

1. INTRODUÇÃO

*"Aquele que nada sabe, sabe que nada sabe,
aquele que muito sabe, sabe que nada sabe,
mas aquele que pouco sabe, pensa que muito sabe"*
Provérbio chinês.

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 ferramental 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.

Esse documento está organizado da seguinte maneira: o Capítulo 2 traz uma breve revisão sobre os conceitos utilizados e algumas considerações sobre os sistemas de classificação de imagens. No Capítulo 3 encontra-se uma análise de um sistema de classificação de imagens denominado ICARE que serviu de ponto de

partida para este trabalho. O Capítulo 4 apresenta a proposta de um sistema especialista e discute alguns aspectos da sua implementação usando operadores da Morfologia Matemática. O Capítulo 5 traz uma aplicação da metodologia proposta na classificação de uma área na Floresta Nacional do Tapajós. No Capítulo 6 é feita uma análise comparativa com um mapa de referência gerado por uma classificação visual feita pelo professor Pedro Hernandez Filho da Divisão de Sensoriamento Remoto do INPE. Finalmente, o Capítulo 7 traz as considerações finais e sugestões para futuros trabalhos.

Este trabalho traz ainda dois apêndices: o primeiro com a descrição das bandas do satélite Landsat TM e suas aplicações e o segundo com as imagens originais em níveis de cinza utilizadas na aplicação.

2. ASPECTOS GERAIS

*"Uma longa caminhada sempre começa
pelo primeiro passo"
Provérbio chinês.*

Esse capítulo aborda resumidamente os tópicos teóricos que serão úteis na seqüência deste trabalho: conjuntos nebulosos, sistemas especialistas e morfologia matemática. Em seguida ele traz algumas considerações sobre o sistema Khoros e classificação de imagens.

2.1. Teoria dos Conjuntos Nebulosos ("Fuzzy Sets")

As origens dos Conjuntos Nebulosos remontam ao ano de 1965, quando o professor Lofti A. Zadeh publicou um artigo que é considerado o marco-zero da teoria: "Fuzzy Sets", onde lança as bases matemáticas desse tipo de conjunto (Zadeh, 1965). A partir daí, inúmeras aplicações e destinos têm sido dados a essa teoria, nos mais variados campos como estatística, inteligência artificial, reconhecimento de padrões, programação linear, entre muitos outros (Dubois e Prade, 1980, Kandel, 1986).

Esta seção visa introduzir algumas definições básicas sobre os conjuntos nebulosos que serão úteis nas discussões futuras.

2.1.1. O que são "Fuzzy Sets".

Na Teoria dos Conjuntos Clássica, cada conjunto A de um universo X pode ser definido através de uma função característica $\mu_A : X \longrightarrow \{0, 1\}$ que é tal que:

$$\mu_A(x) = \begin{cases} 1, & \text{se e somente se } x \in A \\ 0, & \text{caso contrário} \end{cases}$$

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.

Formalizando matematicamente, segue-se a definição (Zadeh, 1965):

Definição 1. Seja X um espaço de pontos, com um elemento genérico de X denotado por x . Um *conjunto nebuloso* A em X é caracterizado por uma *função de pertinência* $\mu_A(x)$ que associa a cada ponto em X um número real no intervalo $[0, 1]$, onde $\mu_A(x)$ representa para x o seu grau de pertinência em A . Quando $\exists x \in X$, tal que $\mu_A(x) = 1$, então A é dito ser normalizado.

Quando $\mu_A(x) = 1$ diz-se que x é completamente compatível com o conceito expresso por A em X e quando $\mu_A(x) = 0$ diz-se que x é completamente incompatível com o conceito expresso por A em X .

Em certos casos, pode ser necessário ou conveniente exibir elementos de X que pertençam a um conjunto nebuloso A , com valor de pertinência de pelo menos $\alpha \in (0, 1]$. Nesses casos, utiliza-se o *corte* – α ou *corte de nível* (Zadeh, 1965).

Definição 2. O conjunto ordinário dos elementos x pertencentes a um conjunto nebuloso A com valores de pertinência de pelo menos $\alpha \in (0, 1]$ é definido pelo conjunto de nível α , A_α de A , tal que:

$$A_\alpha = \{x \in X, | \mu_A(x) \geq \alpha\}.$$

A função de pertinência de um conjunto A pode ser expresso em termos de seus cortes de nível α de acordo com a expressão:

$$\mu_A(x) = \sup_{\alpha \in (0,1]} \min\{\alpha, \mu_{A_\alpha}(x)\},$$

onde:

$$\mu_{A_\alpha}(x) = \begin{cases} 1, & \text{se } x \in A_\alpha, \\ 0, & \text{caso contrário} \end{cases}$$

Exemplo:

Dado um universo X , um conjunto nebuloso A pode ser denotado através de $A = \sum \mu_A(x)/x$, mostrando para cada x a sua pertinência correspondente, para $\mu_A(x)$ não nulo. Sejam, o universo X dado por $X = \{1, 2, 3, 4, 5, 6, 7, 8\}$ e um conjunto nebuloso A definido como:

$$A = 0.1/2 + 0.2/3 + 0.5/4 + 0.6/5 + 0.8/6 + 1.0/7;$$

os conjuntos de nível α de A são dados por:

$$\begin{aligned}
A_{0.1} &= \{2, 3, 4, 5, 6, 7\} \\
A_{0.2} &= \{2, 3, 4, 5, 6, 7\} \\
A_{0.5} &= \{4, 5, 6, 7\} \\
A_{0.6} &= \{5, 6, 7\} \\
A_{0.8} &= \{6, 7\} \\
A_{1.0} &= \{7\}.
\end{aligned}$$

2.1.2. Operações com Conjuntos Nebulosos.

Existem operações sobre os conjuntos nebulosos, similares aos da Teoria de Conjuntos clássica (Kandel, 1986).

Definição 3. Um conjunto nebuloso é vazio se e somente se a sua função de pertinência é identicamente zero sobre X .

Definição 4. Dois conjuntos nebulosos A e B são iguais ($A = B$), se e somente se $\mu_A(x) = \mu_B(x)$ para todo x em X .

Definição 5. O complemento de um conjunto nebuloso A em X , denotado por $\neg A$ é definido por:

$$\mu_{\neg A}(x) = n(\mu_A(x)), \forall x \in X. \quad (2.1)$$

onde $n : [0, 1] \rightarrow [0, 1]$ é um operador de negação que satisfaz as seguintes propriedades:

- 5.1) $n(0) = 1$ e $n(1) = 0$
- 5.2) $n(a) \leq n(b)$ se $a > b$
- 5.3) $n(n(a)) = a, \forall x \in [0, 1]$

e uma negação é estrita se ela é contínua e satisfaz a condição:

- 5.4) $n(a) < n(b)$ se $a > b$.

A principal operação de negação que satisfaz todas as quatro condições acima é $n(a) = 1 - a$.

Definição 6. A intersecção de dois conjuntos nebulosos A e B , com suas funções de pertinência $\mu_A(x)$ e $\mu_B(x)$ resulta um conjunto nebuloso C , cuja função de pertinência é dada por:

$$C = A \cap B \Leftrightarrow \mu_C(x) = \top\{\mu_A(x), \mu_B(x)\}, \forall x \in X, \quad (2.2)$$

onde o operador $\top : [0, 1]^2 \rightarrow [0, 1]$, chamado de T-norma, é associativo, comutativo, monotonicamente crescente e tal que $\forall x \in X, \top(x, 1) = \top(1, x) = x$. Algumas T-normas estão listados na Tabela 2.1.

Definição 7. A união de dois conjuntos nebulosos A e B , com suas funções de pertinência $\mu_A(x)$ e $\mu_B(x)$ resulta um conjunto nebuloso C , cuja função de pertinência é dada por:

$$C = A \cup B \Leftrightarrow \mu_C(x) = \perp\{\mu_A(x), \mu_B(x)\}, \forall x \in X, \quad (2.3)$$

onde o operador $\perp : [0, 1]^2 \rightarrow [0, 1]$, chamado de T-conorma, é associativo, comutativo, monotonicamente crescente e tal que $\forall x \in X, \perp(x, 0) = \perp(0, x) = x$. Algumas T-conormas estão listados na Tabela 2.1.

OBS.: Em particular, quando utiliza-se a t-norma min e a t-conorma max, pode-se verificar facilmente que $A \cap \neg A \neq \emptyset$ e portanto $A \cup \neg A \neq X$ (ver Equações 2.2, 2.3 e o exemplo a seguir).

TABELA 2.1 - T-NORMAS E T-CONORMAS DUAIS.

T-normas	T-conormas
$\min(a, b)$	$\max(a, b)$
$a.b$	$a + b - ab$
$\max(a + b - 1, 0)$	$\min(a + b, 1)$
$\begin{cases} a, & \text{se } b = 1 \\ b, & \text{se } a = 1 \\ 0, & \text{senão} \end{cases}$	$\begin{cases} a, & \text{se } b = 0 \\ b, & \text{se } a = 0 \\ 1, & \text{senão} \end{cases}$

O exemplo a seguir ilustra as definições acima:

Exemplo:

Seja o universo:

$$X = \{1, 2, 3, 4, 5, 6, 7\};$$

e sejam dois conjuntos nebulosos A e B em X :

$$A = 0.8/3 + 1/5 + 0.6/6,$$

$$B = 0.7/3 + 1/4 + 0.5/6;$$

onde, segundo a notação, o conjunto nebuloso A , o elemento 3 possui um grau de pertinência 0.8, o elemento 5 possui um grau 1 e o elemento 6 possui um grau 0.6 e de forma similar para o conjunto nebuloso B .

Então, quando a união dos conjuntos nebulosos A e B é dada por $A \cup B = \max(\mu_A, \mu_B)$; a intersecção, denotada por $A \cap B = \min(\mu_A, \mu_B)$ e a negação é dada por $\neg A = 1 - \mu_A$, temos:

$$\begin{aligned} A \cup B &= 0.8/3 + 1/4 + 1/5 + 0.6/6, \\ A \cap B &= 0.7/3 + 0.5/6; \\ \neg A &= 1/1 + 1/2 + 0.2/3 + 1/4 + 0.4/6 + 1/7. \end{aligned}$$

□

Definição 8. A implicação entre dois conjuntos nebulosos A e B , com suas funções de pertinência $\mu_A(x)$ e $\mu_B(y)$ resulta um conjunto nebuloso C , cuja função de pertinência é dada por:

$$C = A \Rightarrow B \Leftrightarrow \mu_C(x, y) = \nabla\{\mu_A(x), \mu_B(y)\}, \forall x \in X, \forall y \in Y \quad (2.4)$$

onde $\nabla : [0, 1]^2 \rightarrow [0, 1]$ é um operador de implicação que obedece às seguintes propriedades, para $\forall a, a', b, b' \in [0, 1]$.

$$8.1) \text{ Se } b \leq b' \text{ então } I(a, b) \leq I(a, b')$$

$$8.2) I(0, b) = 1$$

$$8.3) I(1, b) = b$$

As implicações "puras" obedecem também às propriedades:

$$8.4) \text{ Se } a \leq a' \text{ então } I(a, b) \geq I(a', b)$$

$$8.5) I(a, I(b, c)) = I(b, I(a, c))$$

Existem vários operadores de implicação definidos na literatura e alguns dos principais estão descritos na Tabela 2.2:

TABELA 2.2 - OPERADORES DE IMPLICAÇÃO

Operador de Implicação	Nome
$\max(1 - a, b)$	Kleene-Dienes
$\min(1 - a + b, 1)$	Lukasiewicz
$1 - a + ab$	Reichenback
$\min(a, b)$	Mandani

As T-normas, embora não pertençam à classe das implicações "puras", são os operadores mais utilizadas na prática para modelar a implicação.

2.2. Sistemas Especialistas

A tarefa de um sistema de classificação consiste em examinar um conjunto de informações e ao final decidir entre um conjunto de classes conhecidas, qual é aquela que o conjunto de informações pertence. Os sistemas de classificação que utilizam conhecimento de especialistas para auxiliar na tarefa de classificação tem usualmente, a arquitetura de sistemas especialistas.

Os sistemas especialistas tratam problemas que normalmente são solucionados por "especialistas" humanos (Rich e Knight, 1993, p. 631). Estes sistemas trabalham sobre o conhecimento de um dado domínio (por exemplo, conhecimento sobre as classes presentes em uma imagem), de forma 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. O conhecimento é geralmente caracterizado por um conjunto de regras e fatos. As regras são a tradução do conhecimento do especialista e os fatos são dados que podem ser adquiridos inicialmente ou posteriormente durante o processo de dedução (Buchanan e Shortliffe, 1985). Usando regras e fatos, novos fatos são obtidos. Para obter novos fatos, utilizam-se de uma ou mais formas de raciocínio. Em geral, os sistemas especialistas podem mostrar ao usuário os caminhos pelos quais trilharam em um processo decisório e adquirir novos e/ou modificar conhecimentos. É claro que o sistema também deve checar se um novo conhecimento não entrará em conflito com o conhecimento já armazenado, ou seja a consistência da base de conhecimento deve sempre ser mantida.

Como o conhecimento deve ser manipulado logicamente, cabe uma definição formal do que é uma *linguagem lógica de primeira ordem* (Bittencourt, 1996):

Definição 9. Uma *linguagem lógica de primeira ordem* - $L(\mathbf{P}, \mathbf{F}, \mathbf{C}, \mathbf{V})$ - é determinada pela especificação dos seguintes conjuntos:

- um conjunto \mathbf{P} de Símbolos de Predicado;
- um conjunto \mathbf{F} de Símbolos de Função;
- um conjunto \mathbf{C} de Símbolos de Constante;
- um conjunto \mathbf{V} de Símbolos de Variável.

A cada símbolo de predicado e de função é associado um número de argumentos do predicado e da função. Estes conjuntos formam o alfabeto da linguagem lógica e com esse alfabeto, em associação aos operadores lógicos (\neg é "não"; \wedge é "e"; \vee é "ou"; \implies é "implica"; \exists é "existe"; \forall é "qualquer"), é possível a escrita de fórmulas, como:

$$\begin{aligned} & ((\text{Pai}(a, b)) \wedge (\text{Pai}(b, c))) \implies (\text{Avô}(a, c)); \\ & ((\text{Pai}(a, b)) \wedge (\text{idade}(b) = x)) \implies (\text{Idade_aproximada}(a, x + 20)); \end{aligned}$$

onde Pai , Avô e Idade_aproximada são predicados; idade é uma função que calcula a idade; a , b , c e x são variáveis e $+$ é a operação de adição.

Ainda que utilizada de uma forma "ad-hoc", a lógica de primeira ordem é a base dos sistemas especialistas.

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:

$$\text{SE } \langle \textit{condição} \rangle \text{ ENTÃO } \langle \textit{conclusão} \rangle.$$

que podem ser vistos como uma implicação $\langle \textit{condição} \rangle \implies \langle \textit{conclusão} \rangle$.

Uma regra pode ser composta de conjunções e disjunções e pode levar a mais de uma conclusão. Por exemplo:

$$\begin{aligned} \text{SE } (\langle \textit{condição } 1 \rangle \text{ OU } \langle \textit{condição } 2 \rangle) \text{ E } (\langle \textit{condição } 3 \rangle) \\ \text{ENTÃO } (\langle \textit{conclusão } 1 \rangle \text{ E } \langle \textit{conclusão } 2 \rangle). \end{aligned}$$

que é a representação da implicação $(\langle \textit{condição } 1 \rangle \vee \langle \textit{condição } 2 \rangle) \wedge (\langle \textit{condição } 3 \rangle) \implies (\langle \textit{conclusão } 1 \rangle \wedge \langle \textit{conclusão } 2 \rangle)$.

A regra acima com mais de uma conclusão é equivalente a um conjunto de regras com somente uma conclusão, ou seja:

$$\begin{aligned} \text{SE } (\langle \textit{condição } 1 \rangle \text{ OU } \langle \textit{condição } 2 \rangle) \text{ E } (\langle \textit{condição } 3 \rangle) \\ \text{ENTÃO } \langle \textit{conclusão } 1 \rangle \\ \text{SE } (\langle \textit{condição } 1 \rangle \text{ OU } \langle \textit{condição } 2 \rangle) \text{ E } (\langle \textit{condição } 3 \rangle) \\ \text{ENTÃO } \langle \textit{conclusão } 2 \rangle \end{aligned}$$

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

$$\begin{aligned} \text{SE nível de cinza do "pixel" está no intervalo } [0, 13] \text{ na banda } 4 \\ \text{ENTÃO classe é Rio.} \end{aligned}$$

As condições e conclusões de uma regra são usualmente representados por uma lista da forma:

$$(\langle \textit{objeto} \rangle, \langle \textit{atributo} \rangle, \langle \textit{valor} \rangle)$$

onde os atributos, através dos seus valores, descrevem as características do objeto em estudo (Bittencourt, 1996; Buchanan e Shortliffe, 1985). No caso desse trabalho, os **objetos** são os tipos sobre os quais o conhecimento atua; os **atributos** são as características presentes na imagem que podem se tornar referências para a utilização do conhecimento, os **valores** são os valores numéricos ou sintáticos que os atributos podem assumir. Um objeto pode ser, por exemplo um segmento de uma imagem, um de seus atributos pode ser a média dos níveis de cinza dos

"pixels" que o compõem com valores entre $[0,255]$. Um outro exemplo é dado pela lista ("pixel"-i, classe, "floresta"), onde classe é o atributo do objeto "pixel"-i que no caso tem como valor "floresta". Do ponto de vista lógico, usualmente a tripla ($\langle \text{objeto} \rangle$, $\langle \text{atributo} \rangle$, $\langle \text{valor} \rangle$) pode ser codificado utilizando o predicado da igualdade, como $(\text{atributo}(\text{objeto})=\text{valor})$, onde atributo é uma função, objeto é uma variável ou uma constante e valor é uma constante. Para que novos fatos sejam deduzidos, é preciso utilizar um mecanismo de inferência que combine fatos e regras.

Em geral há dois tipos de inferência em sistemas especialistas: para-frente e para-trás. No primeiro caso, a partir da verificação das premissas se concluem fatos que podem validar premissas de outras regras. No segundo caso, parte-se das conclusões possíveis e procura-se quais seriam as premissas que poderiam levar a elas e no final dessa seqüência para-trás, de posse de todo o "caminho" percorrido, ele é validado.

Podem haver casos nos quais os atributos não podem ser medidos com a exatidão necessária, ou o próprio especialista verifica que o conhecimento não é válido em qualquer situação. Então podem ser introduzidos os coeficientes de certeza para codificar essa incerteza na conclusão da regra. Nesses casos, a informação incerta pode ser tratada de através de probabilidades (Rich e Knight, 1993; James, 1985), crença e plausibilidade (Senne, 1988); possibilidades (Kruse et al., 1991; Dubois e Prade, 1996) ou "ad-hoc" (Desachy, 1991).

Sistemas especialistas onde regras e fatos envolvem o uso de conjuntos nebulosos são tratados pela chamada "lógica nebulosa", com aplicação notadamente em controle automático de processos (Driankov et al., 1993). Nesta lógica, para combinar regras e fatos lança-se mão de uma forma de raciocínio denominado raciocínio aproximado. Sejam A_i e A'_i , $i = 1, \dots, n$, subconjuntos nebulosos em X_i , B um subconjunto nebuloso em Y com as funções de pertinência conhecidas, R uma regra e F um fato, onde:

$$\begin{aligned} R : & \text{SE } \langle x_1 = A_1 \rangle \text{ E } (\langle x_2 = A_2 \rangle \text{ OU } \langle x_3 = A_3 \rangle) \text{ ENTÃO } \langle y = B \rangle . \\ F : & \langle x_1 = A'_1 \rangle \text{ E } \langle x_2 = A'_2 \rangle \text{ E } \langle x_3 = A'_3 \rangle . \end{aligned}$$

O processo geral de inferência segue os seguintes passos (Sandri, 1997):

- a) Cria-se uma relação nebulosa A em $X_1 \times \dots \times X_n$ entre os A_i e uma relação nebulosa A' em $X_1 \times \dots \times X_n$ entre os A'_i .
- b) Cria-se a relação nebulosa R entre a premissa dada pela relação nebulosa A e pela conclusão dada pelo conjunto nebuloso B , usando uma função de implicação.
- c) Faz-se uma composição de R com A' e projeta-se o resultado sobre Y obtendo-se o subconjunto nebuloso B' .

No caso onde os A'_i representam fatos precisos, isto é, cada A'_i é tal que $\exists x_i^* \in X_i$, $\mu_{A'_i}(x_i^*) = 1$, o processo é simplificado e será descrito detalhadamente a seguir,

dada a sua relevância ao trabalho. Supondo que a base de conhecimento seja composta por n regras R_j do tipo:

$$R_j : \text{Se } \langle x_{ij} = A_{ij} \rangle \text{ E } \dots \text{ E } \langle x_{nj} = A_{nj} \rangle \\ \text{Então } \langle y = B \rangle;$$

o processo se divide em quatro fases:

1) Seja o valor de realização de cada x_i dado por $x_i^* \in X_i$, isto é x_i^* representa o fato A'_i . Determina-se o grau de compatibilidade de x_i^* , $1 \leq i \leq n$, para cada A_{ij} da regra R_j , $1 \leq j \leq m$:

$$h_{ij} = \mu_{A_{ij}}(x_i^*);$$

2) Determina-se o grau de compatibilidade global da premissa de cada regra R_j , $1 \leq j \leq m$, com uma T-norma \top :

$$h_j = \top(h_{1j}, \dots, h_{nj});$$

Quando a regra envolve conectivos OU, este passo envolverá também o uso de uma T-conorma \perp .

3) Determina-se o conjunto nebuloso B'_j , referente a cada regra R_j usando um operador de implicação ∇ :

$$\mu_{B'_j}(y) = \nabla(h_j, \mu_{B_j}(y)), \forall y \in Y;$$

4) Determina-se o conjunto nebuloso B' , usando um operador \diamond para agregar os B'_j :

$$\mu_{B'}(y) = \diamond(\mu_{B'_1}(y), \dots, \mu_{B'_m}(y)); \forall y \in Y.$$

Exemplo:

Sejam, A , B e C conjuntos nebulosos e R_1 : Se $x = A$ então B e R_2 : Se $x = C$ então B , duas regras e três fatos precisos $x^* = x_i$, $i = 1, 2, 3$ e $x_i \in X$. Na Figura 2.1 pode-se observar o progresso do raciocínio aproximado simplificado para a regra R_1 quando a implicação adotada é $\nabla = \sim A \vee B$ e quando a implicação adotada é $\nabla = \min$. Nota-se que quando x_i é completamente compatível com o conjunto nebuloso em questão, os resultados obtidos são iguais para as duas formas de implicação. No entanto, quando x_i é completamente incompatível com o conjunto nebuloso em questão, a modelagem da ignorância sobre o ponto são diferentes. No caso da implicação $\nabla = \sim A \vee B$ todas as respostas possíveis recebem pertinência igual a 1 e no caso da implicação $\nabla = \min$, todas as respostas possíveis recebem pertinência igual a zero.

