

# Arquitetura de Sistemas Especialistas para Classificação de Imagens Utilizando Operadores Morfológicos.

RONEI M. DE MORAES<sup>1</sup>, GERALD J. F. BANON<sup>2</sup>, SANDRA A. SANDRI<sup>2</sup>

<sup>1</sup>DE/CCEN/UFPb—Universidade Federal da Paraíba,  
Campus Universitário I, Castelo Branco III, 58.069-970 João Pessoa, PB, Brasil  
ronei@de.ufpb.br

<sup>2</sup>INPE—Instituto Nacional de Pesquisas Espaciais,  
Caixa Postal 515, 12201 São José dos Campos, SP, Brasil  
banon@dpi.inpe.br, sandri@lac.inpe.br

**Abstract.** In this work, we propose a fuzzy expert system architecture for image classification. In these expert systems, the rules are constructed through translation invariant Mathematical Morphology operators. The rule translation into Mathematical Morphology operators sequences is shown in details. An expert system constructed with this architecture is applied to area of Tapajós National Florest, in the Brazilian state of Pará. The classification results are compared with a visually classified image.

**Keywords:** Mathematical morphology, image classification, expert systems.

## 1 Introdução

Os avanços da Morfologia Matemática nos mais diversos campos da área de Processamento Digital de Imagens permitiram os mais variados tipos de aplicação, com especial enfoque na área de reconhecimento de padrões em imagens binárias (Serra, 1982). No entanto, na área de classificação de imagens em níveis de cinza, a aplicação ainda tem sido incipiente. Madier et al. (1986) propoem um classificador não supervisionado. Os trabalhos de Dougherty et al. (1992) e Dougherty e Cheng (1995), utilizavam granulometria para classificação, porém no sentido de reconhecimento de formas. Moraes (1996) propõe um classificador utilizando-se de uma das caracterizações de operadores morfológicos proposta por Banon (1995).

O presente trabalho mostra como aliar o ferromental bem estruturado da Morfologia Matemática à capacidade de manipular o conhecimento de um sistema especialista e a capacidade de modelar conceitos imprecisos e vagos dos Conjuntos Nebulosos (Zadeh, 1965) para classificar imagens. Esta metodologia é ilustrada através da classificação de uma área da Floresta Nacional do Tapajós, no estado brasileiro do Pará.

Com essa união, torna-se possível a construção de regras de um sistema especialista através de operadores da Morfologia Matemática que possuem a propriedade de invariância à translação. Esses operadores podem tratar atributos (características presentes na imagem que podem se tornar referências para a utilização do conhecimento) semelhantes em

uma imagem em qualquer localização. Desse modo, pode-se criar sistemas especialistas poderosos e simples que com um pequeno número de regras sejam capazes de resultados bastante satisfatórios. Como a proposta é apresentar uma nova arquitetura de sistemas especialistas para a classificação de imagens, neste trabalho não será abordada a questão da comparação entre metodologias.

## 2 Aspectos gerais

Três teorias são de relevância para o entendimento deste trabalho: conjuntos nebulosos, sistemas especialistas e morfologia matemática.

### 2.1 Teoria dos Conjuntos Nebulosos

Na Teoria dos Conjuntos Clássica, cada conjunto  $A$  de um universo  $X$  pode ser definido através de uma função característica  $\mu_A : X \rightarrow \{0, 1\}$ , onde 1 denota a total pertinência do elemento ao conjunto e 0 a sua exclusão. Um conjunto nebuloso pode ser visto como uma representação de um conjunto na Teoria dos Conjuntos Clássica, do qual só temos um conhecimento imperfeito. Nesse caso, a pertinência de um elemento a um conjunto é dada não mais por um valor em  $\{0, 1\}$ , mas por um valor qualquer no intervalo  $[0, 1]$ , isto é, e a pertinência de um elemento a um conjunto pode ser parcial.

### 2.2 Sistemas Especialistas

Os sistemas especialistas tratam problemas que normalmente são solucionados por "especialistas" hu-

manos (Rich e Knight, 1993). Estes sistemas trabalham sobre o conhecimento de um dado domínio (por exemplo, conhecimento sobre as classes presentes em uma imagem), de modo a poder tratar de forma semelhante a um ser humano um conjunto de informações. Esse conhecimento deve ser *representado* ou codificado de forma a poder ser tratado por um computador. Em um sistema especialista, a forma mais comum de se representar o conhecimento é através de regras, ou seja, as regras são representações de fórmulas lógicas. Em geral, essas regras são do tipo:

SE <condição> ENTÃO <conclusão>.

Uma regra simples em processamento de imagens, por exemplo, seria:

SE nível de cinza do "pixel" está entre 0 e 13 na banda 4 ENTÃO classe é Rio.

Sistemas especialistas onde regras e fatos envolvem o uso de conjuntos nebulosos são tratados pela chamada "lógica nebulosa" (Sandri, 1997).

