma como o intérprete observa os valores de DN, ou seja, a intensidade de cinza na imagem, para uma determinada classe, para a banda estudada. $L(x)$ significa em termos de comunicação:

alto = para pixels escuros

baixo = para pixels claros

E a linguagem descrita acima: Muito, Quase, Não etc. é utilizada para expressar detalhes da comunicação e representar valores intermediários de cinza, por exemplo:

Muito Baixo ® significa, numa linguagem pouco científica, que o tom de cinza que representa uma classe C é muito escuro na banda x estudada.

Desta forma, o especialista pode acrescentar novas expressões de comunicação, aumentando a tabela acima, ou utilizar combinações da linguagem já desenvolvida para expressar como visualmente é o comportamento de uma classe na imagem.

Observe que a representação da linguagem por operadores para a classificação *fuzzy* de imagens de satélite é semelhante às apresentadas na classificação *fuzzy* para informações temáticas. O que difere estes dois tipos de classificação são as definições das funções de pertinência, que no caso de imagens são obtidas pelas especificações apresentadas acima ($m_a(x)$ e $m_b(x)$). Estas funções são dependentes do valor da reflectância medida pelos sensores do satélite.

Cada linguagem representa matematicamente uma operação que incide sobre a função original $L(x) = (\text{alto/baixo})$, que por sua vez representa graus de pertinência de um determinado pixel estudado em relação ao comportamento da classe dado pelo especialista. Em outras palavras, ao observar os pixels de uma imagem, pode-se constatar quais têm o comportamento descrito pela linguagem do especialista, dado pelo valor *fuzzy* de pertinência, e assim, identificar quais áreas se encaixam naquela classe, naquela banda.

O valor *fuzzy* $L(x)$, é expresso pela função $m_a(x)$ ou $m_b(x)$, respectivamente se a linguagem usada pelo especialista for “alto” ou “baixo”. Conforme, visto acima $m_a(x)$ e $m_b(x)$ são traduções matemáticas que se relacionam ao valor de x, ou seja, ao DN do pixel.

Portanto, a metodologia descrita pode ser resumida da seguinte maneira:

- usuário através do sistema define as características espectrais das classes C_i numa banda k. Isto é possível através do uso de combinações apropriadas dos termos lógicos e dos operadores:

Quase, Muito, Não, E, Ou, Baixo, Alto

- sistema traduz automaticamente qualquer definição dada pela função correspondente: $m(C_i, K, x)$. Cada função representa a medida da

possibilidade de pertinência à classe C_i de um pixel com um valor de cinza x na banda K.

No caso de se querer trabalhar com imagens de diferentes épocas (multi-temporais), o usuário só deve descrever cada classe considerando apenas as bandas mais úteis em cada data. O sistema pega para cada classe a descrição das bandas selecionadas para cada data e submete estas informações ao sistema de classificação *fuzzy*. Desta forma, garante-se que a base de conhecimento utilizada pelo sistema é consistente.

Se uma banda k foi excluída para uma classe C_j , a função relativa $m(C_j, K, x)$ é considerada com valor 1 para todos os pixels. Isto indica que cada valor de cinza na banda k é compatível com a definição da classe global.

Quando a base de conhecimentos é definida, o sistema atribui a cada ponto da imagem uma classe, a qual a função de possibilidade de pertinência é maximizada. Seja:

$$X = \{ X_1, \dots, X_k, \dots, X_n \}$$

o conjunto de valores de cinza para um dado pixel nas N bandas. E seja:

$$\text{POSS}(C_i, X) = \text{MIN} \{ m(C_j, K, x_k) \} \quad k = 1, 2, \dots, N$$

a possibilidade de X ser incluído na classe C_i (esta escolha garante que os requisitos mais estritos para a seleção da classe foram encontrados). Na verdade o operador MIN corresponde ao operador AND. Logo, X é atribuído a classe C_L se:

$$\text{POSS}(C_L, X) = \text{MAX} \{ \text{POSS}(C_i, X) \}$$

i variando de 1 a número de classes existentes.