A Figura 2.2 ilustra o uso do operador $\diamond = \max$ para a função de implicação $\nabla = \min$ utilizando-se as regras R_1 e R_2 .

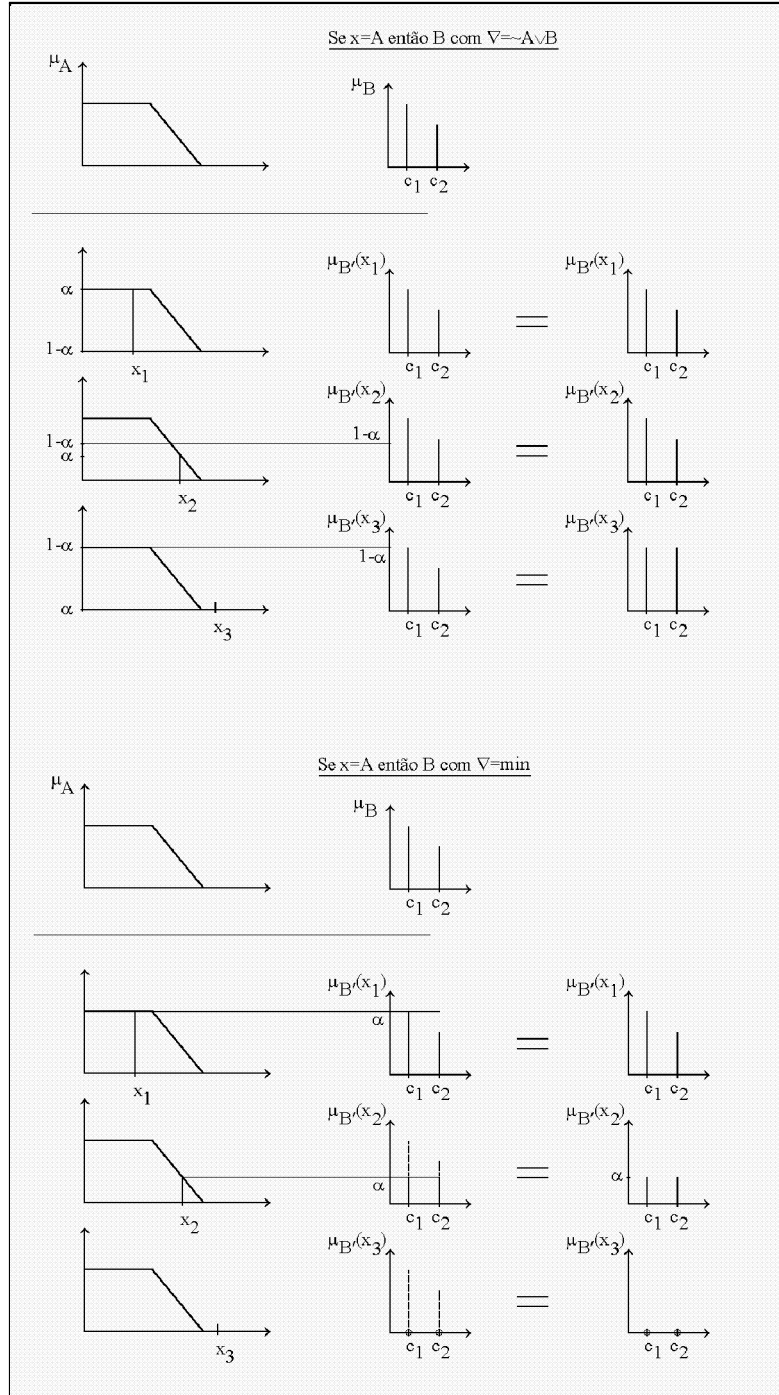


Fig. 2.1: Raciocínio nebuloso simplificado com uma regra e com implicação $\nabla = \sim A \vee B$ e $\nabla = \min$, e com exemplo de 3 fatos precisos $x^* = x_i$.

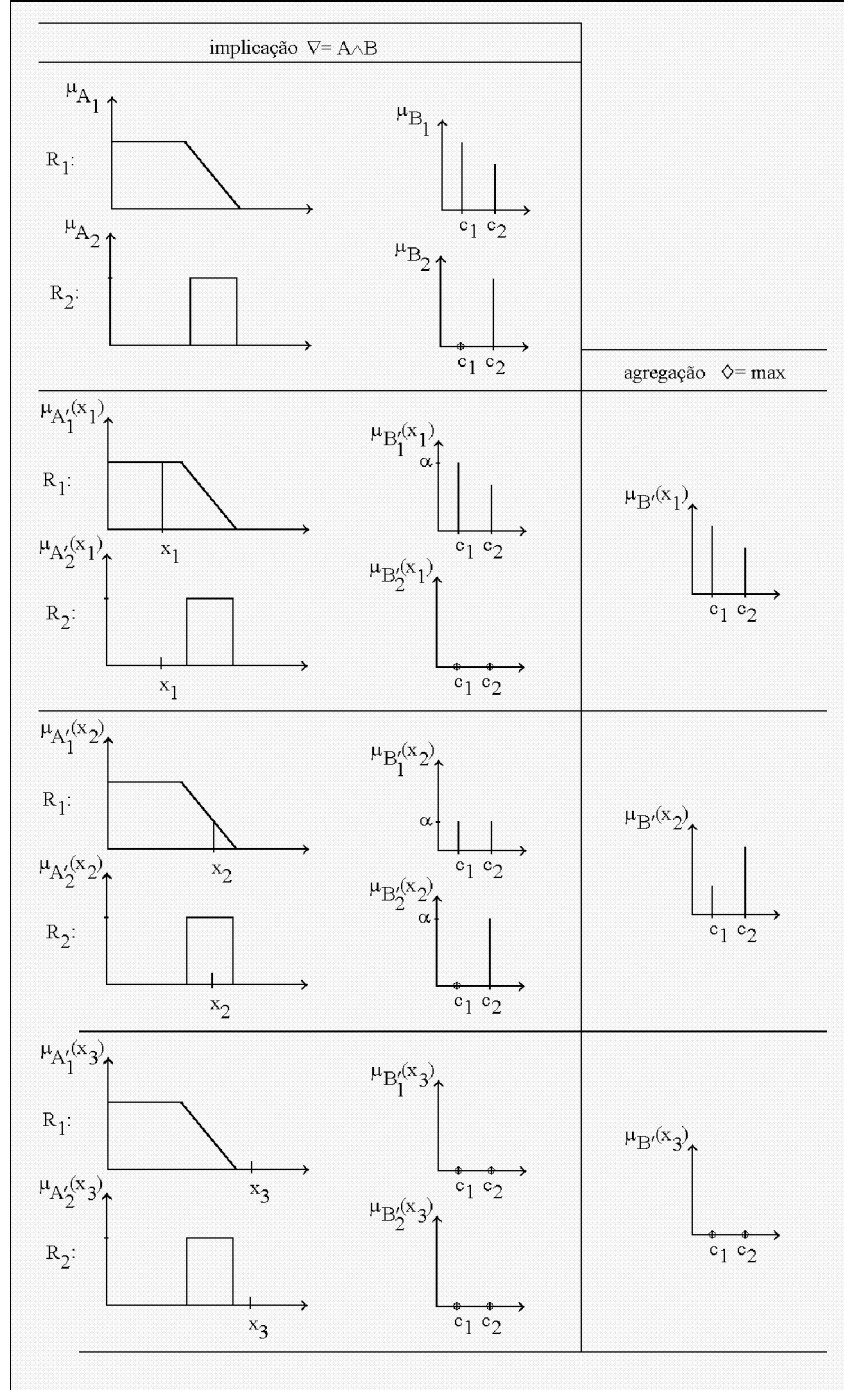


Fig. 2.2: Agregação com $\diamond = \max$ para a função de implicação $\nabla = \min$.

□

O operador que implementa \Diamond é usualmente escolhido em função da implicação ∇ usada. Quando $\nabla(a, b) = \max(1 - a, b)$, denotado por $\nabla = \sim A \vee B$, escolhe-se para \Diamond uma t-norma qualquer. Quando $\nabla(a, b) = \top(a, b)$, denotado por $\nabla = \top$, escolhe-se para \Diamond uma t-conorma qualquer.

2.3. Conceitos da Morfologia Matemática

Para maior facilidade no entendimento do trabalho, apresenta-se a seguir alguns conceitos da Morfologia Matemática que serão utilizados nesse trabalho.

Definição 10. (Birkhoff, 1967) Um conjunto parcialmente ordenado (L_1, \leq_{L_1}) que para quaisquer dois de seus elementos, denotados por a e b , possuir um maior limitante inferior (ínfimo), denotado por $a \wedge_1 b$ e um menor limitante superior (supremo), denotado por $a \vee_1 b$, é um *reticulado*.

Definição 11. (Birkhoff, 1967) Um reticulado L_1 é um *reticulado completo* quando cada um dos seus subconjuntos tem um supremo e um ínfimo em L_1 .

Definição 12. Seja (K_1, \leq_{K_1}) um conjunto parcialmente ordenado. Se a relação \leq_{K_1} é uma relação de ordem total, então K_1 é uma *cadeia*.

Definição 13. Uma cadeia que possua um maior elemento e um menor elemento é uma *cadeia limitada*.

Exemplos de cadeias limitadas, com a relação de ordem \leq do conjunto dos números inteiros:

$$\begin{aligned} K_1 &= \{0, 1\} \\ K_2 &= \{0, 1, 2, 3\} \\ K_3 &= \{0, 1, \dots, 255\} \end{aligned}$$

□

Proposição 1. Toda cadeia limitada é um reticulado.

A utilidade da cadeia limitada para nosso estudo reside no fato de que o contra-domínio de uma imagem em níveis de cinza é uma cadeia limitada (há uma ordenação e limites bem definidos). Nos exemplos acima, K_1 representa o conjunto de níveis de cinza de uma imagem binária e K_3 é o conjunto de níveis de cinza das imagens usadas na maioria das aplicações.

Podemos assim, visualizar mapeamentos entre imagens em níveis de cinza, entre imagens binárias, ou mesmo de imagens em níveis de cinza para imagens binárias ou vice-versa, como mostra a Figura 2.3.




Fig. 2.3: Transformação sobre imagens.

Definição 14. Uma transformação $\Psi : L_1 \rightarrow L_2$ entre imagens é *crescente* se:

$$\forall a, b \in L_1, a \leq_{L_1} b \Rightarrow \Psi(a) \leq_{L_2} \Psi(b)$$

Definição 15. Uma transformação $\Psi : L_1 \rightarrow L_2$ entre imagens é *decrecente* se:

$$\forall a, b \in L_1, a \leq_{L_1} b \Rightarrow \Psi(b) \leq_{L_2} \Psi(a)$$

A definição axiomática é dada para algumas classes de operadores de L_1 em L_2 como se segue:

Definição 16. Seja Ψ , um operador de L_1 em L_2 , sendo L_1 e L_2 dois reticulados finitos, com $i_1 = \sup L_1$ ($i_2 = \sup L_2$) e $o_1 = \inf L_1$ ($o_2 = \inf L_2$):

- Ψ é uma *dilatação* $\Leftrightarrow \Psi(a \vee_1 b) = \Psi(a) \vee_2 \Psi(b)$ e $\Psi(o_1) = o_2$
- Ψ é uma *erosão* $\Leftrightarrow \Psi(a \wedge_1 b) = \Psi(a) \wedge_2 \Psi(b)$ e $\Psi(i_1) = i_2$
- Ψ é uma *anti-dilatação* $\Leftrightarrow \Psi(a \vee_1 b) = \Psi(a) \wedge_2 \Psi(b)$ e $\Psi(o_1) = i_2$
- Ψ é uma *anti-erosão* $\Leftrightarrow \Psi(a \wedge_1 b) = \Psi(a) \vee_2 \Psi(b)$ e $\Psi(i_1) = o_2$

No caso de K_1 e K_2 serem duas cadeias limitadas, a definição se simplifica, tornando-se um caso particular da proposição 1.4 de Banon (1995).

Definição 17. Sejam K_1 e K_2 duas cadeias limitadas. Seja também Ψ um mapeamento de K_1 para K_2 , então:

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

Na Figura 2.4, podemos visualizar exemplos de operadores elementares respectivamente de dilatação, erosão, anti-dilatação e anti-erosão, em acordo com as definições 16 e 17, usando $K_1 = K_2$.




Fig. 2.4: Exemplos de operadores morfológicos elementares.

É importante salientar que um operador Ψ pode vir a não se enquadrar em apenas um tipo. A título de ilustração, mostramos na Figura 2.5 quatro exemplos onde os operadores são, ao mesmo tempo: (a) dilatação e erosão, (b) anti-dilatação e anti-erosão, (c) dilatação e anti-erosão e (d) erosão e anti-dilatação. Fica fácil notar, pela definição 17, a duplicidade de tipos desses operadores.

As transformações elementares da Morfologia Matemática (dilatação, erosão, anti-dilatação e anti-erosão) entre imagens em níveis de cinza podem ser caracterizadas de maneira diferente por resposta impulsiva (função de espalhamento pontual, ou borrão, ou por elementos estruturantes, ou por família de ELUTs) (Banon 1995). As LUTs ("Look Up Tables") são mapeamentos entre níveis de cinza e as ELUTs ("Elementary Look Up Tables") são LUTs com propriedades de transformações elementares da Morfologia Matemática (dilatação ou erosão ou anti-dilatação ou anti-erosão).

Em particular, na Morfologia Matemática binária (Serra, 1982), as definições de dilatação e erosão podem ser dadas de formas equivalentes mais simples. Nesse caso, cabem algumas definições iniciais.

Definição 18. Seja E um espaço arbitrário e seja $P(E)$ a coleção de todos os seus subconjuntos X , ou seja: $P(E) = \{X : X \subset E\}$. A coleção $P(E)$ provida da relação de inclusão (\subset), forma um conjunto parcialmente ordenado, denotado por $(P(E), \subset)$. Essa ordenação garante a existência do maior conjunto (o próprio E) e do menor conjunto (o conjunto vazio, denotado por \emptyset).

Definição 19. Dado um conjunto X , sua translação por um vetor t , seu complemento e sua transposição (simetria com relação a origem), são denotados por: X_t , X^c e X^t , respectivamente, e dados por:




Fig. 2.5: Exemplos de alguns operadores morfológicos de dupla função.

$$\begin{aligned}
 X_t &= X + t = \{x : x - t \in X\}; \\
 X^c &= \{x \in E : x \notin X\}; \\
 X^t &= \{x : -x \in X\}.
 \end{aligned}$$

Nesse momento, é possível construir a dilatação e a erosão invariante por translação da Morfologia Matemática binária:

Proposição 2. Seja $B \in P(E)$. O operador δ_B de $P(E)$ em $P(E)$ dado por:

$$\delta_B(X) = X \oplus B = \cup_{b \in B} X_b,$$

onde $X \oplus B$ é a soma de Minkowski entre os dois conjuntos X e B (Banon e Barrera, 1994), é uma dilatação de $(P(E), \subset)$ em $(P(E), \subset)$. $\delta_B(X)$ chama-se dilatação de X relativamente ao borrão B .

Obs.: A equivalência entre dilatação relativo ao "borrão" e dilatação por "elemento estruturante" é dada em Banon (1995).

Proposição 3. Seja $B \in P(E)$. O operador ε_B de $P(E)$ em $P(E)$ dado por:

$$\varepsilon_B(X) = X \ominus B = \{y \in E : B + y \subset X\},$$

onde $X \ominus B$ é a diferença de Minkowski entre os dois conjuntos X e B (Banon e Barrera, 1994), é uma erosão de $(P(E), \subset)$ em $(P(E), \subset)$. $\varepsilon_B(X)$ chama-se erosão de X pelo elemento estruturante B .

Na prática, a grande maioria dos borrões e dos elementos estruturantes são simétricos, isto é, $B \equiv B^t$, como no caso dos quadrados, discos, cruzeiros, etc (quando centrados na origem).

As demais definições de anti-dilatação e anti-erosão binárias podem ser encontradas em Banon (1995).

A seguir serão dadas definições particulares de alguns operadores da Morfologia Matemática que são utilizados no decorrer deste trabalho.

2.3.1. A Função Distância

Seja Z o conjunto dos inteiros e seja E um retângulo de Z^2 representando um subconjunto da grade quadrada. A função distância é uma transformação $\Psi_d : K_1^E \rightarrow K_2^E$, onde $K_1 = \{0, k_1\}$ e $K_2 = \{0, \dots, k_2\}$ com $k_1, k_2 \in Z^+$, dada por (Barrera et al., 1995):

$$\Psi_d(f)(x) = d(x, \{y \in E : f(y) = 0\})$$

onde

$$d(x, X) := \min \left\{ \left\lfloor d(x, y) + \frac{1}{2} \right\rfloor : y \in X \right\} \quad X \subset E$$

onde $\lfloor a \rfloor$ retorna o maior valor inteiro menor ou igual que o valor a , e $d : E \times E \rightarrow R$, é uma distância. Ou seja, essa transformação associa a cada "pixel" de valor k_1 da imagem de entrada, sua distância ao mais próximo "pixel" com valor 0.

A função distância é frequentemente usada como ferramenta auxiliar para determinar transformações morfológicas como por exemplo, a erosão última e o esqueleto ou o SKIZ ("Skeleton by Influence Zones", ou esqueleto por zonas de influência). Dela pode ser igualmente obtida dilatações por disco de todos os diâmetros (Vincent, 1990, pg 57). Pode-se determinar a função distância do objeto ao fundo da imagem e depois limiarizar, o que produz erosões por discos. Com combinações dessas últimas operações pode-se chegar a aberturas e fechamentos por discos.

Na Figura 2.6 pode-se ver o resultado da função distância aplicada a uma imagem binária com três círculos (onde o valor 0 é associado a cor preta e o valor 1 a branca). No caso 1, a imagem de entrada é invertida e obtemos a distância fora do objeto (o valor 0 é associado a cor vermelha). No caso 2, a imagem não é invertida e obtemos a distância dentro do objeto (o valor zero é associado a cor azul).

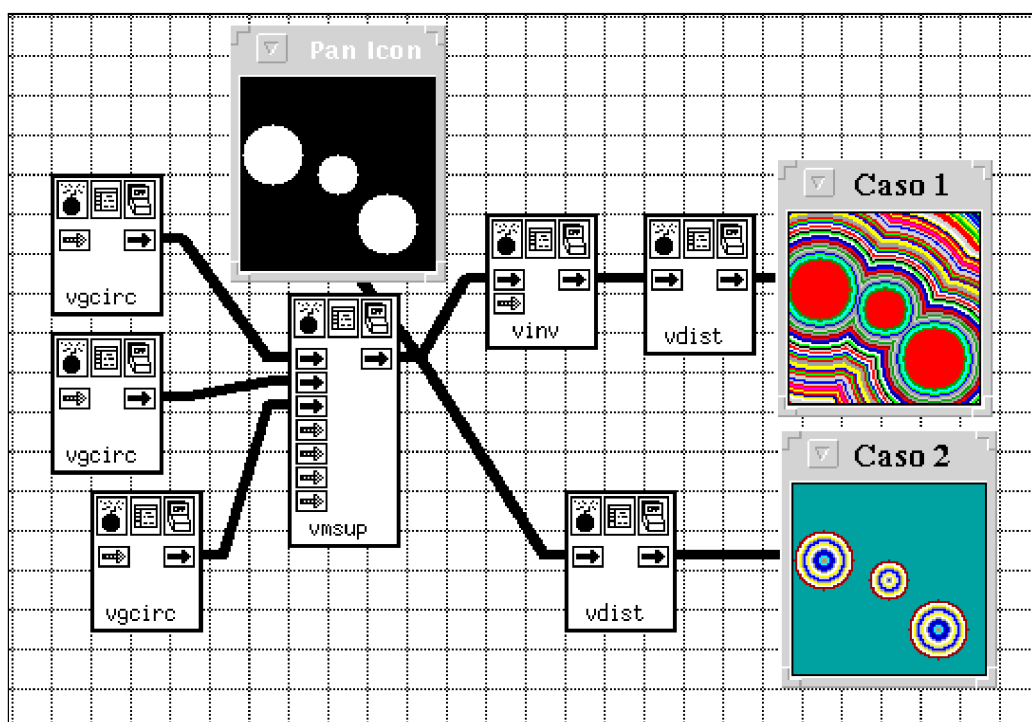


Fig. 2.6: Aplicação da função distância a uma imagem binária com três círculos no Khoros 1.0.5.

Na Figura 2.7 apresenta-se uma construção da função distância em termos de erosões de imagens binárias. Observa-se que a função distância é uma união de composições de erosões por elementos estruturantes $B \subset E$ e, transformações por "Elementary Look Up Tables" (ELUTs) (Banon 1995). Nesse caso, os elementos estruturantes B são discos (Vincent, 1990). Na Figura 2.7, o elemento estruturante nB é o resultado de uma sucessão de $n - 1$ composições da adição de Minkowski aplicado a B , isto é, $nB = (B \oplus B) \dots \oplus B$, para $n \geq 1$ (quando $n = 0$, $nB = \{o\}$) (Barrera et al., 1995). As ELUTs são funções de $\{0, k\}$ em $K = \{0, 1, \dots, n + m\}$, onde k é um valor inteiro e a cadeia K depende do número de linhas n e do número de colunas da imagem em questão.




Fig. 2.7: A função distância em termos de operadores morfológicos.

Além das aplicações mencionadas da função distância (dilatação, erosão, esqueleto, etc), uma outra em particular pode ser vista em (Desachy, 1991) em sistemas automáticos de classificação. Desachy (1991) utiliza-se da função distância para construir um dos parâmetros necessários para um sistema automático de classificação.