### 2.3 Morfologia Matemática

A Morfologia Matemática estuda mapeamentos entre reticulados completos. Em Banon (1995) podem ser vistas definições particulares desses mapeamentos entre cadeias limitadas (Birkhoff, 1967). A utilidade da cadeia limitada para nosso estudo reside no fato de que o contradomínio de uma imagem em níveis de cinza é uma cadeia limitada (há uma ordenação total e limites bem definidos). Assim, pode-se construir mapeamentos entre imagens em níveis de cinza, entre imagens binárias, ou mesmo de imagens em níveis de cinza para imagens binárias ou vice-versa.

**Definição.** Sejam  $K_1$  e  $K_2$  duas cadeias limitadas. Seja  $\Psi$  um mapeamento de  $K_1$  para  $K_2$ , então:

- $\Psi$  é uma *dilatação*  $\Leftrightarrow \Psi$  é crescente e  $\Psi(\min K_1) = \min K_2$
- $\Psi$  é uma *erosão*  $\Leftrightarrow \Psi$  é crescente e  $\Psi(\max K_1) = \max K_2$
- $\Psi$  é uma *anti-dilatação*  $\Leftrightarrow \Psi$  é decrescente e  $\Psi(\min K_1) = \max K_2$
- $\Psi$  é uma *anti-erosão*  $\Leftrightarrow \Psi$  é decrescente e  $\Psi(\max K_1) = \min K_2$

A partir dessas transformações elementares da Morfologia Matemática (dilatação, erosão, anti-dilatação e anti-erosão) pode-se construir uma grande gama de combinações de operadores para resolver problemas de processamento de imagens.

### 3 Sistemas especialistas para classificação de imagens

Os classificadores assistidos por sistemas especialistas surgiram como alternativa para baratear o custo computacional dos classificadores numéricos. Basicamente, eles tentam embutir no processo de classificação o conhecimento humano de "como se faz". Como grande vantagem, pode-se salientar que o processo decisório pode ser suficientemente rico e envolver uma quantidade razoavelmente pequena de informação. Como conseqüência interessante, temos que o conhecimento pode ser armazenado em termos de *regras*, ser explicável e pode ser tratado de forma simplificada (James, 1985). Como desvantagem, temos que ele não necessariamente irá responder corretamente fora dos padrões para os quais foi delineado, em oposição aos métodos exclusivamente numéricos que em geral respondem.

Várias implementações práticas de classificadores existem na literatura: o sistema ICARE (Desachy, 1991); o classificador de Haverkamp et al (1994); os trabalhos de Mascarilla (1995), Wendling et al (1995) e Roux e Desachy (1997) que derivam do sistema ICARE, mas mantém a mesma estrutura. É curioso notar que muitos desses classificadores utilizam o conhecimento em associação a uma pré-classificação numérica, atuando o sistema especialista como um pós-classificador.

### 4 Arquitetura de um sistema especialista para classificação de imagens

Supondo-se que se deseja classificar uma imagem  $f$  em  $m$  classes, onde uma imagem  $f$  pode ser definida como um mapeamento de um retângulo  $E \subseteq Z^2$  em um contradomínio  $K$ . Uma *imagem binária*  $f$  mapeia  $E$  em  $K_1 = \{0, 1\}$ , onde  $K_1$  é uma cadeia limitada. Já uma *imagem em níveis de cinza*  $f$  mapeia  $E$  em  $K_2 = \{0, 1, \dots, 255\}$ , onde  $K_2$  também é uma cadeia limitada. Doravante, os mapeamentos de  $E$  em  $K$  serão chamados de *plano de informação*, pois podem estar representando uma imagem ou um conjunto nebuloso de  $E$  em  $\{0, \dots, 255\}$ . Cada par ordenado  $\pi = (p, f(p))$ , é chamado de "pixel", onde  $p \in E$  é a posição do "pixel" e  $f(p)$  é o seu nível de cinza.

O classificador é composto de um sistema especialista nebuloso cujas premissas das regras são explicitadas por composições de operadores da Morfologia Matemática (Moraes, 1998). Essas regras nebulosas são *compiladas* em uma seqüência de operadores da Morfologia Matemática implementados na caixa de ferramentas de Morfologia Matemática do ambiente de processamento de imagens Khoros. Os operadores da Morfologia Matemática operam

sobre a imagem e podem ser vistos como funções da lógica de primeira ordem (Bittencourt, 1996). A ativação das regras, utilizando-se a imagem  $f$  como entrada, gera como resultado um conjunto de  $n$  planos de informação  $g_k : E \rightarrow [0, 1]$ ,  $k = 1, \dots, n$ , onde  $g_k(p)$  corresponde ao grau de conformidade da posição  $p$  com a classe  $c_k$ . A partir desses  $n$  planos de informação nebulosa - um para cada classe possível - o sistema produz então uma classificação final para os "pixels".