O pixel, portanto, será classificado como pertencente a classe de maior valor *fuzzy*.

4. Classificação Fuzzy em Imagens de Satélite e a Questão dos Limites em Geoecologia

Para se estudar a transição entre classes pode-se, em vez de utilizar o operador MAX, conforme sugerido no item anterior, ou seja, considerar o *máximo valor obtido*, tomar os dois maiores valores, ou ainda todos os valores maiores que 0.5, ficando clara, assim, a possibilidade do pixel ser classificado como pertencente a mais de uma classe. Fica evidenciada, desta forma, a existência de uma transição de classes. A fim de se exemplificar estas transições, será apresentado o seguinte exemplo:

Seja um pixel A ($I=1, j=1$)

BANDA	DN
1	125
2	80
3	200

- Valores *fuzzy* do pixel "A" em relação à classe C1 (= área reflorestada):

{0.6; 0.8; 0.9} respectivamente para as bandas: 1, 2, 3

- A possibilidade de A pertencer a C1 é 0.6 (menor valor, dado pela banda 1)

$$\text{poss}(C1, XA) = 0.6$$

- A possibilidade de XA, pertencer a uma classe :

$$\text{Poss } X = \{ 0.4, 0.6; 0.8 \}$$

0.4 = área desmatada (classe C2)

0.6 = área reflorestada (classe C1)

0.8 = floresta natural (classe C3)

logo:

XA pode ser classificado como: floresta natural (max: 0.8) ou área reflorestada (0.6), caracterizando uma transição entre estas duas classes.

Exemplo de Aplicação:

A fim de validar a metodologia foi realizado um teste na área metropolitana do Rio de Janeiro. Para tanto, foi utilizada uma imagem de satélite Landsat-TM do ano de 1990. As classes consideradas foram:

- floresta;
- área urbana;
- hidrografia

As Figuras 1, 2 e 3 ilustram os resultados obtidos na detecção respectivamente, da área urbana, da hidrografia e das áreas com cobertura vegetal, a partir das funções *fuzzy*. As Figuras 4 a 11 apresentam os gráficos das funções de classificação *fuzzy* utilizadas para representar a linguagem descritiva da

"aparência" do nível de cinza do pixel para cada classe estudada. A segunda escala de gradação de cinzas apresentada nestas figuras mostra o efeito da aplicação daquela função no nível de cinza original, representado na figura na escala de gradação imediatamente acima.

No caso da função "LOW" (Figura 4), por exemplo, sua aplicação significa que a classe estudada, por exemplo, área urbana aparece com níveis de cinza baixo, ou seja, escuro (valores entre 0 e 127). Ao se aplicar a função "LOW" em toda a imagem, de acordo com o efeito apresentado no gráfico, ela irá ressaltar, ou seja, tornar mais claro as áreas mais escuras e bem escuro as áreas mais claras (que de acordo com a classificação visual do usuário não indicava ser área urbana). Desta forma, as áreas urbanas são ressaltadas aparecendo mais "claras".

5. Conclusões

Se, em vez da aplicação das funções para cada classe isolada utilizada no exemplo acima, fossem observados pelo usuário padrões da paisagem, seria possível lançar mão desta ferramenta como um primeiro passo na análise integrada do ambiente.

Desta forma, poder-se-ia aproveitar a visão sinóptica e temporal proporcionada pelas imagens de satélite e expressar a interdisciplinaridade através da linguagem de comunicação *fuzzy* discutida acima, ou através de diversas combinações desta.

Este seria um primeiro passo para a detecção de diferenças na paisagem que, posteriormente, a partir de outras informações: históricas, sociais, de material cartográfico, de bibliografias da região, de investigação de campo, dos processos de classificação temáticos etc. permitiriam detectar as causas e conseqüências das ações naturais ou antrópicas nas paisagens e proporcionar uma caracterização de cada unidade ou padrão.