2.3.2. A Limiarização

A limiarização de uma imagem $f : E \longrightarrow \{0, \dots, 255\}$ relativo ao intervalo $[a, b]$ é o operador dado por:

$$\text{limiarização}_{[a,b]}(f)(x) = \begin{cases} 255, & \text{se } f(x) \in [a, b] \\ 0, & \text{caso contrário} \end{cases}$$

2.3.3. A Abertura por Reconstrução

Seja B um elemento da coleção $\mathcal{P}(E)$ e seja Y um subconjunto de E . O operador $\gamma_{B,Y}$ sobre $\mathcal{P}(E)$ é denominado abertura por reconstrução e é dado por (Banon e Barrera, 1994):

$$\gamma_{B,Y} = \bigcup_{n=1, \dots} \delta_{B,X}^n(Y), \text{ para qualquer } X \text{ em } \mathcal{P}(E).$$

2.3.4. O Sup-gerador

Sejam A e B dois elementos da coleção $\mathcal{P}(E)$, tais que $A \subset B$. O operador $\lambda_{A,B}$ sobre $\mathcal{P}(E)$ é denominado sup-gerador e é dado por (Banon e Barrera, 1994):

$$\lambda_{A,B} = \varepsilon_A \wedge \delta_{B^t}^a, \text{ para qualquer } X \text{ em } \mathcal{P}(E).$$

2.4. O Sistema Khoros

O sistema Khoros é um ambiente de aplicação e desenvolvimento de software para processamento, análise, exploração e visualização de dados multidimensionais (Khoral, 1996). Em particular, no caso específico do nosso trabalho, o Khoros proporciona uma boa variedade de programas para processamento de imagens podendo inclusive receber aplicações bastante diversas, como por exemplo controle de processos, análise de imagens médicas e análise numérica. Sua modularidade permite que ele seja utilizado como um conjunto de bibliotecas programadas visualmente em um ambiente específico denominado *Cantata*. Essas bibliotecas são denominadas "Toolboxes" e o Khoros, em sua versão original, possui as seguintes (Khoral, 1996):

- Bootstrap: contém o Khoros básico e ferramentas de portabilidade.
- Dataserv: contém bibliotecas para manipulação de grandes volumes de dados, além de permitir conversão de tipos de dados.
- Datamanip: contém operadores de manipulação de dados uni-dimensionais até n-dimensionais.

- Design: contém bibliotecas que tornam possível a programação visual e a criação de novas "Toolboxes" pelo usuário.
- Matrix e Image: oferecem operadores para análise numérica e o processamento de imagens.
- Envision e Geometry: contém operadores interativos para visualização e análise de dados 2-D e 3-D.
- Support: é uma coleção de programas utilitários para o ambiente de desenvolvimento.
- Migration: contém utilitários para a conversão de trabalhos realizados em versões anteriores do Khoros.
- Sampledata: contém exemplos de aplicação.
- Retro: É fornecida como cortesia para manter a compatibilidade a versões anteriores do Khoros com a versão atual.

Uma grande vantagem do Khoros sobre outras plataformas de Processamento de Imagens reside no fato dele ser uma plataforma aberta e disponível na Internet sem custos adicionais pelo endereço: <http://www.khoral.com/>. Por esses motivos, além dessas "Toolboxes", existem outras também disponibilizadas na Internet. Nos deteremos em particular em uma que auxiliou a execução desse trabalho: a "MMach Toolbox".

A "MMach Toolbox" ("Morphological Machine Toolbox") é um desenvolvimento em parceria do INPE, USP e UNICAMP. Implementa basicamente operadores da Morfologia Matemática e atualmente está na versão 1.4. É a ferramenta principal deste trabalho. Também está disponível para "download" pela Internet pelo endereço: <ftp://ftp.dca.unicamp.br/pub/Khoros/Khoros2/contrib/toolboxes/mmach>.

O trabalho começou a ser desenvolvido utilizando-se a versão 1.3. Com o lançamento da versão 1.4 em fevereiro de 1997, foi executado um trabalho de migração para a nova "release" e o desenvolvimento passou a ser nessa última versão.

2.5. Os Tipos de Classificação de Imagens

Os métodos de classificação dividem-se em dois grandes grupos principais: os não-supervisionados e os supervisionados (Saebo et al., 1985). Os não-supervisionados dividem as classes automaticamente e podem ser baseados no princípio de Fisher (Johnson e Wichern, 1982; Fisher, 1936) da década de 30. Alguns métodos podem ser baseados também em funções discriminantes matemáticas, como por exemplo a Teoria dos Grafos e relações nebulosas (Dunn, 1974); abordagens estatísticas assintóticas (Cooper e Freeman, 1970), ou ainda modelos de pertinência nebulosa (Kent e Mardia, 1988). Segundo Saebo et al. (1985), os supervisiona-

dos são mais precisos por levarem em consideração informações fornecidas pelo usuário, a *verdade terrestre*. Podem ser divididos em dois sub-grupos: os *clássicos* e os *contextuais*. Os primeiros usam a informação contida no próprio "pixel" para sua classificação do mesmo e o segundo atribui uma das classes disponíveis de acordo com a análise do "pixel" e dos seus vizinhos. Para mais detalhes de diversos métodos de classificação, pode-se citar (Swain e Davis, 1978) e (Fukunaga, 1990) sobre classificação clássica e (Fu e Yu, 1980) e (Saebo et al., 1985) a respeito de classificação contextual. Com relação a esta última, (Moraes, 1992) faz comentários a respeito da implementação de uma metodologia contextual e sua comparação direta com uma metodologia de Máxima Verossimilhança no sistema SITIM. Em Baridó (1989), vários métodos - paramétricos e não-paramétricos - são apresentados e comparados a partir de simulações. Neste mesmo trabalho, encontra-se também a versão não-paramétrica da metodologia contextual. A Teoria de Conjuntos Nebulosos também fornece técnicas nebulosas para classificação supervisionada (Bezdek et al., 1986, Béreau e Dubuisson, 1991 e Kissiov e Hajitodorov, 1992). No vasto campo de pesquisa dos classificadores, foram explorados também a utilização de múltiplos classificadores (Ho et al., 1994) para melhoria da acurácia. Recentemente, técnicas baseadas em Redes Neurais tem ganhado força principalmente pela sua característica de aprendizado (Simpson, 1990) e capacidade de adaptação a diversos problemas (Mustavi et al., 1994).

Há ainda o conceito de pós-classificação ou "classificação em fases", onde uma metodologia é empregada para aumentar a acurácia da classificação gerada por outra. Nesse caso específico, podemos citar o trabalho de (Desachy, 1991), onde um pós-classificador inteligente age sobre uma pré-classificação estatística. Existem outros tipos, com características contextuais (vizinhança do "pixel"), como o MAXVER-ICM do Spring (Frery, 1993; INPE, 1997).

2.5.1. A Classificação Visual de Imagens

Esta é uma metodologias de análise para quem não dispõe de nenhum recurso computacional. Trata-se da Classificação ou Interpretação Visual da Imagem (I.V.I.) (Rudorff et al., 1986). A imagem é então adquirida, geralmente em papel, como uma composição colorida ou em níveis de cinza. Este tipo de material é fornecido pelo Instituto Nacional de Pesquisas Espaciais (INPE) podendo ser esta imagem de uma determinada época do ano, mono ou multiespectral, etc; ou seja, há várias opções de modo que o usuário deve procurar a que melhor se adeque à sua necessidade. Tendo a imagem em mãos, o passo seguinte é o de reconhecer o que existe na imagem e extrair dela a informação desejada.

A interpretação visual requer do usuário conhecimentos prévios. Por exemplo, há a necessidade do conhecimento prévio da época adequada do ano da passagem

do satélite para o fim desejado, tipo de produto (colorido ou em níveis de cinza, já que nem sempre o colorido é que traz mais informações), as bandas a serem escolhidas (cada banda reflete uma determinada faixa do espectro - ver Apêndice A ou para trabalhos com monitoramento ambiental, por exemplo, pode-se encontrar boas indicações em Tucker (1978)). Dependendo da finalidade do estudo, a I.V.I. pode requerer mais conhecimentos da área "in loco", o que nem sempre é possível, ou associações com fotos aéreas, entre outros.

Os fotointérpretes podem ser classificados em três grupos: 1) os que possuem conhecimento de campo (possuem dados que refletem a realidade do local em estudo); 2) os que não possuem este conhecimento e, por fim; 3) os que não possuem este conhecimento, mas que possuem fontes de informações adicionais. Os do primeiro grupo tem o trabalho simplificado pelo conhecimento que possuem. Os do terceiro grupo podem ter dificuldades em cruzar as informações de que dispõem com a imagem. Já os do segundo grupo, dificilmente conseguirão fazê-lo sem o uso de *chaves de interpretação* - conhecimentos utilizados que são estruturados como se fossem formulações para se resolver um problema. É de grande valia que o uso das chaves de interpretação seja feita de forma invariante, ou seja, não possa mudar de um fotointérprete para outro. Para isso, criam-se legendas que vão funcionar como critérios de separação das diversas classes. Além de fixar a interpretação, as legendas auxiliam uma leitura mais rápida.

Feita a classificação, parte-se para extrair da imagem as informações que se procura desde o início. Tomando um exemplo agrícola de estimativa de áreas plantadas, pode-se agir de duas formas. Na primeira, usa-se uma malha de pontos proporcionais a escala para se estimar a área, como um método grosseiro de integração. Logicamente que os resultados podem ser induzidos a erros, que podem comprometer todo o trabalho. Uma solução seria trabalhar com uma malha de pontos bastante densa, o que ainda assim proporciona um risco de proporções razoáveis se o terreno em questão tiver um relevo acidentado. Uma segunda forma, já bem mais sofisticada, requer um computador em associação a uma mesa digitalizadora. Os contornos da região são digitalizados com o auxílio da mesa e remetidos a um computador. Os dados podem ser associados a um mapa da região, incorporando informações sobre o relevo. A seguir, um simples processo de integração numérica fornece a estimativa da área com erros bastante aceitáveis. Esta forma, porém é bastante onerosa, mas permite que se leve em consideração a tridimensionalidade. Com a tecnologia atual - a utilização de "scanners" pode transformar o trabalho ainda mais preciso, pois evita o contato manual - a transferência da imagem é feita por um processo digital de leitura. A grande desvantagem destes dois últimos processos (mesa digitalizadora e integração numérica) é a necessidade de "software" específico, nem sempre disponível com facilidade para este tipo de aplicação.

2.5.2. Classificação Assistida por Sistema Especialista

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 consequência interessante, temos que o conhecimento pode ser armazenado em termos de *regras*, ser explicável e poder 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.

A idéia é bastante simples: um conjunto de regras do tipo "SE *condição* ENTÃO *conclusão*" armazena o conhecimento humano sobre determinado fenômeno, visto pela ótica de um especialista. No entanto, nem sempre um especialista tem plena certeza de que tal regra valha em todas as situações, ou que as variáveis possam ser medidas com total acurácia. Essa incerteza pode ser medida usando-se a probabilidade, as funções de pertinência, possibilidades e necessidades (Granger, 1988), ou ainda as probabilidades nebulosas. O problema de "como" combinar as medidas de incerteza para dar uma resposta final, pode ser resolvido de diferentes formas, de acordo com o caminho escolhido. Em (James, 1985), (Senne, 1988) e (Kruse et al., 1991), podem ser vistas explicações sobre o tratamento desses casos.

3. SISTEMAS ESPECIALISTAS PARA CLASSIFICAÇÃO DE IMAGENS

”Um dia o homem olhará para o céu
e verá que tão pequena quanto aparentam as estrelas no céu
é a sua vã existência. Só aí então, tomará consciência
da grandeza da vida que ele desperdiça”

Autor anônimo.

Várias implementações práticas de classificadores existem na literatura. Como exemplos disso podemos citar:

- o sistema ICARE (Desachy, 1991) que procura gerar um mapa para uma região, com um sistema especialista ”nebuloso” agindo sobre uma pré-classificação estatística, mapas e classificações anteriores da região de interesse;
- O trabalho de Haverkamp et al (1994) que combina métodos numéricos e heurísticas para a classificação de blocos de gelo no mar por imagens de radar. É um classificador de 3 passos, onde, no primeiro passo é feita uma pré-classificação estatística simples, no segundo passo extrai-se atributos para no terceiro passo aplicar regras sobre eles e sobre a classificação inicial.
- O trabalho de Mascarilla (1995) que é uma versão do sistema ICARE com conhecimento armazenado em uma rede neural nebulosa, podendo tratar conhecimento expresso em linguagem natural.
- O trabalho de Wendling et al (1995) que faz a interpretação de imagens de satélite por conhecimento acerca das classes procuradas, similar ao ICARE (Desachy está entre os autores). Também existe uma pré-classificação que agora é realizada por uma técnica nebulosa.
- O trabalho de Mathieu-Marni et al (1996) que utiliza um sistema especialista que gerencia uma biblioteca de programas para computação de misturas de classes e classificação de imagens Spot e Landsat.
- O trabalho de Roux e Desachy (1997) que usam informações de um classificador nebuloso e de um sistema especialista dado por uma rede neural nebulosa. A fusão das informações dessas duas fontes é usada para a classificação.

- O trabalho de Queiroz et al (1997) que utiliza um pequeno sistema especialista nebuloso para classificação de axônios, cujas descrições são obtidas por operadores da Morfologia Matemática. Apesar de não ser um classificador de imagens, é interessante observar que esse sistema poderia ser utilizado para tal, com algumas modificações.

3.1. O Sistema de Interpretação de Imagens ICARE

Como o sistema proposto tem uma inspiração no trabalho inicial de Desachy (1991), será dada aqui uma breve descrição do seu trabalho.

O sistema proposto por Desachy é um classificador automático de imagens, simulando a interpretação visual de imagens, denominado ICARE ("Image Cartographie Expert"), com o objetivo de gerar novas cartas topográficas de uma certa região. O número de classes é limitado em 14 e Desachy as chamou de classes *ecoflorísticas*.

O algoritmo de classificação é dividido em três fases, sendo a primeira denominada de *pré-classificação*. Nessa pré-classificação o sistema obtém os valores numéricos para todas as classes possíveis de um "pixel", levando em consideração a radiometria e a textura. Para cada "pixel", a pré-classificação retém apenas os três maiores valores resultantes da função de classificação. A segunda fase, denominada *fase 1 da classificação*, é auxiliada por um sistema especialista, utilizando-se de dados de Modelos Numéricos de Terreno (MNT). Na terceira fase, denominada *fase 2 da classificação*, o sistema especialista utiliza-se de informações sobre Cartas Topográficas anteriores, para aprimorar a classificação. Nas duas últimas fases o sistema mantém três valores resultantes da função de classificação e somente ao final decide pela classe que produz o maior valor da função de classificação.

Nas fases 1 e 2 de classificação, são necessários dados referentes a área em estudo, tais como mapa de estradas, rios, cidades, isolinhas, etc. Uma boa fonte desse tipo de informação são os Sistemas Geográficos de Informação (SIG). Para manipular as informações oriundas do SIG de forma inteligente, Desachy utiliza um sistema especialista. Esse sistema pode, por exemplo, determinar se um "pixel", estando próximo a uma estrada, favorece alguma classificação em especial. Essa determinação se faz com o auxílio da teoria dos conjuntos nebulosos (no caso, o subconjunto *perto*) aplicada a função distância.

O sistema ICARE (Desachy, 1991) faz parte do diagrama esquemático da Figura 3.1. Devemos notar que a fonte de dados do sistema ICARE também pode ser uma classificação gerada anteriormente.

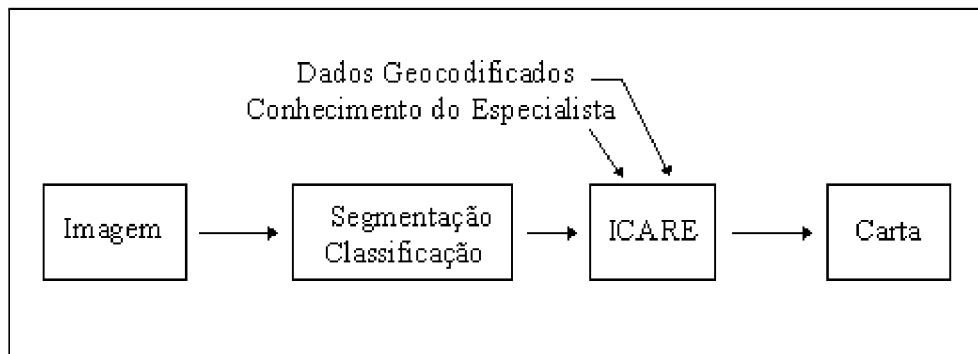


Fig. 3.1: Diagrama geral de um sistema de interpretação de imagens.

Duas bases de dados são utilizadas por Desachy: a Base de Conhecimento (construída a partir de descrições das zonas florísticas) e, a Base de Dados. Na Base de Conhecimento encontram-se informações sobre a vegetação característica das regiões por tipo ou utilização do solo, clima e topografia. Na Base de Dados encontram-se modelos numéricos de cartas climáticas, de solos e topográficas.

As Tabelas 3.1 e 3.2 mostram exemplos de conhecimento armazenados para uma determinada classe (zona ecoflorística, segundo Desachy (1991)). A Tabela 3.1 trata do conhecimento sobre uma classe por dados ecológicos (dados de situação ou localização espacial, clima e tipos de solos) e dados florísticos (área de domínio e tipos de árvores características). A Tabela 3.2 trata do conhecimento sobre cinco classes por dados de localização, tipos cultivados e detecção (tipos de critérios, estação e melhor forma de detecção).

TABELA 3.1 - EXEMPLO DE CONHECIMENTO SOBRE UMA DETERMINADA ZONA ECOFLORÍSTICA POR DADOS ECOLÓGICOS E FLORÍSTICOS.

	Dados		Ecológicos	Dados	Florísticos
Situação	Clima	Solos	Ocupação Humana	Domínio Florístico	Árvores Características
Versante Oeste dos Ghâts ocidentais entre 900 a 1000 m de altitude	Tropical úmido $T = 26^{\circ}C$ $T_m = 20^{\circ}C$ $dt = 3$ a $4^{\circ}C$ $P > 2000m$ 1 à 3 m. s.	ferralíticos às vezes com couraças laterais	Densidade da população muito alta nas partes baixas (600 hab/km^2)	Domínio Ocidental setor Travancore de baixa altitude	dipterocarpaceae cullenia exarillata mesua ferrea disoxylum malabaricum alstonia scholaris

FONTE: Desachy (1991, p. 41).

Note-se que em ambas as tabelas há informações de características locais: os Ghâts e o lago Periyar, localizados na região centro-sul da Índia (Desachy, 1991, p. 40).

O processo de classificação utilizado contém três fases, ou etapas, sendo que as duas últimas fazem uso das bases de Conhecimento e de Dados. O objetivo é aperfeiçoar uma classificação inicial (pré-classificação) utilizando um sistema especialista que manipula o conhecimento armazenado na Base de Conhecimento. Esse conhecimento em certas ocasiões depende de dados que estão armazenados na Base de Dados (como altitude, tipo de clima, tipo de solo, etc).

TABELA 3.2 - EXEMPLO DE CONHECIMENTO SOBRE UMA DETERMINADA ZONA ECOFLORÍSTICA POR DADOS DE VEGETAÇÃO.

Tipos espontâneos	Vegetação				
	Localização	Tipos Cultivados	Detecção		
			critérios	melhor forma	melhor estação
1. Floresta densa úmida	- Vestígios nos fundos dos vales.	Mosaico de culturas e de vegetação degradada: - quaisquer coqueirais -pomares+ mandioca+ especiarias -Quaisquer reflorestamentos de Eucaliptos -rizicultura	Textura densidade reflectância	Bandas 5 e 7	Dezembro à Março
2. Floresta densa úmida	- Vestígios		textura densidade	BC-FCC	Março
3. Floresta úmida degradada	- Vestígios		Textura tonalidade		
4. Savana arbórea	- Reservas perto do lago Periyar		Textura	FCC	Indiferente
5. Mosaico de culturas e de vegetação degradada	- Tipo largamente dominante			FCC	

FONTE: Desachy (1991, p. 41).

Definição das Classes

A metodologia trabalha com informações oriundas de uma imagem multi-espectral, com bandas B_1, B_2, \dots, B_b . Porém, é muito oneroso computacionalmente trabalhar com todas as bandas de uma imagem e por esse motivo, é feita uma transformação de Karhunen-Loève, gerando apenas duas bandas $KL1$ e $KL2$. Essas duas bandas contém apenas informações radiométricas. Para obter informações de textura a partir da imagem radiométrica, utilizamos a metodologia de Haralick et al. (1973).

A partir dessas duas bandas $KL1$ e $KL2$, há uma redução dos níveis de cinza (por exemplo 256) para quatro. São obtidos os parâmetros de textura, extraídos de matrizes de co-ocorrências de Haralick et al. (1973) de níveis de cinza, sendo utilizados 10 parâmetros de textura (t_1 a t_{10} para a banda $KL1$ e tt_1 a tt_{10} para a banda $KL2$). Seu objetivo é embutir em cada pixel a informação da textura proveniente de uma vizinhança de 8 pixels ao pixel dado.

Supõe-se que as classes têm distribuição Gaussiana e cada classe é definida pelas médias e variâncias radiométricas das bandas $KL1$ e $KL2$ (2 parâmetros) e pelas médias e variâncias dos parâmetros de textura, também para cada uma das bandas $KL1$ e $KL2$ (são os 10 parâmetros obtidos pelo método de Haralick et al. (1973) para cada uma das bandas, totalizando 20 parâmetros). Assim, essa distribuição Gaussiana possui uma dimensão 22.

$$\begin{aligned}\mu &= \{ \mu(KL1), \mu(KL2), \mu(\text{texturas em } KL1), \mu(\text{texturas em } KL2) \} \\ \sigma^2 &= \{ \sigma^2(KL1), \sigma^2(KL2), \sigma^2(\text{texturas em } KL1), \sigma^2(\text{texturas em } KL2) \}\end{aligned}$$

Pode-se notar que não foi mencionada nenhuma matriz de covariâncias para as variáveis de textura. Desachy (1991) assume a independência dessas variáveis, fazendo com que a matriz de covariâncias torne-se uma matriz diagonal, na qual estão presentes somente as variâncias de cada uma dessas variáveis. Como decorrência, os cálculos são mais rápidos.

Pré-Classificação

A pré-classificação é efetuada utilizando-se um método geométrico de classificação que mede a distância $d(x, y)$ entre a "assinatura" espectral do pixel e cada classe. Uma classe m_i é válida para um determinado "pixel", se a distância d entre as assinaturas espectrais do "pixel" e a classe m_i é menor ou igual a S , onde $S \in R$ é um limiar ($S > 1$), onde:

$$d_i(x, y) = \gamma_1 \left[\left(\frac{I_{KL1}(x, y) - \mu_{IKL1}}{\sigma_{IKL1}} \right)^2 + \left(\frac{I_{KL2}(x, y) - \mu_{IKL2}}{\sigma_{IKL2}} \right)^2 \right] + \\ + \gamma_2 \left[\sum_{j=1}^{10} \left(\frac{t_j - \mu_{tj}}{\sigma_{tj}} \right)^2 + \sum_{j=1}^{10} \left(\frac{tt_j - \mu_{ttj}}{\sigma_{ttj}} \right)^2 \right]$$

Para cada pixel, retemos três classes que possuam as menores distâncias d e que estas sejam inferiores a um limiar S . Calcula-se então uma função $P : [0, 1] \rightarrow [0, 1]$ (que Desachy (1991) denomina probabilidade em seu trabalho) para cada uma dessas três classes:

$$P_i(x, y) := 1 - (d_i(x, y)/S), i = 1, 2, 3 \quad (x, y) \in E, \quad (3.1)$$

que serão retidas pelo sistema para aquele ponto (x, y) .