O sistema é implementado utilizando-se dois níveis de abstração: 1) as regras fornecidas pelo(s) especialista(s) são traduzidas em seqüências de operadores da Morfologia Matemática e 2) os  $n$  planos de informação  $g_k$  gerados pelo disparo das seqüências no Khoros geram como saída uma classificação para cada "pixel" da imagem. Embora essa concepção seja implementada no Khoros, essa arquitetura pode ser adaptada para outros ambientes.

A arquitetura de sistema especialista proposta para classificação de imagens trata toda a imagem ao mesmo tempo. Porém, por simplicidade e sem perda de generalidade, será detalhado inicialmente como cada "pixel" é tratado. Seja então, um sistema especialista com regras que utilizam somente o conectivo E do tipo (o tratamento para o conectivo OU pode ser visto em (Moraes, 1998):

$$R_j : \text{Se } atr_1(p) = A_{1j} \text{ e } \dots \text{ e } atr_{N_j}(p) = A_{ij} \text{ então} \\ \text{classe}(p) = B_j$$

onde  $A_{ij}$  e  $B_j$ ,  $i = 1, \dots, N_j$ ,  $j = 1, \dots, m$ , são conjuntos nebulosos,  $atr_i(p)$  são atributos do ponto  $p$  na premissa e  $classe(p)$  é o atributo do ponto  $p$  na conclusão. O universo de discurso dos  $B_j$  é dado por  $C = \{c_1, \dots, c_n\}$ , onde cada  $c_k \in C$  é uma das classes precisas possíveis. O universo de discurso de cada  $A_{ij}$  depende do atributo  $atr_i$  e não necessariamente é discreto.

A classificação de um ponto passa por três fases:

- a) classificação do ponto em relação a cada regra;
- b) agregação das classificações das regras em uma classificação global imprecisa;
- c) determinação precisa da classe do ponto.

Na fase (a), a classificação do pixel em relação a regra  $R_j$  obedece o seguinte esquema geral:

a.1) Verificação de compatibilidade do valor dos atributos  $atr_i$  do ponto  $p$  em relação ao conjunto nebuloso  $A_{ij}$ . Este grau de compatibilidade é dado por  $h_{ij}(p) = \mu_{A_{ij}}(atr_i(p))$ , que corresponde ao  $h_{ij}$  do raciocínio aproximado.

a.2) Verificação de compatibilidade geral dos valores dos atributos  $atr_i$  do ponto  $p$  em relação à premissa de cada regra  $R_j$ . Este grau de compatibili-

dade é dado por  $h_j(p) = \top(h_{1j}(p), \dots, h_{N_j m}(p))$ , onde  $\top$  é uma t-norma.

a.3) Inferência da classificação do "pixel", utilizando-se a compatibilidade da premissa, dada por  $h_j(p)$  e pela conclusão da regra dada por  $\mu_{B_j}$ . Este valor é calculado para cada  $p$  como o conjunto nebuloso  $B'_j(p)$  definido em  $C$ , como

$$\mu_{B'_j(p)}(c_k) = \nabla(h_j(p), \mu_{B_j}(c_k)), \quad j = 1, \dots, m$$

onde  $\nabla$  é uma função de implicação (Sandri, 1997). Cada  $B'_j(p)$  representa a classificação nebulosa de  $p$  em relação a regra  $R_j$ .

Na fase (b), os  $B'_j$  são agregados em um único conjunto nebuloso  $B'$ , definido por

$$\mu_{B'(p)}(c_k) = \diamond(\mu_{B'_1(p)}(c_k), \dots, \mu_{B'_m(p)}(c_k)).$$

Se  $\nabla$  é uma t-norma  $\nabla_{\top}$ , então a agregação  $\diamond$  é dada por uma t-conorma  $\diamond_{\perp}$ .

Quando se aplica este raciocínio a imagem como um todo, criam-se  $n$  planos de informação  $g_k : E \rightarrow \{0, \dots, 255\}$ ; um para cada classe  $c_k$  em  $C$  que são tais que:

$$g_k(p) = \mu_{B'(p)}(c_k), \quad k = 1, \dots, n \\ = \diamond \{ \mu_{B'_1(p)}(c_k), \dots, \mu_{B'_m(p)}(c_k) \} \\ = \diamond \{ \nabla [h_1(p), \mu_{B_1}(c_k)], \dots, \nabla [h_m(p), \mu_{B_m}(c_k)] \}$$

Fazendo  $m_{kj} = \mu_{B_j}(c_k)$  e  $g_{kj}(p) = \nabla [h_j(p), m_{kj}]$ , tem-se:

$$g_k(p) = \diamond_{j=1, m} g_{kj}(p).$$

Quando  $\nabla$  é uma t-norma  $\nabla_{\top}$  e as conclusões são dadas por conjuntos nebulosos  $B_j$  precisos, isto é,  $\exists c^* \in C, \mu_{B_j}(c^*) = 1$  e  $\forall c \neq c^*, \mu_{B_j}(c) = 0$  então para  $c_k = c^*$  temos  $m_{kj} = \mu_{B_j(p)}(c^*) = 1$  e  $g_{kj}(p) = \nabla_{\top}(h_j(p), m_{kj}) = \nabla_{\top}(h_j(p), 1) = h_j(p)$  e para  $c_k \neq c^*$   $g_{kj}(p) = \nabla_{\top}(h_j(p), 0) = 0$ .