A questão dos limites rígidos entre padrões também poderia ser eliminada já que a classificação em si não seria rígida. Existe a possibilidade, com esta ferramenta, de se tomar uma gama de valores que são expressivos, ou seja, que possuam valor *fuzzy* > 0.5 e, desta forma representar as transições entre temas, tais como se apresentam na natureza.

6. Figuras



Figura 1 – Área Urbana.



Figura 2 – Hidrografia.




Figura 3 – Vegetação.




Figura 4 - Função "Baixa"




Figura 6 - Função "Muito Muito Baixa"




Figura 5 - Função "Muito Baixa"




Figura 7 - Função "Não Baixa"




Figura 8 - Função "Quase Baixa"




Figura 10 - Função "Não Baixa e Não Alta"




Figura 9 - Função "Quase Quase Baixa"




Figura 11 - Função "Quase Quase Baixa"

Bibliografia

- BLONDA, P.N. & PASQUARIELLO, G. - An Experiment for the Interpretation of Multitemporal remotely Sensed Images on a Fuzzy Logic Approach. International Journal on Remote Sensing. 12(3):463-476, 1991.
- BROOKS, R. - Model-Based Three dimensional Interpretations of TWo-Dimensional Images. I.E.E.E. Transactions on Pattern Analysis and Machine Intelligence. 5:140-150, 1983.
- CHAVEZ, P.S.; STUART, C.S. & JEFFREY, A. A. - Comparison of Three Different Methods to Merge Multiresolution and Multispectral Data: Landsat TM and Spot Panchromatic. Photogrammetric Engineering and Remote Sensing, 57(3):295-303, 1991.
- HIXSON, M. Scholz, D., FUHS, N. & AKIYAMA, T. - Evaluation of Several Schemes for Classification of Remately Sensed Data, Photogrammetric Engineering and Remote Sensing. 46:1547-1553, 1980.
- KANDEL, A. & BYATT, W. J. - Fuzzy Sets, Fuzzy Algebra and Fuzzy Statistics. Proceedings of Institute of Electrical and Electronics Engineers. 66:1619-1639, 1978.
- LACAZE, B. & DEBUSSCHE, G. - Integration of Multiple Thematic Data With Landsat Data: Some Results About the Feasability of Mediterranean Land Cover Inventories. Proceedings of Integrated Approaches in Remote Sensing Held in Guildford. U.K., 8-11. SP-214, pp 21-39, 1984.
- LATTY, R. S. & HOFFER, R. M. - Computer Based Calssification Accuracy Due to the Spatial Resolution Using Per-Point and Per- Field Classification Techniques. Proceedings of The 7th Symposium on Machine Processing of Remotely Sensed Data, Indiana, pp 384-392., 1981
- MATSUYAMA, T. - Knowledge-Based Aerial Image Understanding Systems and Expert Systems for Image Processing. I.E.E.E. Transaction on Geoscience and Remote Sensing, 3, 305-316, 1987.
- McKEOWN, D.M., HARVEY, W.A. & McDERMOTT, J. - Rule-Based Interpretation of Aerial Imagery. I.E.E.E. Transaction on Pattern Analysis and machine Intelligence. 7:570-585, 1985.
- STORY, M. H., CAMPBELL, J. B. and BEST, G. - An Evaluation of the Accuracies of Five Algorithms for Machine Classification of Remotely Sensed Data, in Proceedings of Nineth Pecora Symposium, ASPRS, Falls Church, V.A., pp. 399-405, 1984
- SWAIN, P.H. - Fundamentals of Pattern recognition in Remote Sensing. In: Remote Sensing: The Quantitative Approach, edited by P.H. SWAIN & S.M. DAVIS (New York: McGRAW HILL), 1978.
- TOWSHEND, J.R.G. - A Spectral-Knowledge-Based Approach for Urban Cover Discrimination. I.E.E.E. Transaction on Geoscience and Remoter Sensing. 3:272-282, 1980.