É digno de nota que para o cálculo de $d_i(x, y)$, leva-se em consideração alguns fatores auxiliares: γ_1 e γ_2 (assumindo valores no intervalo $[0, 1]$) (Desachy, 1991). Esses fatores ponderam a contribuição das informações radiométricas e texturais na classificação.

Primeiro Nível de Classificação

O conhecimento do especialista intervirá nas duas últimas fases da classificação, fazendo com que o valor da função P_i de uma classe m_i de um pixel (x, y) permaneça inalterada, diminua menos ou mais, caso sua localização seja totalmente favorável, favorável ou desfavorável a essa determinada classe. Isso ocorre em duas etapas, de acordo com o tipo de característica tratada (características de nível 1 ou de nível 2) - Figura 3.2.

A construção da base de conhecimento deve satisfazer a dois critérios:

- 1) Facilitar a expressão do conhecimento pelo especialista sobre as classes
- 2) Facilitar o cálculo para cada ponto do seu contexto para cada classe possível.

Segundo Desachy (1991), isso o obriga a definir de 4 tipos de características, a partir das quais o conhecimento será representado:

- CTO (características do tipo de objeto): indica qual entidade (objeto) está sendo considerada, dentro de um determinado contexto de classe.

Exemplo: vila, estrada, etc.

□

- CTR (características do tipo relacional): descreve a relação entre a classe e o objeto definido pelo CTO.

Exemplo: perto, longe, etc.

□

- CTP (características do tipo de presença): define um grau de incerteza sobre a descrição de uma classe, que é quantificado em p_{pres} . Desachy (1991) apresenta esse grau p_{pres} de forma tabelada e o denomina "probabilidade de presença".

Exemplo:

CTP	sempre	principalmente	predominante	frequente	presente	jamais
p_{pres}	1.00	0.85	0.70	0.55	0.40	0.00

(3.2)

□

- CTS (características de tipo espacial): exprime certas características de classes de nível 2 (relacionadas ao contexto, como superfície, forma, etc).

A partir dessas 4 características representa-se o conhecimento sobre cada classe, dependendo do nível em que atua:

Para o nível 1:

((CTP.CTR.CTO) E (CTP.CTR.CTO) E ...)

OU

((CTP.CTR.CTO) E (CTP.CTR.CTO) E ...)

OU ...

Exemplo:

((COMUM. PERTO. VILA) OU (COMUM. PERTO. RUA))
 CTP CTR CTO CTP CTR CTO

□

Para o nível 2:

((CTP.CTS) E (CTP.CTS) E ...)

OU

((CTP.CTS) E (CTP.CTS) E ...)

Exemplo:

"Todos os cumes altos antigos ou fundos de vales antigos"

para o nível 1: (todos.altos.cumes) OU (todos.fundos.vales)

para o nível 2: (todos.antigos)

□

As características CTP, CTR e CTO são utilizadas no primeiro nível de classificação, para melhorar a pré-classificação. Essas características participam na construção do fator $b(x, y)$ que é um fator de correção. Esse fator modifica o valor da função P de cada "pixel". O princípio utilizado é aumentar a diferença entre os três valores da função P para um dado "pixel" (x, y) se o contexto é favorável a uma das classe dada e diminuí-la caso contrário.

Sendo assim, a função de classificação $P_i^{(1)}(x, y)$ para o nível 1, é dada por:

$$P_i^{(1)}(x, y) := b_i(x, y) * P_i(x, y), \quad (3.3)$$

onde $b_i(x, y)$ é o fator de correção global para o ponto (x, y) e classe m_i .

O fator de correção global $b_i(x, y)$ depende da característica global de nível 1 da classe m_i (conhecimento armazenado na base de conhecimento) e da localização do "pixel" em relação à base de dados geocodificados. Sua forma de cálculo é dada a seguir:

A partir de cada característica parcial da forma $(CTP_i.CTR_i.CTO_i)$, produz-se um fator de correção parcial $pcar_i(x, y)$. CTP_i define uma função de presença (que no trabalho de Desachy (1991) é denominada "probabilidade de presença"), já mencionada. CTR_i introduz um nível de pertinência nebuloso ao objeto CTO_i , $appar(x, y)$ que pode ser interpretado como o grau de realização (valor no intervalo $[0, 1]$) de uma característica "proximidade".

Exemplo:

Se um "pixel" (x, y) situa-se a uma distância de 200 metros de uma rua, o grau de realização da característica "perto de rua" é fornecido por uma função de pertinência de um sub-conjunto nebuloso "perto de rua". Por essa função, necessariamente, quanto mais próximo o ponto for da rua, maior será o seu grau de realização e a medida em que a distância for maior, o grau diminui. Em termos práticos, isso pode ser obtido por uma transformação sobre a *função distância* (vista na seção anterior) de modo a fornecer altos graus de realização quanto menor for a distância entre a rua e o ponto em questão para o referido exemplo.

□

Por fim, o fator de correção parcial $pcar_i(x, y)$ para a característica particular $(CTP_i.CTR_i.CTO_i)$ é definido por:

$$pcar_i(x, y) := p_{pres} * appar(x, y) + (1 - p_{pres}) * (1 - appar(x, y))$$

Dessa forma, quando $appar(x, y) = 1$ temos que $pcar_i(x, y) = p_{pres}$ e quando $appar(x, y) = 0$ temos que $pcar_i(x, y) = 1 - p_{pres}$ ou seja:

$$pcar_i(x, y) = \begin{cases} p_{pres} & \text{se } (CTR_i.CTO_i) \text{ é verdadeiro a } 100\% \\ 1 - p_{pres} & \text{se } (CTR_i.CTO_i) \text{ é falso a } 100\% \end{cases}.$$

O fator de correção global $b_i(x, y)$ é calculado com base em todos os fatores de correção parcial $pcar_i(x, y)$. Para cada composição de interseções das características particulares, calcula-se um fator intermediário $b^{(1)}(x, y)$ que é definido por:

$$b^{(1)}(x, y) := \min_k(pcar_k(x, y))$$

onde k é a quantidade de características particulares que estão presentes na composição de interseções.

Exemplo:

$$(CTP_1.CTR_1.CTO_1 \cap CTP_2.CTR_2.CTO_2 \cap \dots) \cup (\dots) \cup \dots$$

$$b_1^{(1)}(x, y) := \min_{k_1}(pcar_{k_1}(x, y)) \quad b_2^{(1)}(x, y) := \min_{k_2}(\dots)$$

□

Para compor toda a informação, é necessário analisar a composição como um todo, ou seja, analisar também as uniões. O cálculo é dado por:

$$b_i(x, y) := \max_j(b_j^{(1)}(x, y))$$

para a classe m_i e j são os atributos observados pelo sistema especialista, como vila, rio, estrada, etc.

Assim, finaliza-se essa fase de classificação, obtendo como resultado para cada "pixel", os três valores revisados:

$$\begin{aligned} P_1^{(1)}(x, y) &= b_1(x, y) * P_1(x, y) && \text{para a classe } m_1 \\ P_2^{(1)}(x, y) &= b_2(x, y) * P_2(x, y) && \text{para a classe } m_2 \\ P_3^{(1)}(x, y) &= b_3(x, y) * P_3(x, y) && \text{para a classe } m_3 \end{aligned}$$

Segundo Nível de Classificação

Para o nível 2, são utilizadas as características CTP e CTS das classes. No entanto, os cálculos são análogos ao nível 1, inclusive a própria nomenclatura atribuída por Desachy permanece inalterada. O cálculo da função $P_i^{(2)}(x, y)$ é dado por:

$$P_i^{(2)}(x, y) := k_i(x, y) * P_i^{(1)}(x, y), \quad (3.4)$$

onde $k_i(x, y)$ é o fator de correção global no segundo nível de classificação, para o ponto (x, y) e classe m_i .

As características globais do nível 2 diferem das do nível 1 pela utilização do CTS e CTP e, são do tipo:

$$(CTP_1.CTS_1) \cap (CTP_2.CTS_2) \cap \dots \cup (CTP\dots)$$

Para cada característica parcial ($CTP.CTS$) calcula-se um fator de correção parcial:

$$pcar_i(x, y) := p_{pres} * appar(x, y) + (1 - p_{pres}) * (1 - appar(x, y))$$

onde : p_{pres} descreve a confiança (CTP_i) que se dá à afirmação CTS_i , ou seja:

$$p_{pres} := \begin{cases} 1, & \text{certeza a 100\%} \\ 0, & \text{falso a 100\%} \end{cases} \quad (3.5)$$

e, $appar(x, y)$ é o grau de realização de CTS_i no ponto (x, y) .

Exemplo:

Suponha-se que uma formação rochosa em questão é antiga. No sistema ICARE, "antigos" será considerado como "sempre antigos" e então $p_{pres} = 1$ (Desachy, 1991, pg84).

□

O grau $appar(x, y)$ é calculado em função de uma superfície S da região onde se encontra o ponto, em relação a dois limiares pré-definidos S_1 e S_2 (Figura 3.3). Um possível exemplo, é a de classes comuns em determinadas faixas de altitudes que ficam evidenciadas nas imagens dos Modelos Digitais de Terreno.

O mínimo entre todas as imagens $pcar$ resulta na imagem $k^{(2)}$:

$$k_i^{(2)} = \min_j (pcar_j(x, y))$$

para a classe m_i e j é a quantidade de características particulares que estão presentes na composição de interseções.

Novamente, para compor toda a informação, é necessário analisar a composição como um todo, analisando também as uniões, se elas existirem. O cálculo é dado por:

$$k_i(x, y) := \max_j (k_j^{(2)}(x, y))$$

onde j são os atributos observados pelo sistema especialista para a classe m_i .

Finaliza-se então a segunda fase de classificação, obtendo como resultado para cada "pixel", os três valores revisados:

$$\begin{aligned} P_1^{(2)}(x, y) &= k_1(x, y) * P_1^{(1)}(x, y) && \text{para a classe } m_1 \\ P_2^{(2)}(x, y) &= k_2(x, y) * P_2^{(1)}(x, y) && \text{para a classe } m_2 \\ P_3^{(2)}(x, y) &= k_3(x, y) * P_3^{(1)}(x, y) && \text{para a classe } m_3 \end{aligned}$$

E, finalmente, é feita a atribuição do "pixel" (x, y) à uma classe m_i das três classes inicialmente selecionadas, de forma que:

$$\begin{aligned} P_i^{(2)}(x, y) &: = \max_k (P_k^{(2)}(x, y)) \\ \text{classe } (x, y) &= m_i \end{aligned} \quad (3.6)$$

onde k denota as três classes selecionadas para a maximização da função $P^{(2)}$ para cada "pixel".

3.2. Considerações Sobre o Sistema ICARE

O trabalho de Desachy (1991) deixa transparecer a abordagem "ad-hoc". A fase de pré-classificação utiliza-se de uma metodologia complexa de matrizes de textura, enquanto a primeira e segunda fases se encarregam de utilizar dados provenientes de bases de dados e de conhecimento para aperfeiçoar a classificação inicial gerada.

O sistema é pouco formal e as medidas ditas "probabilidades", na realidade não podem ser vistas como tal. O tratamento numérico não é uniforme, misturando "probabilidades" e fatores de correção com interpretações diferenciadas. Isso torna o algoritmo bastante complexo e de difícil compreensão. Por isso o ICARE utiliza-se de uma linguagem para a composição das regras para auxiliar o usuário a interagir com esse complexo sistema.

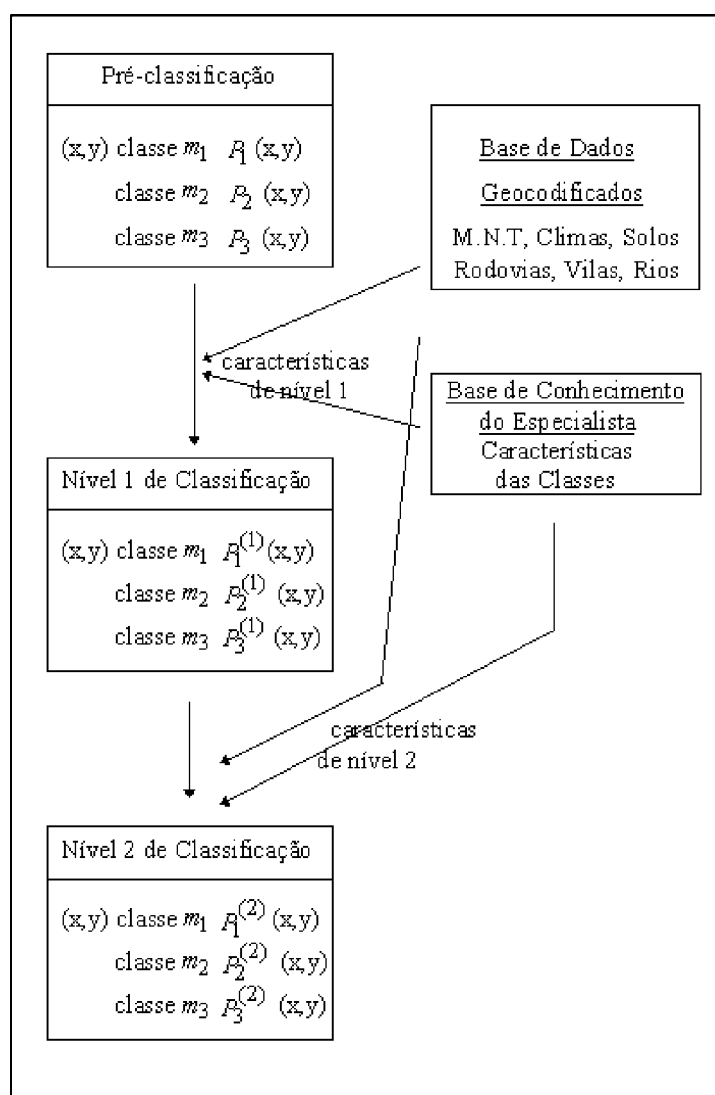


Fig. 3.2: As três fases do sistema ICARE.

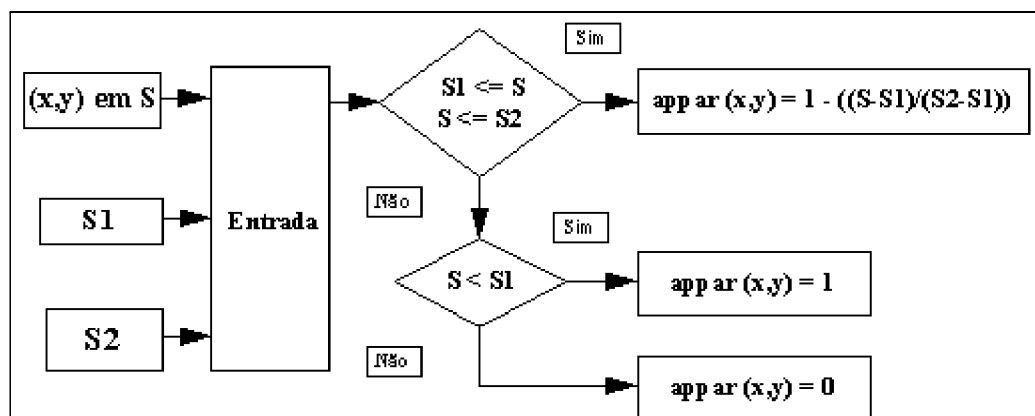


Fig. 3.3: Diagrama de cálculo de $\text{appar}(x,y)$.

4. PROPOSTA DE UM SISTEMA ESPECIALISTA PARA CLASSIFICAÇÃO DE IMAGENS

"A única possibilidade de descobrir os limites do possível é aventurar-se um pouco no terreno do impossível"

Artur C. Clark (1917-)

As regras cumprem papel fundamental na construção de um sistema especialista. É a partir delas que o conhecimento se codifica para a resolução de um problema e por elas um especialista exprime o seu conhecimento a respeito de um fenômeno. Elas podem ser expressas por uma construção do tipo *Se A ocorre e B ocorre então C ocorre*.

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 $K_1 = \{0, 1\}$ e como visto na seção 2.3, K_1 é uma cadeia limitada. Já uma *imagem em níveis de cinza* f mapeia E em $K_2 = \{0, 1, \dots, 255\}$ e como visto na seção 2.3, 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.

A seguir é proposto um sistema especialista nebuloso cujas premissas das regras são explicitadas por composições de operadores da Morfologia Matemática. A maior contribuição deste trabalho é justamente o uso homogêneo da Morfologia Matemática e da Teoria dos Conjuntos Nebulosos na classificação de imagens. Procurando sanar alguns dos problemas apresentados pelo ICARE (ver Capítulo 3), o tratamento numérico é uniforme, em termos de valores de pertinências a conjuntos nebulosos. Essa abordagem facilita o entendimento desse sistema pelo usuário.

4.1. A Arquitetura do Sistema

Para classificar uma imagem é proposto nesse trabalho um conjunto de regras nebulosas *compiladas* em uma seqüência de operadores da Morfologia Matemática implementados na "toolbox" 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 (vide definição 9 do Capítulo 2). 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 e gera 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:

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

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 atributo 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 (ver Capítulo 2).

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 compatibilidade é dado por $h_j(p) = \top(h_{1j}(p), \dots, h_{N_j m}(p))$ - ver Capítulo 2.

OBS.: Se as regras utilizam somente o conectivo OU em lugar do conectivo E, $h_j(p)$ seria dado pela expressão $h_j(p) = \perp(h_{1j}(p), \dots, h_{N_j m}(p))$, onde \perp é uma t-conorma. Caso usem conectivos E e OU, $h_j(p)$ é calculado utilizando t-normas \top e t-conormas \perp convenientemente.

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 μ_{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 ∇ é uma função de implicação (vide Capítulo 2). 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 ∇ é uma t-norma ∇_{\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 $g_k : E \longrightarrow \{0, \dots, 255\}$; um para cada classe c_k em C que são tais que:

$$g_k(p) = \mu_{B'(p)}(c_k), k = 1, \dots, n$$

o que equivale a

$$\begin{aligned} g_k(p) &= \diamond \{ \mu_{B'_{1(p)}}(c_k), \dots, \mu_{B'_{m(p)}}(c_k) \} \\ &= \diamond \{ \nabla [h_1(p), \mu_{B_1}(c_k), \dots, h_j(p), \mu_{B_j}(c_k), \dots, h_m(p), \mu_{B_m}(c_k)] \} \end{aligned}$$

Fazendo $m_{kj} = \mu_{B_j}(c_k)$, temos:

$$g_k(p) = \diamond \{ \nabla [h_1(p), m_{k1}], \dots, \nabla [h_j(p), m_{kj}], \dots, \nabla [h_m(p), m_{km}] \};$$

e fazendo $g_{kj}(p) = \nabla [h_j(p), m_{kj}]$, temos que

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

Quando ∇ é uma t-norma ∇_{\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

$$g_{kj}(p) = \top_i [\mu_{A_{ij}}(atr_i(p))] \quad (4.1)$$

e conseqüentemente

$$g_k(p) = \diamond_j \left\{ \top_i [\mu_{A_{ij}}(atr_i(p))] \right\}. \quad (4.2)$$

Na Figura 4.1, pode-se observar o progresso do raciocínio quando a função de implicação é $\nabla = A \wedge B$. Sejam o evento A definido por um intervalo de níveis de cinza e B é uma classe. Sejam ainda duas regras R_1 e R_2 , tais que: R_1 : Se $f(x) \in A=[0, k_1]$ então B é a classe c_1 e R_2 : Se $f(x) \in A=[k_1, k_2]$ então B é a classe c_2 . Supondo que os fatos sejam: $A'_1 = k_{11} \in [0, k_1]$ e $A'_2 = k_{12} \in [k_1, k_2]$ e dado que esses fatos são valores exatos, então usa-se o esquema de raciocínio inexato simplificado descrito no Capítulo 2. Para cada uma dessas regras, os resultados serão planos $\mu_{B'_j(p)}$ para cada classe, como descritos na Figura 2.1. Dado que as conclusões são dadas por conjuntos nebulosos precisos e supondo que a implicação resulte em planos $\mu_{B'_j(p)}$ de forma análoga àquela Figura, pode-se observar a alteração para os planos $g_{kj}(p)$.

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 estão o método do centro de massa e da média dos máximos (Driankov et al., 1993). Porém, esses dois métodos não podem ser aplicados nesse trabalho, pois o domínio de B não é uma escala contínua.

Uma alternativa para resolver esse problema consiste em 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 $c_{\{k_1, k_2\}}$. Se por exemplo, para uma dada posição p obtém-se $g_1(p) = g_2(p) = 1$ e $g_k(p) = 0$ para $2 < k \leq n$. Então é razoável classificar p como pertencente à classe $c_{\{1, 2\}}$. Nesse caso, $c_{\{1, 2\}}$ será denominada *classe imprecisa*.

Para se obter classes disjuntas c_k , dois procedimentos são imediatos:

1) limiarizar cada plano de informação g_k com um limiar l_k , fixado para a aplicação. Desta forma obtemos n planos de informação binários g'_k . Então para uma dada posição p , a $classe(p) = c_k, k = \{k | g'_k(p) = 1\}$.