Portanto, para  $c_k = c_j^*$  para a regra dada anteriormente, onde as premissas são conectadas por E, temos

$$g_{kj}(p) = \top_i [\mu_{A_{ij}}(atr_i(p))] \quad (1)$$

e conseqüentemente

$$g_k(p) = \diamond_j \{ \top_i [\mu_{A_{ij}}(atr_i(p))] \}. \quad (2)$$

Na fase (c), procede-se uma "desfuzzificação", onde atribui-se somente uma classe ao ponto. O resultado desta fase é a determinação da classificação final do ponto. Entre as opções disponíveis está a

de classificar os pontos, não a uma só das classes originais, mas a algumas dessas classes. Seja a parte constituída de duas classes  $c_{k_1}$  e  $c_{k_2}$  denotada por  $c_{\{k_1, k_2\}}$  que é denominada *classe imprecisa*.

Para se obter classes disjuntas  $c_k$ , dois procedimentos são imediatos: limiarizar cada plano de informação  $g_k$  com um limiar  $l_k$ , fixado para a aplicação ou tomar o maior grau de pertinência do ponto  $p$  nos planos de informação  $g_k$ .

## 5 Considerações para a Implementação Usando Morfologia Matemática

Como foi visto anteriormente, os operadores da Morfologia Matemática operam sobre a imagem e podem ser vistos como funções da lógica de primeira ordem. O principal papel desses operadores é a extração dos atributos da imagem para que o sistema especialista possa atuar. A operação principal para a extração dos atributos são as limiarizações da Morfologia Matemática. Porém, nem sempre é possível somente com elas extrair os atributos na sua melhor forma. Podem ocorrer casos onde há erro pela falta de pontos ou pelo seu excesso. Quando isso ocorre, a operação de reconstrução resolve a maioria dos casos, com algum processamento auxiliar, como erosões, filtragem, dilatações, etc. Em casos onde a limiarização resulta em áreas bem definidas, mas com alguns pontos isolados indesejáveis, o operador sup-gerador pode extrair esses pontos isolados sem afetar as demais áreas presentes na imagem. A partir da função distância da Morfologia Matemática pode-se implementar características nebulosas como perto, muito perto, nas proximidades, longe, muito longe, etc.

O procedimento de como uma regra pode ser modelada utilizando operadores da Morfologia Matemática, é mostrado a seguir. Deve-se ressaltar que essa modelagem não é única, devido ao fato de que pode-se variar a função de implicação, bem como as normas utilizadas. Doravante, um conjunto nebuloso será denotado por *conjunto nebuloso* e sua função de pertinência por  $\mu_{\widetilde{\text{conjunto nebuloso}}}$ . Deve-se chamar a atenção para o fato que o contradomínio das funções de pertinências nos conjuntos nebulosos é o intervalo  $[0,1]$ . Por questão de eficiência, as imagens trabalhadas são imagens com valores inteiros no conjunto  $\{0, \dots, 255\}$  e não com valores reais naquele intervalo.

A seguir, será exemplificado como as regras podem ser implementadas usando operadores da Morfologia Matemática. Três exemplos de fragmentos de conhecimento serão tratados, mostrando detalhadamente os passos da transformação da regra explicitada pelo especialista em uma sequência de operadores

da Morfologia Matemática representando conjuntos nebulosos.

Supondo que um fragmento do conhecimento dado pelo especialista seja dado pela regra:

$$R_1 : \begin{array}{l} SE \text{ radiometria na banda 4 =} \\ \text{nível\_de\_cinza\_escuro} \\ E \text{ radiometria na banda 5 =} \\ \text{nível\_de\_cinza\_mais\_escuro} \\ ENTÃO \text{ posição} \in \widetilde{b_{rio}} \end{array}$$

onde:  $\widetilde{\text{nível\_de\_cinza\_escuro}}$  é um conjunto nebuloso cuja função de pertinência  $\mu_{\widetilde{\text{nível\_de\_cinza\_escuro}}} : \{0, \dots, 255\} \rightarrow \{0, 255\}$  é dada por:

$$\mu_{\widetilde{\text{nível\_de\_cinza\_escuro}}}(s) = \begin{cases} 255, & \text{se e só se } s \leq 13 \\ 0, & \text{caso contrário} \end{cases};$$

$\widetilde{\text{nível\_de\_cinza\_mais\_escuro}}$  é um conjunto nebuloso cuja função de pertinência  $\mu_{\widetilde{\text{nível\_de\_cinza\_mais\_escuro}}}$  é:

$$\mu_{\widetilde{\text{nível\_de\_cinza\_mais\_escuro}}}(s) = \begin{cases} 255, & \text{sss } s \leq 10 \\ 0, & \text{cc} \end{cases};$$