2) a classificação de p será o conjunto de classes que obtiverem um grau maximal nos planos de informação g_k . Seja $u(p) = \max_{1 \leq k \leq n} g_k(p)$, o grau maximal

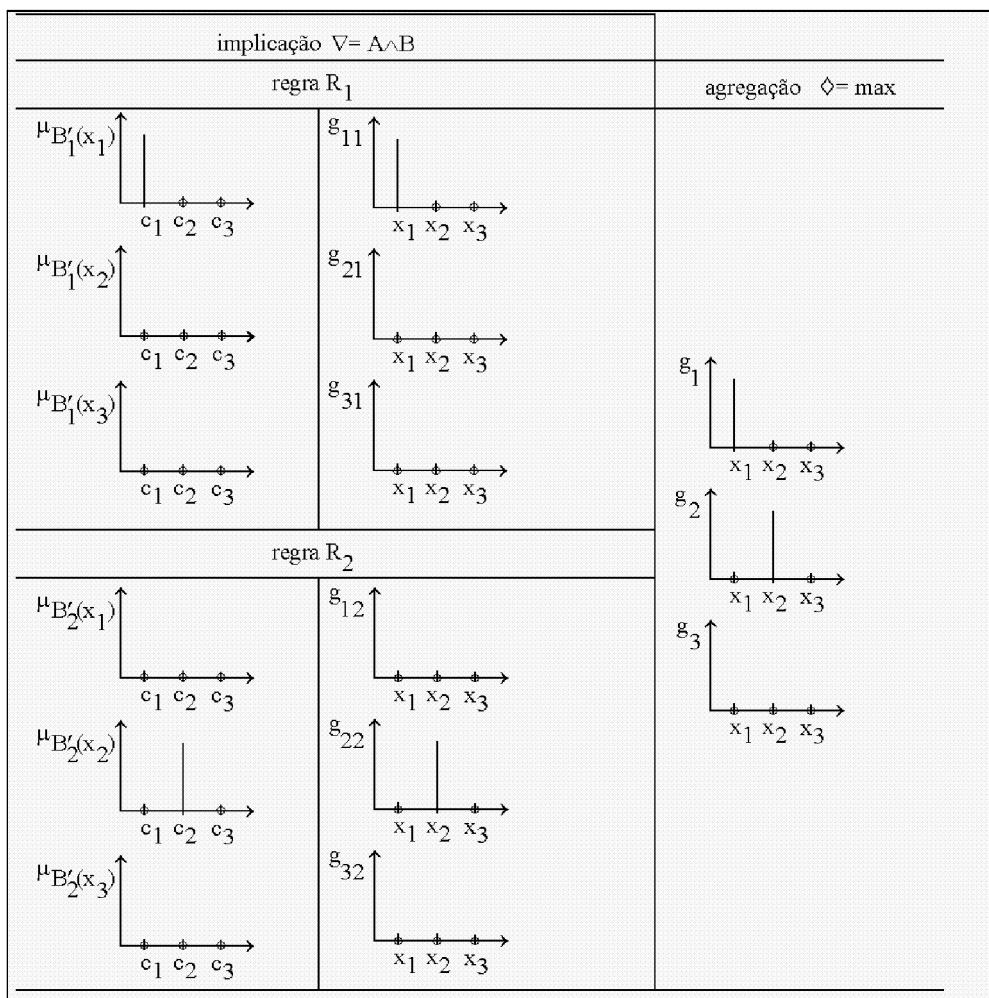


Fig. 4.1: Raciocínio nebuloso quando a implicação é $A \wedge B$ e a agregação é dada pelo max.

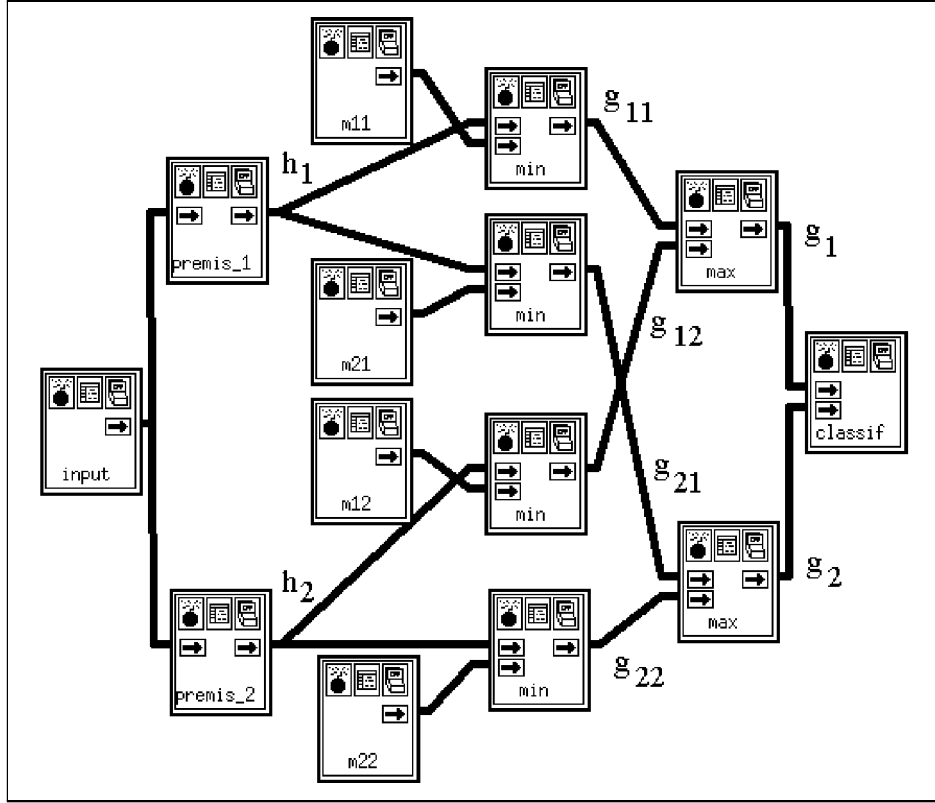


Fig. 4.2: Seqüência de operações no Khoros representando um sistema especialista, com $\nabla = \min$ e $\diamond = \max$.

dos g_k , a classificação de p será dada por $classe(p) = c_k, k = \{k | g_k(p) = u(p)\}$. Também nesse caso o resultado vem na forma de n planos de informação binários $g'_k(p)$, onde $g'_k(p) = 1$, se k pertence à classe de p e 0 caso contrário. Esta alternativa é mais onerosa em termos de tempo de processamento do que a primeira.

Exemplo

Observando a arquitetura proposta como um todo, seja a aplicação dada pela Figura 4.2 e seja uma regra R dessa aplicação dada por:

$$R: \begin{array}{l} SE \text{ posição} \in \widetilde{b_{mata}} \\ \quad E \text{ posição} \in \widetilde{perto_da_cidade} \\ \quad ENTÃO \text{ classe} = \tilde{c}_1. \end{array}$$

onde: $\widetilde{b_{mata}}$ é um conjunto nebuloso com função de pertinência $\mu_{\widetilde{b_{mata}}} : E \longrightarrow$

$\{0, 255\}$, $\widetilde{\text{perto_da_cidade}}$ é um conjunto nebuloso com função de pertinência $\mu_{\widetilde{\text{perto_da_cidade}}} : E \longrightarrow [0, 255]$ e \widetilde{c}_i é um conjunto nebuloso com função de pertinência $\mu_{\widetilde{c}_i} : C \longrightarrow [0, 255]$, onde $C = \{c_1, c_2\}$.

Na Figura 4.3 (Sandri et al., 1996) pode-se observar a seqüência de operações que tratam da aplicação da premissa da regra R_1 a uma imagem f_1 , gerando as imagens f_2 a f_5 . A caixa "Mata" (o mesmo raciocínio vale para a caixa "Cidade") processa a imagem de maneira a dar como saída uma imagem binária $E \rightarrow \{0, 255\}$, indicando se o "pixel" está localizado em área com nível de cinza indicador de "Mata" (respec. "Cidade"). Informações desse gênero podem ser obtidas através de um pré-processamento estatístico, seqüência de limiarizações ou ainda por cartas de um sistema geográfico de informações. Nesse caso especificamente, utilizou-se uma seqüência de limiarizações da Morfologia Matemática para a obtenção do atributo "Mata" (respec. "Cidade").

A caixa "Perto" é também uma seqüência de operações: primeiramente uma função distância é aplicada à imagem f_3 , que demarca a cidade na imagem, gerando um plano de informação intermediário que forma "curvas de nível" em torno à cidade, tal como visto na Figura 2.6 com a distância aplicada fora da cidade. Verifica-se o grau de pertinência da distância de cada "pixel" em relação a um dado conjunto nebuloso "Perto", gerando a imagem f_4 que aponta os "pixels" perto da cidade.

As saídas das caixas "Mata" e "Perto" são pois mapeamentos de E em $\{0, \dots, 255\}$, representando a conformidade dos valores dos atributos de cada "pixel" da imagem com valores *Mata* e *Perto_de_cidade* presentes na premissa da regra. Isso corresponde ao passo (a.1) da fase (a), onde $f_2(p)$ e $f_4(p)$ representam respectivamente $h_{11}(p)$ e $h_{12}(p)$. A caixa "min" implementa o conectivo E como a t-norma min e equivale ao passo (a.2) da fase (a), ou seja, $f_5(p)$ representa $h_1(p)$. Portanto, dada uma imagem mapeando de um retângulo E em $\{0, \dots, 255\}$, o resultado do processamento da premissa da regra R_j é um mapeamento $h_j : E \rightarrow [0, 255]$.

Observando a arquitetura proposta como um todo, seja a aplicação dada pela Figura 4.2 que mostra um sistema especialista criado no Khoros com duas regras e $C = \{c_1, c_2\}$. As caixas "premis_1" e "premis_2", tratam as premissas de duas regras R_1 e R_2 , respectivamente. A Figura 4.3 corresponde pois à caixa "premis_1" da Figura 4.2.

Seja a conclusão da regra R_j dada por $\mu_{B_j}(c_k) = m_{kj}$, $m_{kj} \in \{0, \dots, 255\}$. Essa abordagem consiste em utilizar uma caixa do Khoros para implementar a implicação de $h_j(p)$ em relação a cada m_{kj} , obtendo como resultado o mapeamento $g_{kj} : E \rightarrow \{0, \dots, 255\}$, onde $g_{kj}(p) = \nabla(h_j(p), m_{kj}), p \in E$. Cada plano de informação $g_{kj}(p)$ representa a possibilidade de que a classe de p seja c_k , levando-se em conta somente a regra R_j . Na aplicação considerada na Figura 4.2, o operador de implicação ∇ utilizado é dado pelo operador min. Quando a conclusão é dada

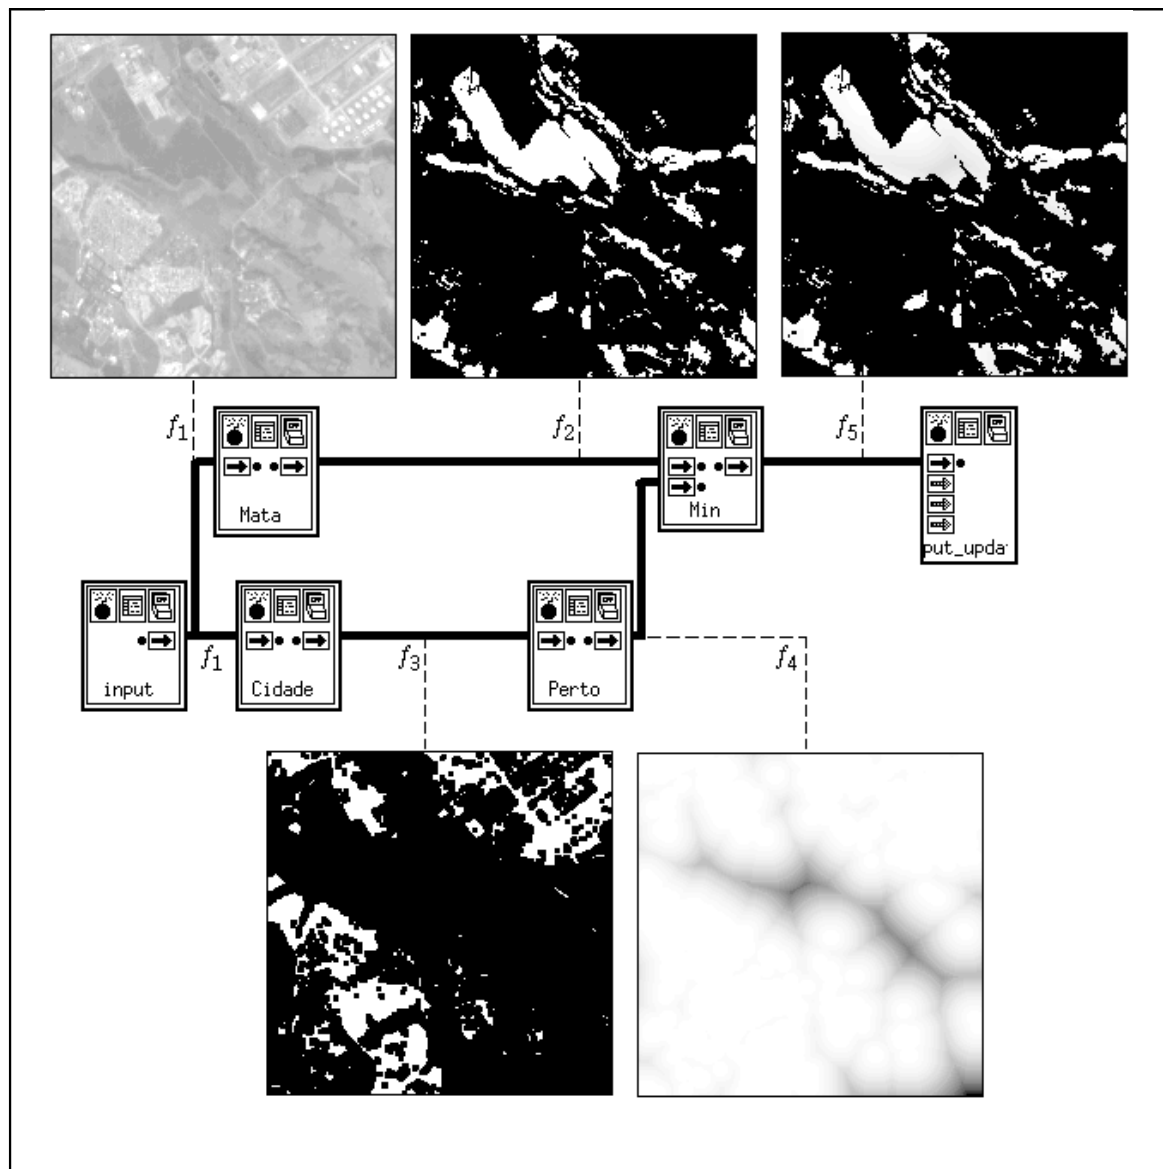


Fig. 4.3: Sequência de operações do Khoros 1.0.5 sobre uma imagem.

por um conjunto nebuloso preciso, $g_{kj}(p) = h_j(p)$.

É importante notar que o conjunto nebuloso $B'_j(p)$ relativo a cada ponto p tornou-se na verdade "implícito" nos planos de informação g_{kj} ; para obtê-lo basta fazer $\mu_{B'_j(p)}(c_k) = g_{kj}(p)$.

Finalmente, os planos de informação g_{kj} são agregados, utilizando um operador \diamond , resultando em um conjunto de mapeamentos $g_k : E \rightarrow \{0, \dots, 255\}$, onde $g_k(p) = \diamond(g_{k1}(p), \dots, g_{km}(p))$, $p \in E$. Cada plano de informação $g_k(p)$ representa a possibilidade de p pertencer a classe c_k levando-se em consideração todas as m regras da base de conhecimento. Na aplicação da Figura 4.2, o operador de agregação \diamond utilizado é dado pelo operador max. É importante notar que o conjunto nebuloso $B'(p)$ relativo a cada ponto p também está "implícito" nos planos de informação g_k ; para obtê-lo basta fazer $\mu_{B'(p)}(c_k) = g_k(p)$.

Na seções seguintes esse assunto será tratado com maiores detalhes, mostrando como as regras utilizadas foram implementadas para a construção de um classificador, tomando como base a descrição dada acima.

4.2. Considerações para a Implementação Usando Morfologia Matemática

Para criar um sistema especialista nos moldes da seção anterior usando Morfologia Matemática, utiliza-se de regras. No entanto, pode haver problemas para a implementação de uma ou mais regras dadas pelo especialista. Por exemplo, o especialista pode definir uma classe utilizando-se de uma imagem colorida em composição RGB e o domínio do sistema trata de imagens em níveis de cinza. Em um caso desse tipo, pode haver uma "tradução" do conhecimento do especialista em uma ou mais regras compatíveis com o domínio do sistema.

Como foi visto no capítulo anterior, 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, sem a necessidade da reconstrução.

A partir da função distância da Morfologia Matemática pode-se implementar características nebulosas como perto, muito perto, nas proximidades, longe, muito longe, etc. Essas implementações podem se dar a partir de uma função da função distância; seja criando os graus de pertinência para o conjunto nebuloso desejado ou com limiarizações.

4.2.1. A Modelagem das Regras

Como mencionada anteriormente, os operadores da Morfologia Matemática podem ser vistos como funções da lógica de primeira ordem. 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 a t-norma e a t-conorma utilizadas. Doravante, um conjunto nebuloso será denotado por $\widetilde{\text{conjunto_nebuloso}}$ 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. Cinco 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:

$$\begin{aligned} R_1 : SE \text{ radiometria na banda } 4 &= \widetilde{\text{aproximadamente_entre_0_e_13}} \\ E \text{ radiometria na banda } 5 &= \widetilde{\text{aproximadamente_entre_0_e_10}} \\ ENTÃO \text{ posição} &\in \widetilde{b_{rio}} \end{aligned}$$

onde: $\widetilde{\text{aproximadamente_entre_0_e_13}}$ é um conjunto nebuloso cuja função de pertinência $\mu_{\widetilde{[0,13]}} : \{0, \dots, 255\} \longrightarrow \{0, 255\}$ é dada por:

$$\mu_{\widetilde{[0,13]}}(s) = \begin{cases} 255, & \text{se } s \leq 13 \\ 0, & \text{caso contrário} \end{cases} ;$$

$\widetilde{\text{aproximadamente_entre_0_e_10}}$ é um conjunto nebuloso cuja função de pertinência $\mu_{\widetilde{[0,10]}}$ é:

$$\mu_{\widetilde{[0,10]}}(s) = \begin{cases} 255, & \text{se } s \leq 10 \\ 0, & \text{caso contrário} \end{cases} ;$$

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

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

Deve-se observar que as proposições $X = A$ e $X \in A$ têm aqui o mesmo significado e só aparecem de forma diferenciada para facilitar a leitura. 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 $\mu_{\widetilde{[0,13]}}$ e $\mu_{\widetilde{[0,10]}}$ 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 $\mu_{\widetilde{[0,13]}}$ e $\mu_{\widetilde{[0,10]}}$ são LUTs de operadores de limiarização, pelas Equações 4.1 e 4.2 resultará em uma imagem $g_{b_{rio}}(x)$, onde:

$$g_{b_{rio}}(x) = \min \left[\left(\mu_{\widetilde{[0,13]}}(f_4(x)), \mu_{\widetilde{[0,10]}}(f_5(x)) \right) \right]$$

Como as funções de pertinência $\mu_{\widetilde{[0,13]}}$ e $\mu_{\widetilde{[0,10]}}$ são aplicadas a radiometria e não a uma imagem, para que seja aplicada uma imagem, faz-se uma composição: $\mu_{\widetilde{[0,13]}}(f_4(x)) \triangleq \mu_{\widetilde{[0,13]}}(x) \circ f_4(x)$ e $\mu_{\widetilde{[0,10]}}(f_5(x)) \triangleq \mu_{\widetilde{[0,10]}}(x) \circ f_5(x)$. Então:

$$g_{b_{rio}}(x) \triangleq \min \left[\left(\mu_{\widetilde{[0,13]}}(x) \circ f_4(x), \mu_{\widetilde{[0,10]}}(x) \circ f_5(x) \right) \right]$$

Em termos de operadores da Morfologia Matemática, as composições $\mu_{\widetilde{[0,13]}}(x) \circ f_4(x)$ e $\mu_{\widetilde{[0,10]}}(x) \circ f_5(x)$ são operadores de limiarização. Então:

$$g_{b_{rio}}(x) \triangleq \min \left(\text{limiarização}_{[0,13]}(f_4)(x), \text{limiarização}_{[0,10]}(f_5)(x) \right).$$

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 :

$$\begin{aligned} R_2 : & \text{SE } \widetilde{\text{posição}} \in \widetilde{\text{muito_perto_do_rio}} \\ & \text{E } \text{posição} \in \neg \widetilde{b_{rio}} \\ & \text{ENTÃO } \text{posição} \in \widetilde{b_{\text{arg em_do_rio}}} \end{aligned}$$

onde: $\widetilde{\text{muito_perto_do_rio}}$ é um conjunto nebuloso cuja função de pertinência $\mu_{\widetilde{\text{muito_perto_do_rio}}} : E \longrightarrow \{0, 255\}$ é aqui definida em termos da função distância $\Psi_d(f)(x)$, do Capítulo 2, e é dada por:

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

$\neg \widetilde{b_{rio}}$ é o complemento do conjunto nebuloso $\widetilde{b_{rio}}$ e é dado por:

$$\mu_{\neg \widetilde{b_{rio}}} = 255 - \mu_{\widetilde{b_{rio}}};$$

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

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

Pela arquitetura proposta, a implementação da regra R_2 , sendo que a conclusão é um conjunto nebuloso preciso, a implicação $\nabla = \min$, pelas Equações 4.1 e 4.2 resultará em uma imagem $g_{\text{arg em_do_rio}}$, dada por:

$$g_{\text{arg em_do_rio}} = \min \left[\left(\mu_{\widetilde{\text{muito_perto_do_rio}}}, f_{255} - g_{b_{rio}} \right) \right]$$

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 $\widetilde{\text{muito_perto_do_rio}}$ é um operador de limiarização sobre a função distância. Então:

$$g_{\text{arg em_do_rio}} \triangleq \min \left(\text{limiarização}_{[0,10]}(\Psi_d(g_{b_{rio}})), f_{255} - g_{b_{rio}} \right)$$

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:

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

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

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

Pela arquitetura proposta, a implementação da regra R_3 , sendo que a conclusão é um conjunto nebuloso preciso, a implicação $\nabla = \min$, pelas Equações 4.1 e 4.2 resultará em uma imagem $g_{c_{rio}}$, onde:

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

Seja o conjunto nebuloso dado pela descrição "componente conexa do conjunto das posições dos "pixels" com radiometria aproximada entre 70 e 200 na banda 3, que contém pelo menos uma área quadrada de 270 m²", denotado por $\widetilde{componente_conexa_1}$. Então $\widetilde{componente_conexa_1}$ é uma área da imagem, cujos níveis de cinza pertencem a um intervalo e que possuem uma área superior a uma área definida. Uma regra R_4 poderia ser da forma:

$$R_4 : SE \text{ posição} \in \widetilde{componente_conexa_1} \\ ENTÃO \text{ posição} \in \widetilde{b_{\text{área_antropizada}}}$$

onde: $\widetilde{componente_conexa_1}$ é um conjunto nebuloso cuja função de pertinência $\mu_{\widetilde{componente_conexa_1}} : E \longrightarrow \{0, 255\}$ é definida em termos da abertura por reconstrução $\gamma_m(f)(x)$, do Capítulo 2, onde m é um marcador, e é dada por:

$$\mu_{\widetilde{componente_conexa_1}} = \gamma_{\varepsilon(\text{limiarização}_{[70,200]} f_3)}(\text{limiarização}_{[70,200]} f_3);$$