$\widetilde{b_{rio}}$  é um conjunto nebuloso cuja função de pertinência  $\mu_{\widetilde{b_{rio}}} : Y = \{\text{sim, não}\} \rightarrow \{0, 255\}$  é:

$$\mu_{\widetilde{b_{rio}}}(y) = \begin{cases} 255, & \text{se } y = \text{sim} \\ 0, & \text{se } y = \text{não} \end{cases}.$$

As funções de pertinência acima são dilatações e erosões conforme as definições da seção 2.3. Deve-se salientar também que usa-se uma nomenclatura nebulosa, apesar das definições das funções reportarem um sentido não-nebuloso. Isso apenas enfatiza que conjuntos nebulosos também poderiam ser utilizados nesse ponto.

As funções  $\mu_{\widetilde{\text{nível\_de\_cinza\_escuro}}}$  e  $\mu_{\widetilde{\text{nível\_de\_cinza\_mais\_escuro}}}$  são LUTs de operadores de limiarização que aplicadas a uma imagem em níveis de cinza (nesse caso, respectivamente bandas 4 e 5) resultam em imagens binárias.

Pela arquitetura proposta, a implementação da regra  $R_1$ , sendo que a conclusão é um conjunto nebuloso preciso, a implicação  $\nabla = \min$ , a agregação  $\diamond = \max$ , e pelas Equações 1 e 2, resultará em uma imagem  $g_{b_{rio}}(x)$ , onde:

$$g_{b_{rio}}(p) = \min(\mu_{\widetilde{\text{nível\_de\_cinza\_escuro}}} f_4(p), \mu_{\widetilde{\text{nível\_de\_cinza\_mais\_escuro}}} f_5(p))$$

Como as funções de pertinência  $\mu_{\widetilde{\text{nível\_de\_cinza\_escuro}}}$  e  $\mu_{\widetilde{\text{nível\_de\_cinza\_mais\_escuro}}}$  são aplicadas a radiometria e não a uma imagem, para que seja aplicada uma imagem, faz-se uma composição:

$\mu_{\widetilde{\text{nível\_de\_cinza\_escuro}}}(f_4(p))$  por definição é:  
 $(\mu_{\widetilde{\text{nível\_de\_cinza\_escuro}}} \circ f_4)(p)$  e  
 $\mu_{\widetilde{\text{nível\_de\_cinza\_mais\_escuro}}}(f_5(p))$  por definição é:  
 $(\mu_{\widetilde{\text{nível\_de\_cinza\_mais\_escuro}}} \circ f_5)(p)$ . Então:

$$g_{b_{rio}}(p) := \min((\mu_{\widetilde{\text{nível\_de\_cinza\_escuro}}} \circ f_4)(p), (\mu_{\widetilde{\text{nível\_de\_cinza\_mais\_escuro}}} \circ f_5)(p))$$

Em termos de operadores da Morfologia Matemática, as composições acima são operadores de limiarização (Banon, 1995). Então:

$$g_{b_{rio}}(x) := \min(\text{limiarização}_{[0,13]}(f_4)(p), \text{limiarização}_{[0,10]}(f_5)(p)).$$

Note-se que o min que aparece na equação acima se refere a T-norma que implementa o conectivo E.

A seguir será mostrado de forma mais suscinta a modelagem de uma segunda regra. Supondo que um segundo fragmento do conhecimento dado pelo especialista seja dado pela regra  $R_2$ :

$$R_2 : \begin{array}{l} SE \text{ posição} \in \widetilde{\text{muito\_perto\_rio}} \\ E \text{ posição} \in \widetilde{\neg b_{rio}} \\ ENTÃO \text{ posição} \in \widetilde{b_{m \text{ arg em do rio}}} \end{array}$$

onde:  $\widetilde{\text{muito\_perto\_rio}}$  é um conjunto nebuloso cuja função de pertinência  $\mu_{\widetilde{\text{muito\_perto\_rio}}} : E \rightarrow \{0, 255\}$  é aqui definida em termos da função distância  $\Psi_d(f)$  (Moraes, 1998), e é dada por:

$$\mu_{\widetilde{\text{muito\_perto\_rio}}} = \text{limiarização}_{[0,10]} \Psi_d(g_{b_{rio}})$$

$\widetilde{\neg b_{rio}}$  é o complemento do conjunto nebuloso  $\widetilde{b_{rio}}$  e é dado por:  $\mu_{\widetilde{\neg b_{rio}}} = 255 - \mu_{\widetilde{b_{rio}}}$ ; e  $\widetilde{b_{m \text{ arg em do rio}}}$  é um conjunto nebuloso cuja função de pertinência  $\mu_{\widetilde{b_{m \text{ arg em do rio}}}} : Y = \{\text{sim}, \text{não}\} \rightarrow \{0, 255\}$  é:

$$\mu_{\widetilde{b_{m \text{ arg em do rio}}}}(y) = \begin{cases} 255, & \text{se } y = \text{sim} \\ 0, & \text{se } y = \text{não} \end{cases}$$

Pela arquitetura proposta, a implementação da regra  $R_2$ , sendo que a conclusão é um conjunto nebuloso preciso, a implicação  $\nabla = \min$  e pelas Equações 1 e 2, resultará em uma imagem  $g_{m \text{ arg em do rio}}$ , dada por:

$$g_{m \text{ arg em do rio}} = \min(\mu_{\widetilde{\text{muito\_perto\_rio}}}, f_{255} - g_{b_{rio}})$$

onde  $f_{255}$  é uma imagem branca, isto é,  $\forall x \in E$ ,  $f_{255}(x) = 255$ .

Em termos de operadores da Morfologia Matemática, a função de pertinência de  $\widetilde{\text{muito\_perto\_rio}}$

é um operador de limiarização sobre a função distância. Então:

$$g_{m \text{ arg em do rio}} := \min(\text{limiarização}_{[0,10]}(\Psi_d(g_{b_{rio}})), f_{255} - g_{b_{rio}}).$$

Seja  $C = \{c_{rio}, c_{floresta}, c_{\text{área\_antropizada}}\}$  o conjunto de classes relevantes a uma dada aplicação. Para a classe  $c_{rio}$ , uma regra adicional  $R_3$  relaciona o conjunto nebuloso  $\widetilde{c_{rio}}$  com o conjunto nebuloso  $\widetilde{b_{rio}}$  obtido anteriormente:

$$R_3 : \begin{array}{l} SE \text{ posição} \in \widetilde{b_{rio}} \\ ENTÃO \text{ classe} = \widetilde{c_{rio}} \end{array}$$

onde  $\widetilde{c_{rio}}$  é um conjunto nebuloso cuja função de pertinência  $\mu_{\widetilde{c_{rio}}} : C \rightarrow \{0, 255\}$  é:

$$\mu_{\widetilde{c_{rio}}}(c) = \begin{cases} 255, & \text{se } c = c_{rio} \\ 0, & \text{caso contrário} \end{cases}$$

$$255, \text{ se e só se } \leq 13 \\ 0, \text{ caso contrário}$$

A implementação da regra  $R_3$ , dada pelas Equações 1 e 2 resultará em uma imagem  $g_{c_{rio}}$ , onde:

$$g_{c_{rio}}(x) = \mu_{\widetilde{c_{rio}}}'(x)(c_{rio}).$$

## 6 Utilização da arquitetura proposta

A arquitetura proposta foi utilizada na construção de um classificador para a área da Floresta Nacional do Tapajós. As imagens foram tomadas pelos sensores do satélite Landsat TM em 7 de agosto de 1995, através das bandas 3, 4, 5 e 7. A Figura 1 é uma imagem em composição colorida RGB (banda 3 em B, banda 4 em G e banda 5 em R) processada da região.

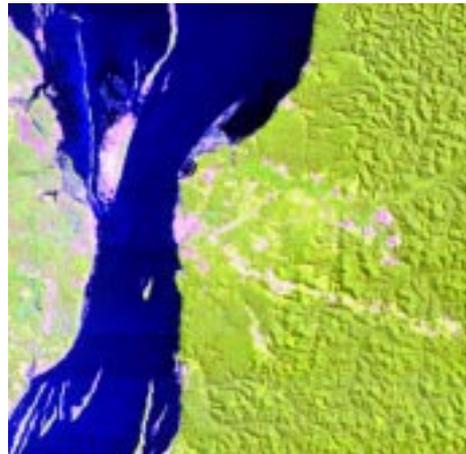


Figura 1 - Composição colorida RGB (5-4-3) da imagem da Floresta Nacional do Tapajós.

A área em questão foi classificada visualmente por Pedro Hernandez Filho da Divisão de Sensoriamento Remoto do INPE em setembro de 1997. Essa classificação é utilizada como referência ou mapa de referência para a comparação com o sistema proposto. As classes presentes nessa área são (Moraes, 1998):



Figura 2 - Resultado da classificação visual.

- *Rio Tapajós*: É a área azul na Figura 1 com textura lisa.
- *Área Antropizada*: São as áreas mais claras nas margens do Rio que se estendem para o interior. Na Figura 1, são áreas em amarelo, rosa e branco.
- *Área Urbana da Cidade de Aveiro*: São áreas em amarelo, rosa e branco à direita do Rio, em forma aproximada de um triângulo.
- *Vegetação Secundária*: São áreas em verde com textura lisa próximas às margens do Rio com pouca presença de drenagem.
- *Floresta Ombrófila Densa*: São áreas em verde com textura rugosa na presença de drenagem
- *Áreas de Contato: Floresta Ombrófila/Formações Pioneiras*: são áreas em rosa e mistura de rosa e azul próximas às margens do Rio.
- *Floresta Aluvial*: são áreas particularmente verdes (na imagem composta em RGB) e estreitas nas proximidades das Áreas Antropizadas.
- *Área de mistura de Área Antropizada e Flo-*

*resta Secundária*: são áreas presentes na margem esquerda do Rio. Não é possível distingui-las com clareza. Na Figura 1, são áreas em amarelo, rosa e branco à esquerda do Rio. A classificação visual pode ser observada na Figura 2.