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

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

Pela arquitetura proposta, a implementação da regra R_4 , sendo que a conclusão é um conjunto nebuloso preciso, a implicação $\nabla = \min$, pelas Equações 4.1 e 4.2 resultará em uma imagem $g_{\widetilde{b_{\text{área_antropizada}}}}$, onde:

$$g_{\widetilde{b_{\text{área_antropizada}}}} = \mu_{\widetilde{componente_conexa_1}}$$

Em termos de operadores da Morfologia Matemática, a função de pertinência de $\widetilde{componente_conexa_1}$ é o operador de reconstrução do conjunto das posições dos "pixels" com radiometria aproximada entre 70 e 200 na banda 3 marcado pelo conjunto das posições dos "pixels" com radiometria aproximada entre 70 e 200 na banda 3 que contém pelo menos uma área quadrada de 270 m². Então:

$$g_{b_{\widetilde{área_antropizada}}} \triangleq \gamma_{\varepsilon(\text{limiarização}_{[70,200]} f_3)}(\text{limiarização}_{[70,200]} f_3)$$

Seja o conjunto nebuloso dado pela descrição "ao norte da área antropizada", denotado por $\widetilde{área_norte}$. Então $\widetilde{área_norte}$ é uma área da imagem, que depende de uma área já definida anteriormente e que possui uma posição geograficamente definida. Uma quinta regra poderia ser dada por:

$$\begin{aligned} R_5 : \quad & SE \text{ posição} \in \widetilde{área_norte} \\ & E \text{ posição} \in b_{\widetilde{margem_do_rio}} \\ & ENTÃO \text{ posição} \in b_{\widetilde{floresta}} \end{aligned}$$

onde: $\widetilde{área_norte}$ é um conjunto nebuloso cuja função de pertinência $\mu_{\widetilde{área_norte}} : E \longrightarrow \{0, 255\}$ é definida em termos de uma N-dilatação que é uma sucessão de N dilatações por um elemento estruturante EE . Para que a posição "norte" seja a resultante, a dilatação deverá ter por elemento estruturante:

$$EE = \begin{pmatrix} 0 & 1 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{pmatrix}$$

e a N-dilatação é denotada por $\delta_{EE}^N(f)$. A função de pertinência de $\widetilde{área_norte}$ é dada por:

$$\mu_{\widetilde{área_norte}} = \delta_{EE}^N(g_{b_{\widetilde{área_antropizada}}});$$

onde: $\widetilde{b_{margem_do_rio}}$ é um conjunto nebuloso já definido anteriormente e $\widetilde{b_{floresta}}$ é um conjunto nebuloso cuja função de pertinência $\mu_{\widetilde{b_{floresta}}} : Y = \{sim, não\} \longrightarrow \{0, 255\}$ é:

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

Pela arquitetura proposta, a implementação da regra R_5 , sendo que a conclusão é um conjunto nebuloso preciso, a implicação $\nabla = \min$, pelas Equações 4.1 e 4.2 resultará em uma imagem $g_{b_{\widetilde{floresta}}}$, onde:

$$g_{b_{flore\widetilde{sta}}}(x) = \min \left(\mu_{\widetilde{área_norte}}(x), \mu_{b_{margem_do_rio}}(x) \right)$$

Pelas definições anteriores das funções de pertinência de $\widetilde{área_norte}$ e $b_{margem_do_rio}$, temos:

$$g_{b_{flore\widetilde{sta}}} \triangleq \min \left(\delta_{EE}^N(g_{b_{\widetilde{área_antropizada}}}), g_{margem_do_rio} \right).$$

No Capítulo 5 será visto uma aplicação completa usando esta arquitetura.

5. UTILIZAÇÃO DA ARQUITETURA PROPOSTA

”Um sutil pensamento errado pode dar lugar a uma
indagação frutífera que revelará grandes verdades”
Isaac Asimov (1920-1992).

A arquitetura proposta foi utilizada na construção de um classificador para a área da Floresta Nacional do Tapajós, descrita em detalhes na seção seguinte.

Para essa implementação vale observar que: para \top será utilizada a t-norma min; para \perp será utilizada a t-conorma max; o operador de implicação ∇ utilizado é dado pelo operador min. Por questão de eficiência, as imagens trabalhadas são imagens com valores inteiros no conjunto $\{0, \dots, 255\}$ e não com valores reais no intervalo $[0, 1]$. Os valores de m_{kj} são sempre unitários e portanto $g_{kj} = h_j$ para todos k e j . Como há uma única fonte de informação e cada regra refere-se sempre a apenas uma classe, o operador de agregação \diamond não se torna necessário.

5.1. A Floresta Nacional do Tapajós

A Floresta Nacional do Tapajós (Figura 5.1) está localizado geograficamente dentro de um retângulo imaginário de coordenadas, cujos vértices são: $02^\circ 43' 27''$ S e $55^\circ 26' 01''$ W e $04^\circ 07' 39''$ S e $54^\circ 45' 00''$ W, no estado brasileiro do Pará. Note-se a pequena cidade de Aveiro no interior da Floresta Nacional, a sudoeste da cidade de Santarém, também no estado do Pará. Aveiro é um município autônomo com 1714 habitantes (dados do Censo Demográfico Brasileiro de 1991), criado em 1961 e com uma área de $17157,9 \text{ km}^2$ (IBGE, 1995).

As imagens foram tomadas pelos sensores do satélite Landsat TM em 7 de agosto de 1995, através das bandas 3, 4, 5 e 7. Elas contém a cidade de Aveiro e uma extensa área que denota a presença humana na área. Está presente na imagem também uma pequena área na margem oposta do rio que não faz parte da floresta nacional. A Figura 5.2 é uma imagem em composição colorida RGB (banda 3 em B, banda 4 em G e banda 5 em R) processada da região.




Fig. 5.1: Localização da Floresta Nacional do Tapajós no estado do Pará
 FONTE: Projeto RADAMBRASIL (1983).




Fig. 5.2: Composição colorida RGB (5-4-3) da imagem da Floresta Nacional do Tapajós sobre a cidade de Aveiro.

5.2. A Classificação Visual da Área

A área em questão foi classificada visualmente por Pedro Hernandez Filho da Divisão de Sensoriamento Remoto do INPE em setembro de 1997. Essa classificação será utilizada como referência ou mapa de referência para o sistema proposto. São oito as classes presentes nessa área. A nomenclatura dos tipos de vegetação seguiu a nomenclatura dada por IBGE (1992). Com referência a imagem da Figura 5.2, segue uma breve descrição de cada uma delas (essas descrições são as chaves de interpretação mencionadas na seção 2.4.1.):

- *Rio Tapajós*: atravessa a região e corta a imagem de norte a sul. É a área azul na Figura 5.2 com textura lisa.

- *Área Antropizada* (área que o homem ocupa ou ocupou recentemente): São as áreas mais claras nas margens do Rio que se estendem para o interior e algumas áreas maiores isoladas. Na Figura 5.2, são áreas em amarelo, rosa e branco.

- *Área Urbana da Cidade de Aveiro*: se encontra na margem direita ou margem leste do Rio, em forma aproximada de um triângulo perfurado. Na Figura 5.2, são áreas em amarelo, rosa e branco próximas ao Rio.

- *Vegetação Secundária*: é a área próxima às margens do Rio com pouca presença de drenagem. Sua maior área está nas proximidades da área antropizada. Na Figura 5.2, são áreas em verde com textura lisa.

- *Floresta Ombrófila Densa*: presente na área de maior presença de drenagem, esta área está mais distante do Rio e da cidade de Aveiro, na direção leste. Na Figura 5.2, são áreas em verde com textura rugosa.

- *Áreas de Contato: Floresta Ombrófila/Formações Pioneiras*: se encontra principalmente no interior do rio e em áreas próximas às margens, tanto à direita como à esquerda. Na Figura 5.2, 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 Floresta Secundária*: são áreas presentes na margem esquerda do Rio. Não é possível distinguir com clareza uma classe da outra, tanto nas imagens em níveis de cinza quanto na composição. Na Figura 5.2, são áreas em amarelo, rosa e branco à esquerda do Rio.

A classificação visual pode ser observada na Figura 5.3. Note-se na Figura 5.4, as legendas correspondentes a classificação.




Fig. 5.3: Resultado da classificação visual.

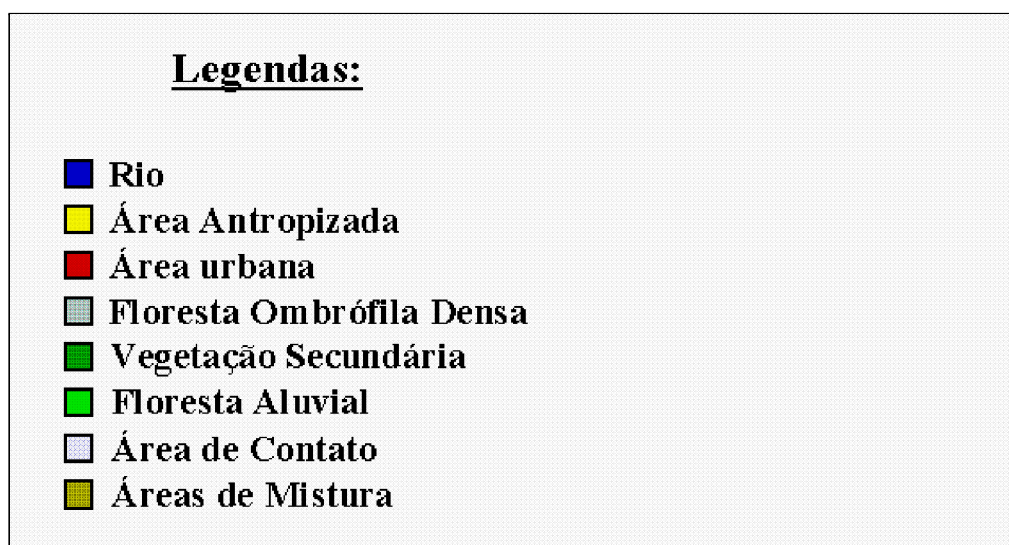


Fig. 5.4: Legenda da classificação visual da Figura 5.3.

5.3. As Tabelas de Conhecimento

As regras para a classificação da área da Floresta Nacional do Tapajós foram obtidas a partir de informações e dados fornecidos pelo professor Pedro Hernandez Filho da Divisão de Sensoriamento Remoto do INPE. Essas regras estão resumidas na Tabela 5.1.

TABELA 5.1 - CONHECIMENTO DO ESPECIALISTA SOBRE UMA DETERMINADA CLASSE POR DADOS DE VEGETAÇÃO, LOCALIZAÇÃO E DETECÇÃO.

Classes	Localização	Vegetação	Detecção	
			critérios	melhor forma
1. Rio Tapajós ou lâminas d'água	Corta a imagem de Norte a Sul		Níveis de cinza escuros	Bandas 4 e 5
2. Área Antropizada	ambos os lados do Rio		Níveis de cinza escuros ou claros	Bandas 3 e 7 Banda 5
3. Área Urbana da Cidade de Aveiro	margem direita do Rio contida na Área Antrop.		Níveis de cinza médios	Bandas 3 e 7
4. Floresta Ombrófila Densa	lado direito longe do Rio	Floresta Ombrófila Densa	Níveis de cinza médios	Banda 5
5. Vegetação Secundária	ambos os lados do Rio	Vegetação Secundária	Níveis de cinza médios	Banda 5

(continua)

TABELA 5.1- Conclusão.

Classes	Localização	Vegetação	Detecção	
			critérios	melhor forma
6. Floresta Aluvial	áreas estreitas nas proximidades da Área Antropizada ambos os lados do Rio	Floresta Aluvial	verde bem definido em RGB ou níveis de cinza médio na Banda 5 e escuros na Banda 7	composição RGB ⁽¹⁾ ou Bandas 5 e 7
7. Área de Contato: Floresta Ombrófila/ Formações Pioneiras	formações dentro do Rio e proximidades das margens	gramíneas e florestas inundadas periodicamente	Níveis de cinza diferenciados dentro do Rio e às margens	Bandas 3, 4, 5 e 7
8. Área de Mistura	lado esquerdo do Rio	Vegetação Secundária		composição RGB ⁽¹⁾ ou Bandas 3, 5 e 7

(1) A composição RGB é efetuada associando-se a banda 3 a B, a banda 4 a G e a banda 5 a R.

5.4. 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.

Numa primeira fase da classificação, extrai-se os atributos (características presentes na imagem que podem se tornar referências para a utilização do conhecimento) que são relacionados às classes (conjunto de "pixels" que são admitidos pertencer a um mesmo grupo). Porém, podem ocorrer casos onde atributo e classe sejam únicos. Por exemplo, o Rio presente na imagem da Figura 5.2, é um atributo e pode ser usado como referência para encontrarmos uma classe que esteja próximo ou mesmo distante dele. Mas, o Rio também é uma classe presente na imagem. Nesse caso, Rio é um atributo e também uma classe.

É importante salientar que nessa fase de extração de atributos, as definições de níveis de cinza claro, médio e escuro presentes na Tabela 5.1 (pertinentes à radiometria da imagem) para alguns atributos, é resolvida manualmente, ou seja, buscando-se nas próprias bandas da imagem os valores correspondentes.

A Figura 5.5 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 sequência, 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. Deve-se ressaltar que essa não necessariamente seja a única forma de se resolver o problema, mas dentro da ótica da Morfologia Matemática, acredita-se ser a mais eficiente encontrada.

O restante deste capítulo será dedicado a mostrar como as regras foram implementadas em termos dos operadores morfológicos para se constituírem no classificador observado na Figura 5.5.

5.4.1. Isolando Atributos da Imagem

Pelas descrições das classes dadas em 5.2 e pela Tabela 5.1, já fica evidente algumas das regras que serão utilizadas. Já se nota também alguns dos *atributos* que serão referências para a utilização do conhecimento, como o Rio e a Área

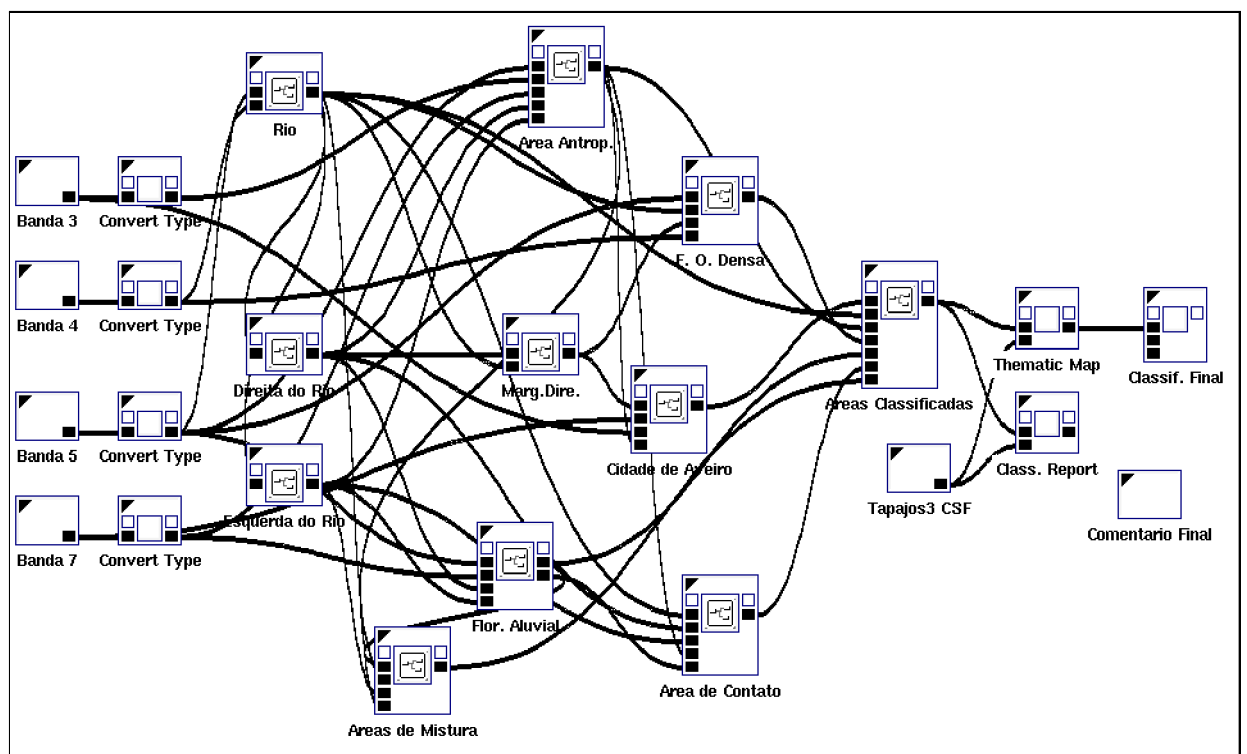


Fig. 5.5: "Workspace" que gera a classificação para uma imagem com quatro bandas.

Antropizada (que também são classes) e a drenagem densa (ou textura - que não se constitui como classe).

Três são os atributos principais presentes na imagem: o rio Tapajós, a Área Antropizada com suas estradas de ligação e caminhos ou pequenas estradas na mata (por vezes também denominada ocupação humana) e a drenagem densa (textura). Esses atributos são usados como referência para a extração de outros atributos. Pode-se pensar em dois atributos desse tipo que são a cidade de Aveiro e as margens do rio que serão úteis como referência. No caso, as margens do Rio são atributos que serão obtidos a partir do próprio Rio e a Cidade de Aveiro, a partir da Área Antropizada.

Antes de iniciar a discussão sobre as regras, cabe algumas importantes observações sobre os conjuntos nebulosos utilizados:

a) Para todo $c \in C$, o conjunto nebuloso $\widetilde{c_k}$ (por exemplo, $\widetilde{c_{rio}}$) será definido por $\mu_{\widetilde{c_k}} : C \longrightarrow \{0, 255\}$, onde $C = \{c_{rio}, c_{\text{área_antropizada}}, c_{\text{área_urbana_da_cidade_de_Aveiro}}, c_{\text{floresta_ombrófila_densa}}, c_{\text{floresta_aluvial}}, c_{\text{áreas_de_contato}}, c_{\text{áreas_de_mistura}}, c_{\text{vegetação_secundária}}\}$ tal que:

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

b) Os conjuntos nebulosos $\widetilde{b_{XXX}}$ são definidos como $\mu_{\widetilde{b_{XXX}}} : Y \longrightarrow \{0, 255\}$, onde $Y = \{sim, não\}$, tais que:

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

c) Os conjuntos nebulosos $\widetilde{componente_conexa_i}$ onde $i \in Z$ são definidos como $\mu_{\widetilde{componente_conexa_i}} : E \longrightarrow \{0, 255\}$, tal que:

$$\mu_{\widetilde{componente_conexa_i}}(x) = \begin{cases} 255, & \text{se } x \in \gamma_g(f) \\ 0, & \text{caso contrário} \end{cases} ,$$

onde γ é o operador abertura por reconstrução que reconstrói uma componente conexa da imagem f dado um marcador definido pela imagem g .

d) Os conjuntos nebulosos que possuem referência à distância de uma região (por exemplo: $\widetilde{perto_do_rio}$, $\widetilde{longe_da_área_antropizada}$, $\widetilde{na_região_da_cidade_de_Aveiro}$, etc) são definidos por $\mu_{\widetilde{distância}} : E \longrightarrow \{0, 255\}$, tal que:

$$\mu_{\widetilde{distância}}(x) = \begin{cases} 255, & \text{se } x \in \text{limiarização}_{[a,b]} \Psi_d(f)(x) \\ 0, & \text{caso contrário} \end{cases} ,$$

onde Ψ_d é a função distância e limiarização é o operador de limiarização, ambos definidos no Capítulo 2, e a e b são valores estipulados de acordo com a característica em questão.

e) Os conjuntos nebulosos *aproximadamente_entre_a_e_b* são LUTs de operadores de limiarização, definidos por: $\mu_{\widetilde{[a,b]}} : \{0, \dots, 255\} \longrightarrow \{0, 255\}$, tal que:

$$\mu_{\widetilde{[a,b]}}(s) = \begin{cases} 255, & \text{se } a \leq s \leq b \\ 0, & \text{caso contrário} \end{cases}.$$

f) Os conjuntos nebulosos *erosão_de_XXX* são definidos por: $\mu_{\widetilde{\text{erosão_de_}XXX}} : E \longrightarrow \{0, 255\}$, tal que:

$$\mu_{\widetilde{\text{erosão_de_}XXX}}(x) = \begin{cases} 255, & \text{se } x \in \varepsilon(f_{XXX})(x) \\ 0, & \text{caso contrário} \end{cases},$$

onde ε é o operador de erosão definido no Capítulo 2.

g) O conjunto nebuloso *não_ponto_isolado* é definido por: $\mu_{\widetilde{\text{não_ponto_isolado}}} : E \longrightarrow \{0, 255\}$, tal que:

$$\mu_{\widetilde{\text{não_ponto_isolado}}}(x) = \begin{cases} 255, & \text{se } x \in \lambda_{\bullet}(f_{XXX})(x) \\ 0, & \text{caso contrário} \end{cases},$$

onde λ_{\bullet} é o operador sup-gerador definido no Capítulo 2.

A Classe Rio

Conforme a breve definição dada sobre a classe Rio (que também é um atributo) e utilizando-se as bandas adequadas que realcem a presença de água na imagem, a regra para a extração do Rio é:

$$\begin{aligned} R_1 : SE \text{ radiometria na banda } 4 &= \widetilde{\text{aproximadamente_entre_0_e_13}} \\ E \text{ radiometria na banda } 5 &= \widetilde{\text{aproximadamente_entre_0_e_10}} \\ ENTÃO \text{ posição} &\in \widetilde{b_{rio}} \end{aligned}$$

A Figura 5.6 mostra a implementação da regra R_1 . As bandas 4 e 5 são as mais convenientes para esse tipo de extração, visto o realce que dão às lâminas d'água. Por isso, não importando a sua localização na imagem, é possível extraí-lo apenas pela sua radiometria. Da limiarização da imagem para cada banda resultam imagens binárias cujo ínfimo é uma imagem binária representando a classe Rio.

A regra R_1 dá a forma de obtenção do Rio Tapajós na imagem, mas não o relaciona ao universo das classes C . Para fazer isso, uma regra adicional R_{1a} relaciona o conjunto nebuloso \widetilde{c}_{rio} com o conjunto nebuloso \widetilde{b}_{rio} obtido anteriormente.

$$R_{1a} : \begin{array}{l} SE \text{ posição} \in \widetilde{b}_{rio} \\ ENTÃO \text{ classe} = \widetilde{c}_{rio} \end{array}$$

onde \widetilde{c}_{rio} é um conjunto nebuloso de C . Como visto na regra R_3 do capítulo anterior, essa regra não é explicitada em uma "workspace" própria.