## 7 A Implementação das Regras

Nessa seção será dada uma explanação sobre cada regra e a forma de sua implementação valendo-se de operadores da Morfologia Matemática presentes na caixa de ferramentas MMach do Khoros.

A Figura 3 mostra a implementação do classificador no ambiente Cantata do Khoros. Essa figura reflete a estrutura do conhecimento fornecido pelo especialista para a classificação da área. À esquerda, podem ser vistas as quatro bandas utilizadas: 3, 4, 5 e 7. Na seqüência, os extratores de atributos são rio, ocupação humana ou área antropizada, drenagem densa, margem direita do rio, a cidade de Aveiro, floresta aluvial, áreas de contato e áreas de mistura (área antropizada e vegetação secundária). A drenagem densa ainda é processada em conjunto com o rio e uma de suas margens gerando um marcador para uma segmentação e rotulação para gerar a classe Floresta Ombrófila Densa. A seguir as áreas classificadas são reunidas e visualizadas no final.



Figura 3 - "Workspace" que gera a classificação para uma imagem com quatro bandas.

## 8 Comparação com um mapa de referência

A aplicação da abordagem proposta neste trabalho com o conhecimento modelado pelas regras deram como resultado a classificação final ilustrada na Figura 4. As cores utilizadas na classificação visual são as mesmas utilizadas aqui para melhor visualização comparativa.

Segundo Hernandez Filho (1997), a classificação

aqui obtida pelo sistema especialista pôde ser considerada bastante satisfatória, visualmente falando. No entanto, existem também as formas numéricas de comparação entre classificações e elas se constituem num importante instrumento de avaliação. Neste caso especificamente, para essa verificação foi utilizado o coeficiente Tau. Segundo Brites et al. (1996), esse é o coeficiente que melhor reflete a exatidão dos processos de classificação. A semelhança entre a imagem classificada e a imagem de referência resultou em 84,11%, com variância de  $7,86.10^{-7}$ .

É importante notar que essa classificação baseou-se exclusivamente no conhecimento do especialista modelado pelas regras e que a imagem de referência não serviu de base para a classificação apresentada na Figura 4.

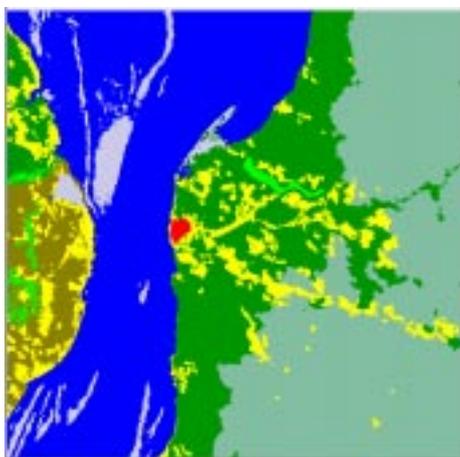


Figura 4 - Resultado final da classificação.

## 9 Conclusões

Apresenta-se um classificador de imagens que se utiliza de um sistema especialista com base de conhecimento. As regras foram construídas a partir de operadores da Morfologia Matemática, em um sistema de programação visual: o Cantata. Essa forma de construção das regras é uma contribuição deste trabalho na área de Morfologia Matemática.

A maior contribuição deste trabalho é o uso homogêneo da Morfologia Matemática e da Teoria dos Conjuntos Nebulosos na classificação de imagens. O tratamento numérico é uniforme, em termos de valores de pertinências a conjuntos nebulosos. Essa abordagem facilita o entendimento desse sistema pelo usuário.

Uma importante característica do classificador implementado foi a obtenção de resultados satisfatórios usando apenas o conhecimento, isto é, sem a necessidade de fontes de dados externos, como mapas, etc, e também sem a associação a uma pré-

classificação numérica, diferentemente de outros trabalhos citados aqui como (Desachy, 1991) e (Mascarilla, 1995). A invariância a translação dos operadores simplificam as operações de isolar atributos tanto por características de forma (principalmente em imagens binárias) quanto por níveis de cinza, independentemente da localização e quantidade desse atributo presente na imagem. Essa importante característica dos operadores invariantes por translação permite ainda uma substancial modularidade no sistema, ou seja, uma mesma seqüência de operações pode, com pequenos ajustes de parâmetros, ser utilizado sobre outra imagem proporcionando o mesmo efeito.

Como desvantagens, observa-se a necessidade de conhecimento sobre a região a ser classificada para se poder construir um bom classificador e há a necessidade de um conhecimento mínimo sobre os operadores da Morfologia Matemática. Em compensação, a prototipagem do sistema é muito facilitada pelo sistema Khoros e pela sua caixa de ferramentas MMACH, reduzindo o tempo de desenvolvimento do primeiro protótipo e facilitando o desenvolvimento do classificador final.

Visualmente e estatisticamente, os resultados obtidos são satisfatórios, mas é necessário observar que para cada imagem a ser classificada, deve-se obter as regras apropriadas para a sua classificação.

## 10 Referências

- Banon, G. J. F. **Characterization of translation invariant elementary morphological operators between gray-level images**. São José dos Campos: INPE, 1995. (INPE-5616-RPQ/671 - <http://hermes.dpi.inpe.br:1905/rep/dpi.inpe.br/banon/1995/10.20.17.45> ).
- Birkhoff, G. **Lattice Theory**. 3. ed. Providence: American Mathematical Society, 1967.
- Bittencourt, G. Inteligência Artificial: ferramentas e teorias. In: Escola de Computação, 10, Campinas, 1996. **Tutorial**. Campinas, UNICAMP, 1996, 127 p.
- Brites, R. S.; Soares, V. P.; Ribeiro, C. A. A. S. Comparação de desempenho entre três índices de exatidão aplicados a classificações de imagens orbitais. [CDROM] In: Simpósio Brasileiro de Sensoriamento Remoto, 8, Salvador, 1996. **Anais**. São Paulo: Image Multimídia, 1996.

- Desachy, J. **Interpretation Automatique d'Images Satellite: Le Systeme ICARE**. Toulouse. 275 p. Tese (Doutorado em Informática) - Université Paul Sabatier. France, 1991.
- Dougherty, E. R.; Newell, J. T.; Pelz, J. B. Morphological texture-based maximum-likelihood pixel classification based on local granulometric moments. **Patt. Recogn.**, v. 25, p. 1181-1198, 1992.
- Dougherty, E. R. and Cheng, Y. Morphological pattern-spectrum classification of noisy shapes: exterior granulometries. **Patt. Recogn.**, v. 28, p. 81-98, 1995.
- Haverkamp, D.; Tsatsoulis C.; Gogieni, S. The combination of algorithmic and heuristic methods for the classification of sea ice imagery. **Rem. Sens. Rev.**, v. 9, n. 1, p. 135-159, 1994.
- Hernandez Filho, P. Classificação visual de imagens. (Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1997). Comunicação pessoal.
- James, M. **Classification Algorithms**. New York: John Wiley & Sons, 1985.
- Khoral Research Inc. **Khoros Pro: Installation Guide**. Albuquerque: Khoral Research Inc., 1996, 81 p.
- Madier, J. P.; Flouzat, G.; Jourlin, M. A non-parametric supervised multispectral classification method using binary morphological operators. In: International Geoscience and Remote Sensing Symposium - IGARSS'86. **Remote Sensing today's solutions for tomorrow's needs** Zurich, 8-11 sept. 1986. Paris: ESA, 1986, v. 1, p.547-552.
- Mathieu-Marni, S.; Moisan, S.; Vincent, R.; A knowledge system for the computation of land cover mixing and the classification of multispectral satellite imagery. **Int. Jour. of Rem. Sens.**, v. 8, p. 1483-1492, 1986.
- Mascarilla, L. **Apprentissage de connaissances pour l'interprétation des images satellite**. Toulouse. 230 p. Tese (Doutorado em Informática) - Université Paul Sabatier, 1995.
- Moraes, R. M. Image classification using Mathematical Morphology. In: Simpósio Brasileiro de Computação Gráfica e Processamento de Imagens, 9, Caixambu: 1996. **Anais** p. 357-358.
- Moraes, R. M. **Uma Arquitetura de Sistemas Especialistas Nebulosos para Classificação de Imagens Utilizando Operadores da Morfologia Matemática**. São José dos Campos. 114 pág. Tese (Doutorado em Computação Aplicada). Instituto Nacional de Pesquisas Espaciais, 1998.
- Rich, E.; Knight, K. **Inteligência Artificial**. Rio de Janeiro: McGraw Hill, 1993.
- Roux, L.; Desachy, J. Multisources information-fusion application for satellite image classification. In: Dubois, D; Prade, H.; Yager, R. R. ed. **Fuzzy information Engineering - a guide tour of applications**. New York: John Wiley and Sons, 1997, cap. 6, p. 212-221.
- Sandri, S. Introdução à lógica "fuzzy". In: Simpósio Brasileiro de Automação Inteligente, 3, Vitória: 1997. **Tutorial**. São Paulo: Sociedade Brasileira de Automação, 1997.
- Serra, J. **Image Analysis and Mathematical Morphology**. Londres: Academic, 1982.
- Wendling, L.; Zehana, M.; Desachy, J. Fuzzy segmentation and structural knowledge for satellite image analysis. In: International Conference on Image Analysis and Processing, 8, San Remo: 1995. **Proceedings**. Berlin: Springer-Verlag, 1995, p. 703-708.
- Zadeh, L. A. Fuzzy Sets, **Information and Control**, v. 8, p. 338-353, 1965.