O Atributo Margem Direita do Rio As margens do Rio são as porções de terra muito próximas ao próprio Rio. Porém nesse caso, o interesse recai sobre uma das margens especificamente e por isso necessita-se de algo que a caracterize. Então as regras são:

$$\begin{array}{l} R_2 : \begin{array}{l} SE \text{ posição} \in \widetilde{\text{muito_perto_do_rio}} \\ E \text{ classe} \in \neg \widetilde{b}_{rio} \\ ENTÃO \text{ posição} \in b_{\widetilde{\text{margem_do_rio}}} \end{array} \\ R_3 : \begin{array}{l} SE \text{ posição} \in \widetilde{\text{componente_conexa_1}} \\ ENTÃO \text{ posição} \in b_{\widetilde{\text{lado_leste_do_rio}}} \end{array} \end{array}$$

onde: $\widetilde{\text{componente_conexa_1}}$ denota o conjunto nebuloso dado pela descrição "componente conexa de "não" rio marcada pelo lado leste da imagem".

$$R_4 : \begin{array}{l} SE \text{ posição} \in b_{\widetilde{\text{margem_do_rio}}} \\ E \text{ posição} \in b_{\widetilde{\text{lado_leste_do_rio}}} \\ ENTÃO \text{ posição} \in b_{\widetilde{\text{margem_direita_do_rio}}} \end{array}$$

Extraír as margens do Rio e, em especial, uma das margens do Rio, é uma tarefa mais complexa. A Figura 5.7 ilustra a obtenção do atributo Direita do Rio que é necessário para essa operação de extração e será útil em outras ocasiões. Nota-se pela Figura 5.8 que se torna necessário um conjunto maior de operadores ou "caixinhas" para executar a tarefa.

Nota-se também que nas regras aparecem operadores da Morfologia Matemática que viabilizam o processo. No caso, a Abertura por Reconstrução é um operador cuja função é reconstruir todo o lado direito do Rio a partir do marcador lado leste da imagem, ou seja, a Abertura por Reconstrução reconstrói todo um conjunto a partir de um subconjunto utilizado como marcador (Banon e Barrera, 1994).

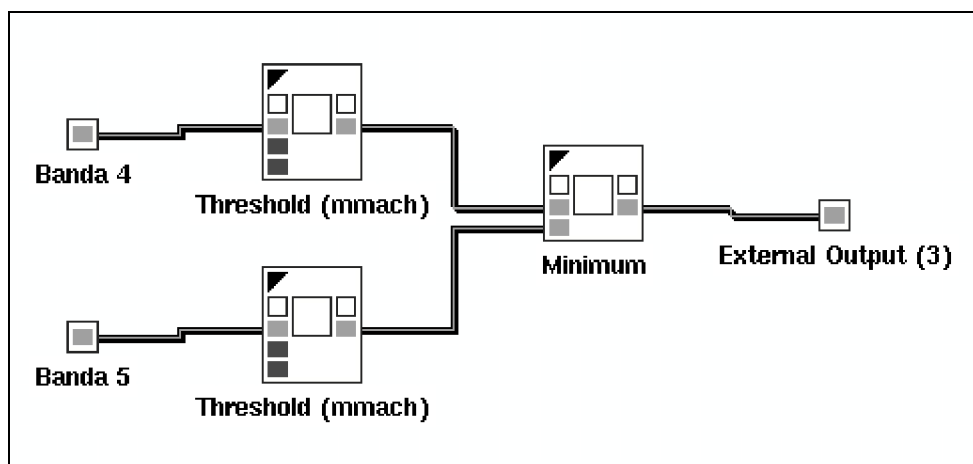


Fig. 5.6: "Workspace " que extrai o atributo Rio da imagem.

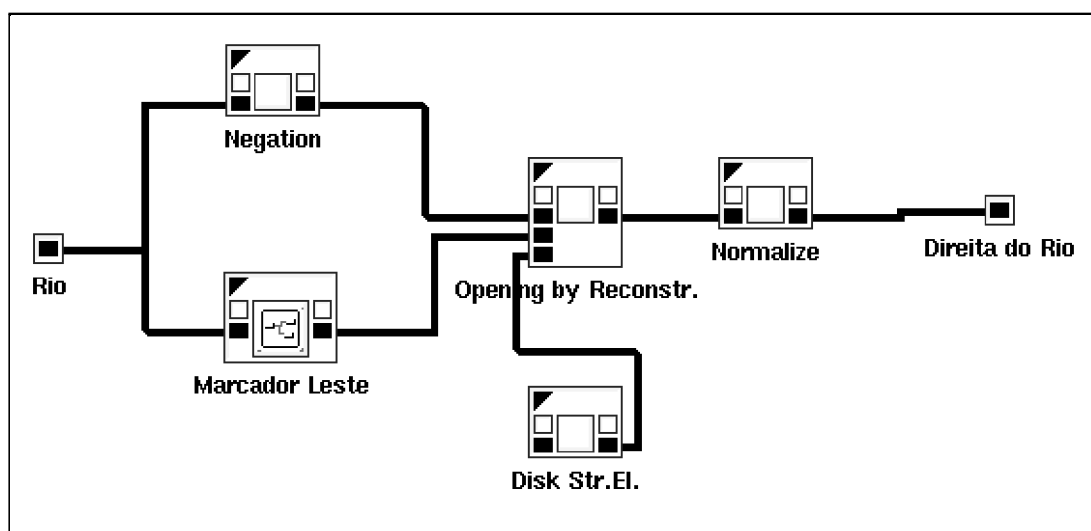


Fig. 5.7: "Workspace" que obtém a componente Direita do Rio.

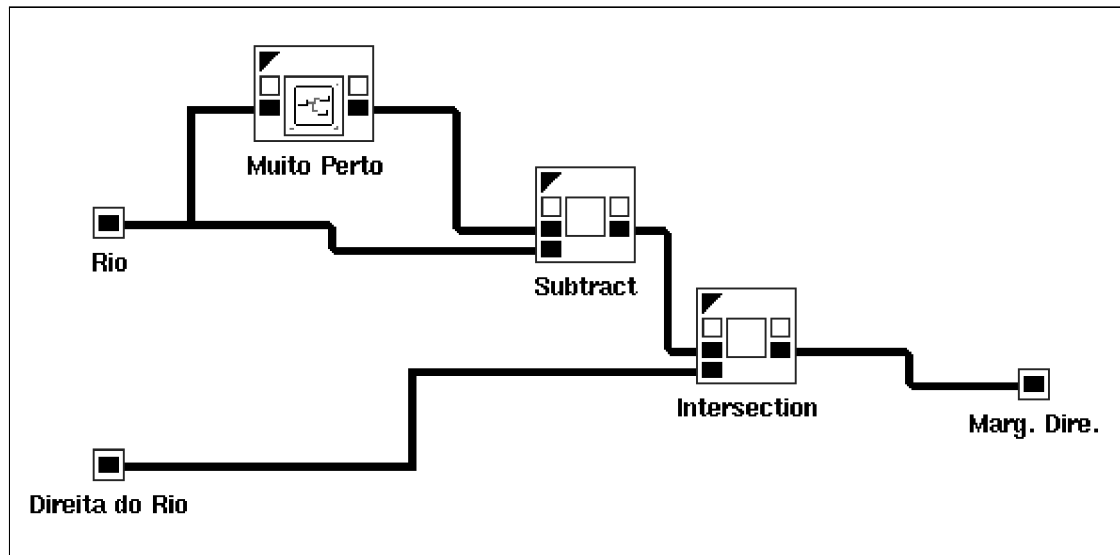


Fig. 5.8: "Workspace" que extrai o atributo Margem Direita do Rio.

Pelas Figuras 5.7 e 5.8, percebe-se que a implementação é uma tradução literal das regras expostas acima. A regra R_2 é construída a partir das "caixinhas" situadas na parte de cima da Figura 5.8, onde a subtração retira o Rio isolando a característica Margens do Rio. Na regra R_3 , ilustrada na Figura 5.7, a negação do Rio resulta em uma imagem sem a presença do Rio. A "caixinha" Marcador Leste extrai o lado leste da moldura ("frame") da imagem de entrada. O marcador será utilizado na Abertura por Reconstrução, tendo como entrada a negação do Rio. O resultado é uma imagem binária apontando toda a região à lado leste do Rio. A intersecção final (na Figura 5.8) representa a junção do resultado das regras R_2 e R_3 na regra R_4 e a imagem resultante é a Margem Direita do Rio.

A característica nebulosa Muito Perto é construída a partir da função distância da Morfologia Matemática. Sobre a função distância é aplicada uma limiarização, resultando na área da imagem com a característica Muito Perto (Figura 5.8). Essa limiarização da Morfologia Matemática corresponde a um corte de nível α dos Conjuntos Nebulosos.

A Classe Área Antropizada

Conforme a breve definição dada anteriormente, a classe Área Antropizada é caracterizada pelas áreas mais claras da imagem. Utilizando-se as bandas ade-

quadas que realcem essa característica, processa-se sua extração, através da regra:

$$\begin{aligned}
 R_5 : & \textit{SE} \textit{ posição} \in \widetilde{b_{\textit{lado_direito_do_rio}}} \textit{ OU } \textit{ posição} \in \widetilde{b_{\textit{lado_esquerdo_do_rio}}} \\
 & \textit{E } \textit{ posição} \in \widetilde{\textit{componente_conexa_2}} \\
 & \textit{OU } \textit{ posição} \in \widetilde{\textit{componente_conexa_3}} \\
 & \textit{OU } \textit{ posição} \in \widetilde{\textit{componente_conexa_4}} \\
 & \textit{ENTÃO } \textit{ posição} \in \widetilde{b_{\textit{área_antropizada}}}
 \end{aligned}$$

onde: $\widetilde{\textit{componente_conexa_2}}$ denota o conjunto nebuloso dado pela descrição "conjunto das posições dos "pixels" com radiometria aproximada entre 27 e 70 na banda 3, que não são pontos isolados"; $\widetilde{\textit{componente_conexa_3}}$ denota o conjunto nebuloso dado pela descrição "componente conexa do conjunto das posições dos "pixels" não isolados com radiometria aproximada de no mínimo por volta de 70 na banda 5, que contém pelo menos uma área quadrada de 270 m²" e $\widetilde{\textit{componente_conexa_4}}$ denota o conjunto nebuloso dado pela descrição "componente conexa do conjunto das posições dos "pixels" não isolados com radiometria aproximada entre 16 e 60 na banda 7, que contém pelo menos uma área quadrada de 270 m²"

A Figura 5.9 mostra como extrair o atributo Área Antropizada da imagem. As bandas 3 e 7 são as melhores para esse tipo de extração; a banda 5 atua como auxiliar. Novamente, a localização do atributo na imagem não é importante e é possível extraí-lo apenas pela sua radiometria. A limiarização da imagem para cada banda resulta em imagens binárias. O operador Afnamento na seqüência visa eliminar pontos isolados e é um sup-gerador (intersecção de uma erosão binária pelo elemento estruturante pontual centrado na origem e uma anti-dilatação binária pelo quadrado estruturante 3x3 a menos de seu ponto central). A seqüência de operações erosão e reconstrução nas bandas 5 e 7 visam eliminar as componentes de pontos com área quadrada inferior a 270m² e reconstruir as componentes conexas, cuja conexidade seja maior ou igual a um disco de diâmetro 2.

O supremo de todas as imagens em ambos os lados do Rio produz uma imagem com o atributo Área Antropizada.

Para a classe área antropizada, a regra adicional R_{5a} dá a relação:

$$\begin{aligned}
 R_{5a} : & \textit{SE } \textit{ posição} \in \widetilde{b_{\textit{área_antropizada}}} \\
 & \textit{ENTÃO } \textit{ classe} = \widetilde{c_{\textit{área_antropizada}}}
 \end{aligned}$$

onde $\widetilde{c_{\textit{área_antropizada}}}$ é um conjunto nebuloso de C . Analogamente a regra R_{1a} essa regra não é explicitada em uma "workspace" própria.

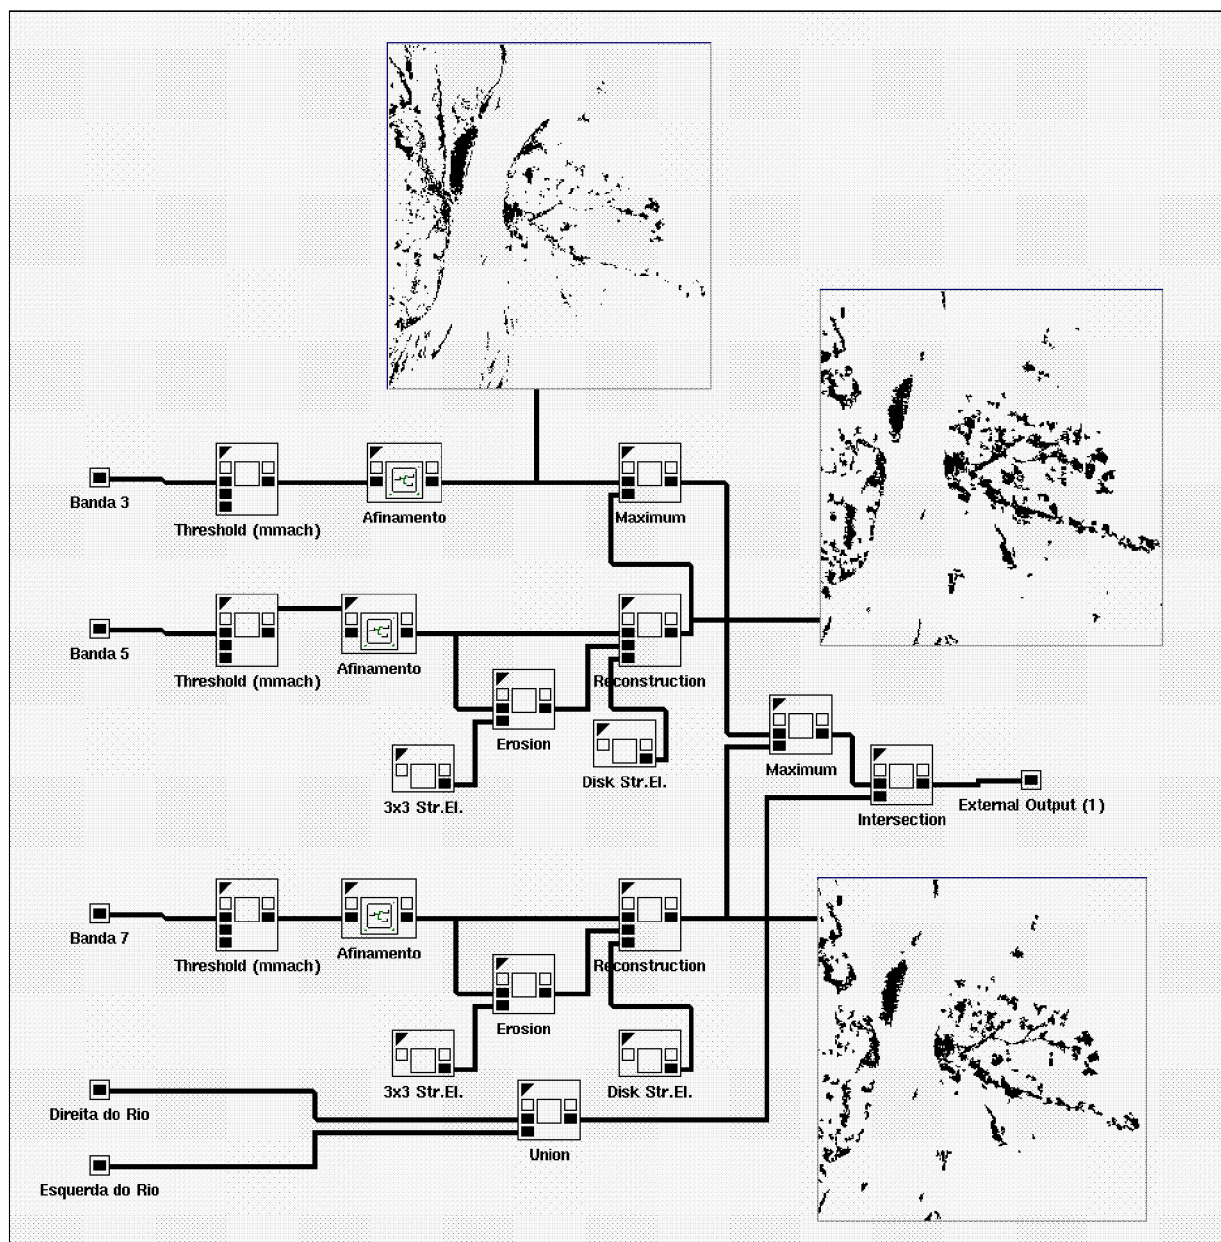


Fig. 5.9: "Workspace" que extrai o atributo Área Antropizada.

A Classe Área Urbana da Cidade de Aveiro Pela descrição, a cidade de Aveiro se encontra dentro da Área Antropizada. Por isso, utilizando-se uma limiarização mais restrita pode-se obtê-la, ainda que apenas isso não baste. Uma outra informação importante é que é possível visualizar os cruzamentos das ruas da cidade. As regras são:

$$\begin{aligned}
 R_6 : & \text{SE } \textit{posição} \in \widetilde{b_{\textit{área-antropizada}}} \\
 & \textit{E radiometria_na_banda_3} = \widetilde{\textit{aproximadamente_entre_37_e_70}} \\
 & \textit{E radiometria_na_banda_7} = \widetilde{\textit{aproximadamente_entre_22_e_60}} \\
 & \textit{E posição} \in \widetilde{b_{\textit{margem_direita_do_rio}}} \\
 & \textit{ENTÃO } \textit{posição} \in \widetilde{b_{\textit{possíveis-áreas-de-cidade}}} \\
 R_7 : & \text{SE } \textit{posição} \in \widetilde{\textit{componente_conexa_5}} \\
 & \textit{ENTÃO } \textit{classe} = \widetilde{\textit{área_urbana_da_cidade_de_Aveiro}}
 \end{aligned}$$

onde: *componente_conexa_5* denota o conjunto nebuloso dado pela descrição "componente conexa do conjunto das posições dos "pixels" que denotam "possíveis áreas de cidade" marcado pela erosão das $\widetilde{b_{\textit{possíveis-áreas-de-cidade}}}$ pela cruz.

Conforme pode ser visto na Figura 5.10, a implementação é praticamente uma tradução da própria regra. Faz-se uma limiarização da banda 3 e 7, em uma faixa de níveis de cinza mais estreita que a da Área Antropizada. O mínimo dessa imagem com a imagem da Margem direita do Rio resulta em uma imagem que contém a área da cidade e outras componentes. Essas áreas são classificadas como "possíveis áreas de cidade". O marcador para a reconstrução leva em consideração os cruzamentos das ruas do centro da cidade, onde a cruz é um elemento presente. Aparece, portanto, a Erosão na regra como uma forma de apontar onde a forma de cruz aparece na imagem. O afinamento elimina ruídos da imagem e segue-se a abertura por reconstrução por um disco estruturante de diâmetro 6. O fechamento a seguir delimita a área urbana da Cidade de Aveiro.

A Classe Floresta Ombrófila Densa

A Floresta Ombrófila Densa é uma área caracterizada pela presença da Drenagem Densa. Essa classe em especial tem alguma diferença em relação às demais classes: somente a caracterização pela drenagem não é suficiente para que o resultado final seja considerado satisfatório. Por esse motivo, além da drenagem, usou-se uma segmentação e a intervenção do usuário para informar ao sistema quais são as componentes conexas que correspondem a Floresta Ombrófila Densa (Figura 5.11).

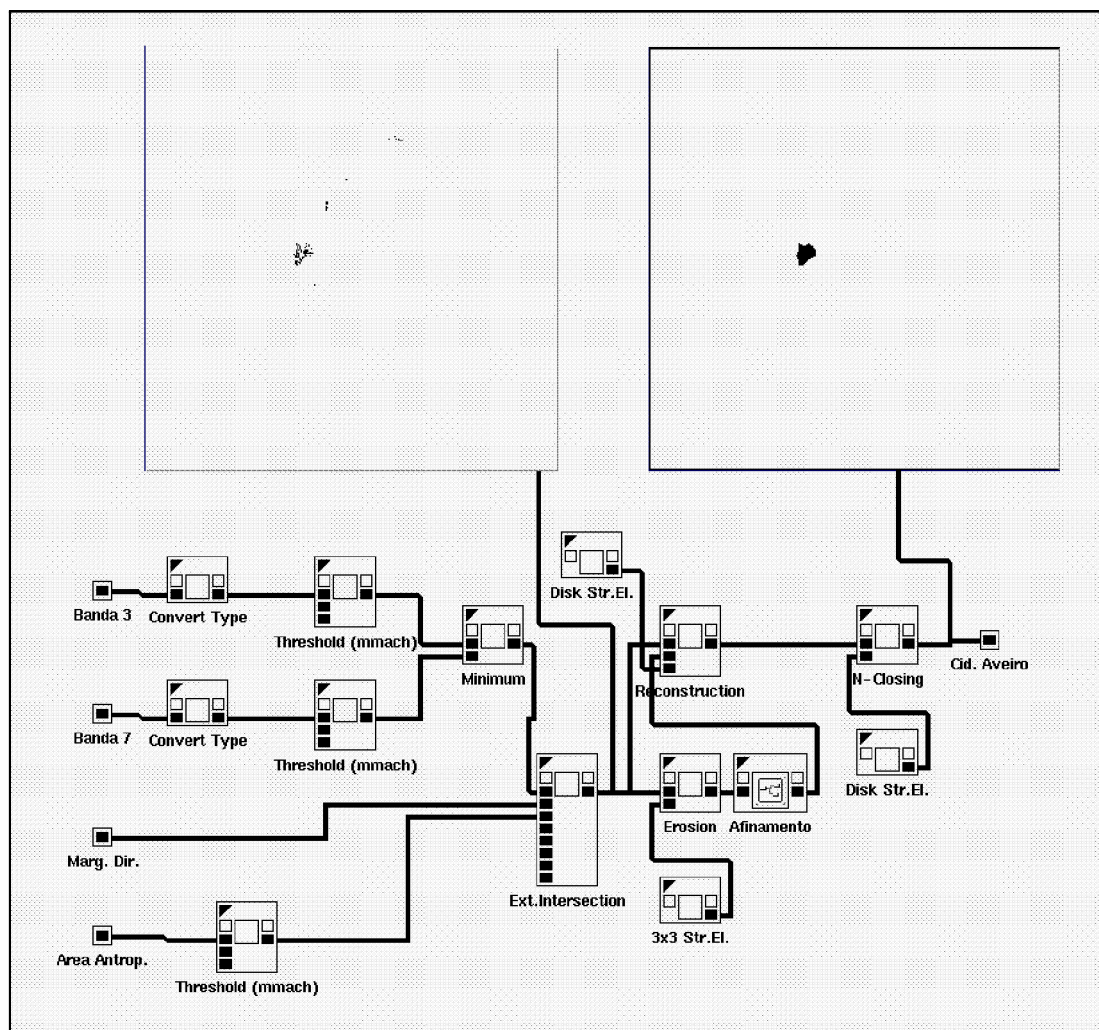


Fig. 5.10: "Workspace" que extrai o atributo Cidade de Aveiro.

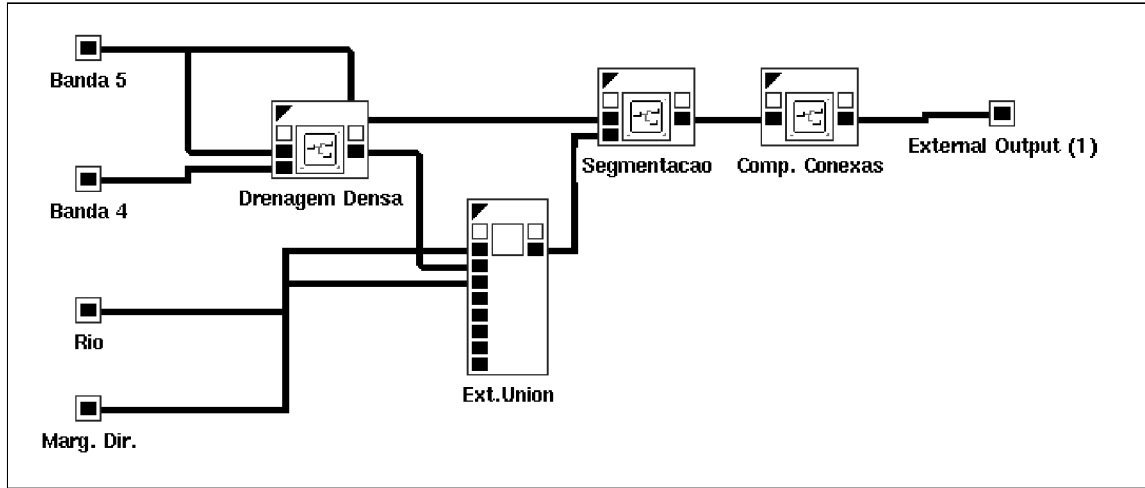


Fig. 5.11: "Workspace" que extrai o sub-atributo Floresta Ombrófila Densa.

O Atributo Drenagem Densa O atributo Drenagem Densa (Textura) é uma das características da classe Floresta Ombrófila Densa que está caracterizada também pela sua distância do Rio e da cidade de Aveiro, na direção leste. As regras são:

$$R_8 : SE \text{ posição} \in \widetilde{\text{componente_conexa_6}} \\ ENTÃO \text{ posição} \in \widetilde{b_{\text{não_longe_da_área_antropizada}}}$$

onde: $\widetilde{\text{componente_conexa_6}}$ denota o conjunto nebuloso dado pela descrição "componente conexa do conjunto das posições dos "pixels" com radiometria aproximada entre 23 e 30 na banda 5, marcado pela área antropizada" e $\widetilde{b_{\text{não_longe_da_área_antropizada}}}$ denota o conjunto nebuloso "não muito longe da área antropizada à leste do rio".

$$R_9 : SE \text{ posição} \in \widetilde{\text{na_região_de_}(\text{longe_do_rio} \text{ E } b_{\text{não_longe_da_área_antropizada}})} \\ E \text{ posição} \in \widetilde{\text{não_ponto_isolado}} \\ ENTÃO \text{ posição} \in \widetilde{b_{\text{marcador_para_textura}}}$$

onde: $\widetilde{\text{na_região_de_}(\text{longe_do_rio} \text{ E } b_{\text{não_longe_da_área_antropizada}})}$ denota o conjunto nebuloso dado pela descrição "na região das áreas 'longe do rio' e 'não muito longe da área antropizada à leste do rio' " e $\widetilde{\text{não_ponto_isolado}}$ denota a filtragem por afinamento.

A seqüência de limiarizações é necessária para uma melhor obtenção da informação. As bandas 4 e 5 são boas para o trabalho sobre drenagem. As limiarizações na banda 5, visam obter uma imagem binária com o atributo Textura para posterior Reconstrução (Figura 5.12). O seu marcador parte de uma imagem binária filtrada por Afinamento e utilizando-se a característica: está localizada Não Muito Longe da Área Antropizada, na direção Leste. Pode-se notar a presença de uma caracterização nebulosa sobre esse atributo: Não Muito Longe. A função nebulosa que delimita essa condição é dependente da escala da imagem e tem como resultado uma imagem binária para se constituir um marcador para a reconstrução. Essa abertura por reconstrução por um disco planar de diâmetro 22 isola o atributo Textura, porém ainda não de forma satisfatória. Para resolver esse problema, utiliza-se da informação adicional: ela está Longe do Rio. Porém, aqui sua conotação é de melhorar a imagem reconstruída visando aprimorar o marcador que será usado na segmentação posteriormente, pela intersecção das duas imagens. Novamente, um Afinamento é aplicado para filtragem.

A "caixinha" "Proxim. Drenag." faz o papel da expressão "na região de" e se trata de uma função dependente da escala da imagem e tem como resultado uma imagem binária. Em seguida, aplica-se o operador "Close Holes" (por um quadrado estruturante 3x3) que melhora definitivamente a qualidade do marcador. Por fim, obtém-se um marcador para a Textura que tem como conotação: nas proximidades da área de Drenagem.

A Segmentação e Componentes Conexas Como o que foi obtido foi um marcador para a área da Floresta Ombrófila Densa através da Drenagem Densa e não a classe propriamente, pode-se lançar mão de uma segmentação para obter essa classe. A segmentação tem duas imagens de entrada: uma das entradas para a segmentação é a imagem de uma das bandas (no caso a banda 5) e a outra é a união dos marcadores que são os originados pelas regras que definem o Rio, a Margem Direita do Rio e a Drenagem Densa (Figura 5.13). Vale salientar que a segmentação não é um processo que tenha uma regra como equivalente, contida no sistema especialista. Porém, contém em seu bojo um conhecimento morfológico.

A segmentação ajuda a dar uma forma final a classe Floresta Ombrófila Densa. Porém, para apontá-la, lança-se mão de um outro conceito da Morfologia: o de Componentes Conexas.

A "caixinha" Componentes Conexas é o decisor que vai selecionar a classe Floresta Ombrófila Densa, em sua forma final. Nesse ponto, a intervenção do usuário é decisiva, apontando as "componentes conexas" que realmente constituem a classe, após a rotulação ("Labeling") - Figura 5.14.

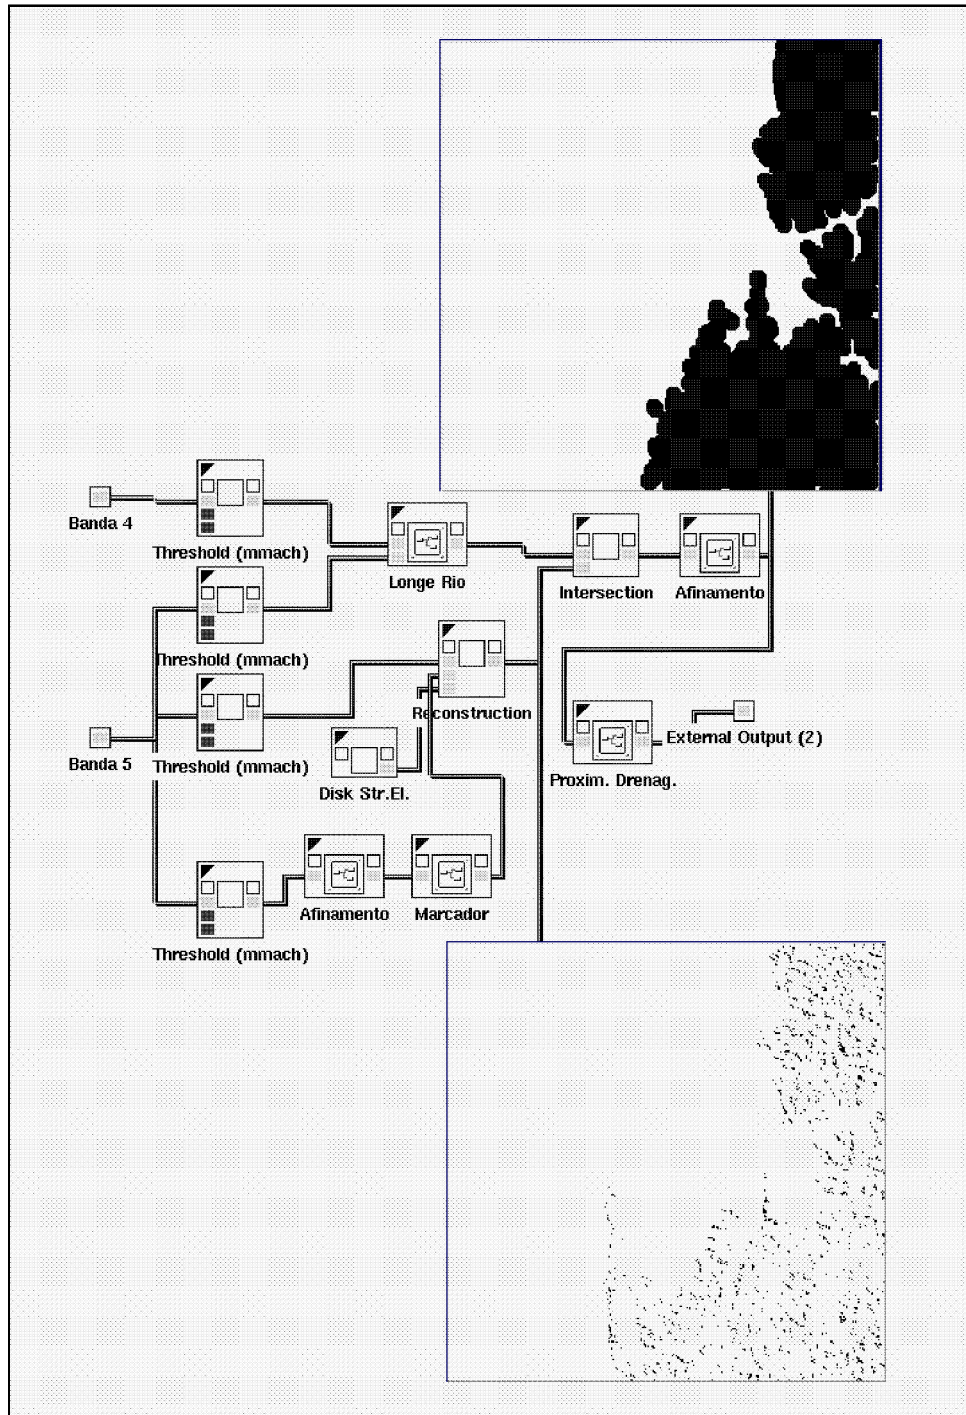


Fig. 5.12: "Workspace" que extrai o atributo Drenagem Densa (regras R_8 e R_9).

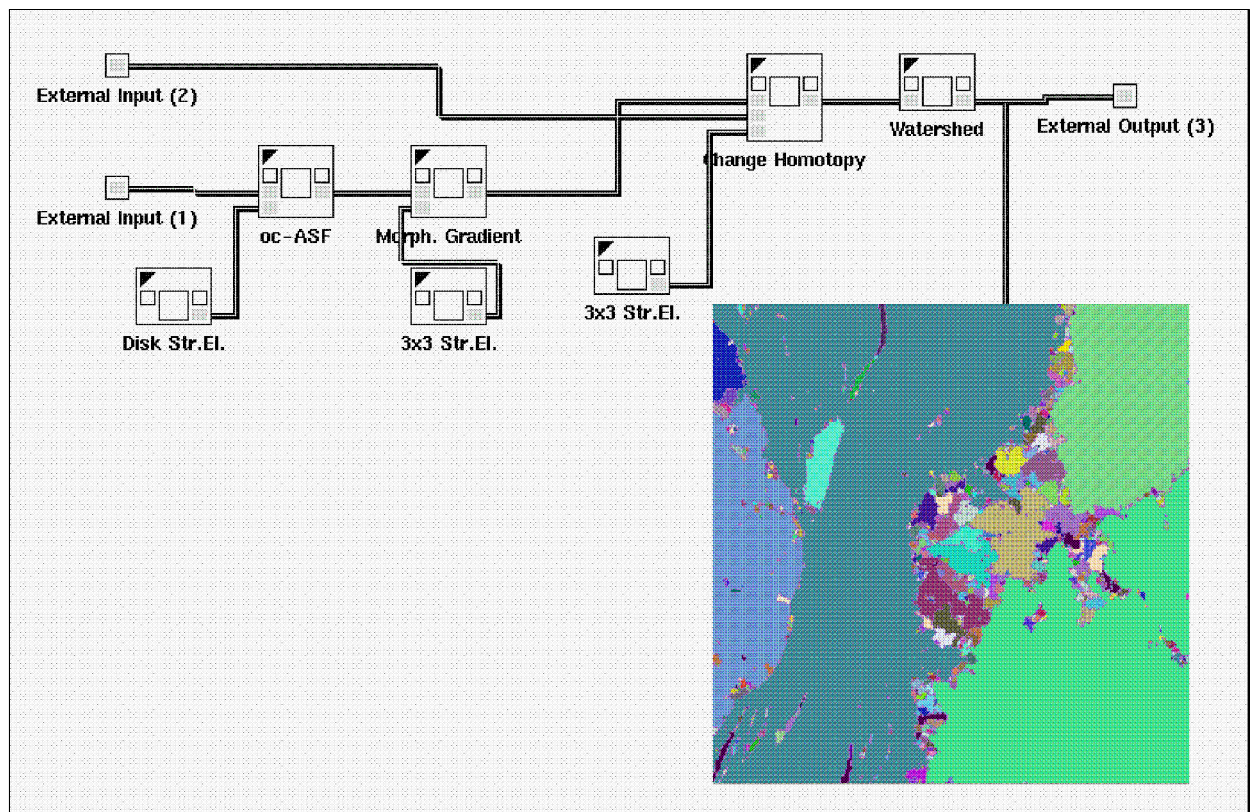


Fig. 5.13: "Workspace" que implementa a segmentação no Khoros 2.1

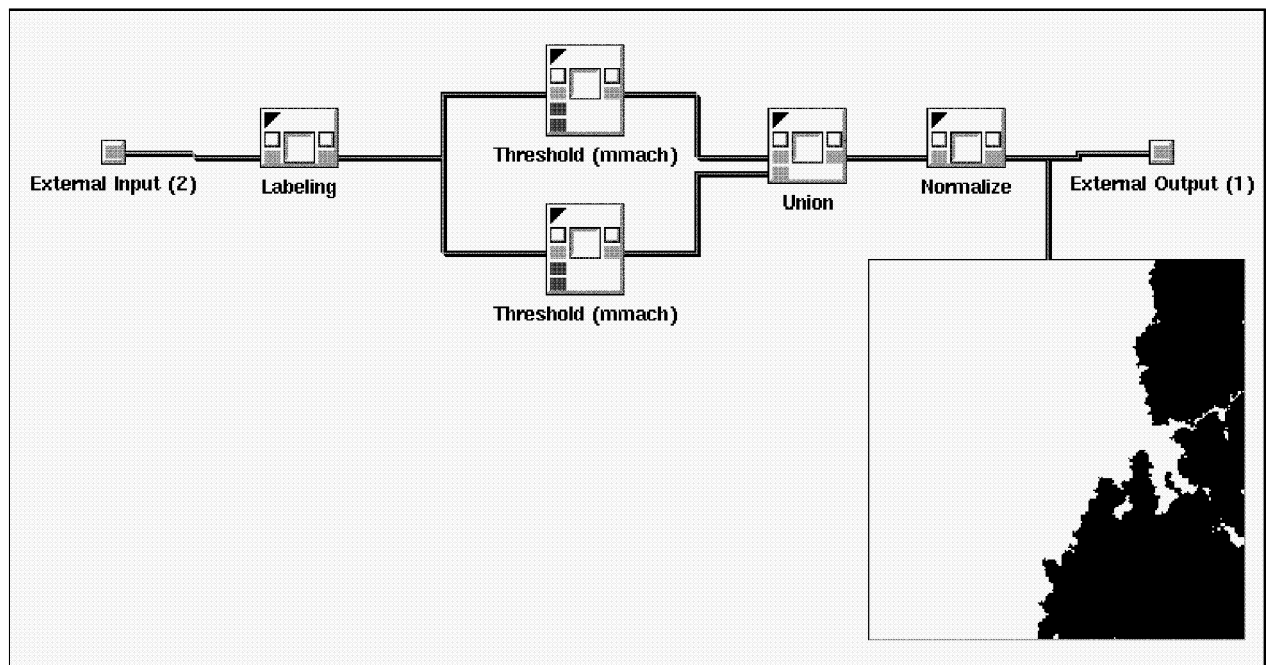


Fig. 5.14: Operadores que compõem a "caixinha" Componentes Conexas.

A Classe Floresta Aluvial

Conforme visto anteriormente, a Floresta Aluvial está presente em ambos os lados do Rio e é definida pelas regras:

$$R_{10} : SE \text{ posição} \in \widetilde{\text{erosão_da_banda_7_à_direita_do_rio}} \\ ENTÃO \text{ posição} \in \widetilde{b_{pafadr7}}$$

onde: $\widetilde{\text{erosão_da_banda_7_à_direita_do_rio}}$ denota o conjunto nebuloso dado pela descrição "erosão das componentes com radiometria aproximada entre 6 e 8 na banda 7 e à direita do rio" e $\widetilde{b_{pafadr7}}$ denota o conjunto nebuloso "possíveis áreas de floresta aluvial à direita do rio na banda 7".

$$R_{11} : SE \text{ posição} \in \widetilde{\text{erosão_da_banda_5_à_direita_do_rio}} \\ ENTÃO \text{ posição} \in \widetilde{b_{pafadr5}}$$

onde: $\widetilde{\text{erosão_da_banda_5_à_direita_do_rio}}$ denota o conjunto nebuloso dado pela descrição "erosão das componentes com radiometria aproximada entre 44 e 47 na imagem filtrada da banda 5 e à direita do rio" e $\widetilde{b_{pafadr5}}$ denota o conjunto nebuloso dado pela descrição "possíveis áreas de floresta aluvial à direita do rio na banda 5".

$$R_{12} : SE \text{ posição} \in \widetilde{b_{pafadr7}} \\ E \text{ posição} \in \widetilde{b_{pafadr5}} \\ ENTÃO \text{ posição} \in \widetilde{b_{pafadr}}$$

onde: $\widetilde{b_{pafadr}}$ denota o conjunto nebuloso "possíveis áreas de floresta aluvial à direita do rio".

$$R_{13} : SE \text{ posição} \in \widetilde{\text{componente_conexa_7}} \\ ENTÃO \text{ posição} \in \widetilde{b_{afadr}}$$

onde: $\widetilde{\text{componente_conexa_7}}$ denota o conjunto nebuloso dado pela descrição "componente conexa das possíveis áreas de floresta aluvial à direita do rio na banda 5" marcado pelas possíveis áreas de floresta aluvial à direita do rio" e $\widetilde{b_{afadr}}$ denota o conjunto nebuloso "áreas de floresta aluvial à direita do rio".

$$R_{14} : SE \text{ radiometria_na_banda_7} = \widetilde{\text{aproximadamente_entre_6_e_8}} \\ E \text{ posição} \in \widetilde{b_{lado_esquerdo_do_rio}} \\ E \text{ posição} \in \widetilde{\text{não_ponto_isolado}} \\ ENTÃO \text{ posição} \in \widetilde{b_{paf aer7}}$$

onde: $\widetilde{b_{paf aer7}}$ denota o conjunto nebuloso "possíveis áreas de floresta aluvial à esquerda do rio na banda 7".

$$R_{15} : SE \text{ posição} \in \widetilde{\text{erosão_da_banda_5_à_esquerda_do_rio}} \\ ENTÃO \text{ posição} \in \widetilde{b_{paf aer5}}$$

onde: $\widetilde{eros\tilde{a}o_da_banda_5\grave{a}_esquerda_do_rio}$ denota o conjunto nebuloso dado pela descrio "eroso das componentes com radiometria aproximada entre 44 e 47 na imagem filtrada da banda 5 e  esquerda do rio" e $\widetilde{b_{paf\grave{a}erb5}}$ denota o conjunto nebuloso "possveis reas de floresta aluvial  esquerda do rio na banda 5".

$$R_{16} : SE \text{ posico} \in \widetilde{componente_conexa_8} \\ ENT\tilde{A}O \text{ posico} \in \widetilde{b_{afaer}}$$

onde: $\widetilde{componente_conexa_8}$ denota o conjunto nebuloso dado pela descrio "componente conexa das possveis reas de floresta aluvial  esquerda do rio na banda 7 marcado pelas possveis reas de floresta aluvial  esquerda do rio na banda 5" e $\widetilde{b_{afaer}}$ denota o conjunto nebuloso "reas de floresta aluvial  esquerda do rio".

$$R_{17} : SE \text{ posico} \in \widetilde{b_{afadr}} \\ OU \text{ posico} \in \widetilde{b_{afaer}} \\ ENT\tilde{A}O \text{ posico} \in \widetilde{b_{\acute{a}reas_de_floresta_aluvial}}$$

A Figura 5.15 ilustra a obteno do atributo Floresta Aluvial. Como esta classe em particular foi definida pelo especialista sobre a composio RGB da Figura 5.2, como uma colorao especfica de verde, as regras que a definem em imagens em nveis de cinza so regras operacionais. A seqncia de limiarizaes e eroses so necessrias para uma melhor obteno da informao resultando tanto  direita como  esquerda do Rio em possveis reas de floresta aluvial. Em particular, uma filtragem pelo filtro da mediana  til na banda 5 para realar essa rea. Na seqncia, a Reconstruo recupera a informao em ambos os lados do Rio e a unio final recoloca essas reas em uma mesma imagem.

Para a classe $\widetilde{c_{\acute{a}reas_de_floresta_aluvial}}$, uma regra adicional R_{17a} relaciona o conjunto nebuloso $\widetilde{c_{\acute{a}reas_de_floresta_aluvial}}$ ao conjunto nebuloso $\widetilde{b_{\acute{a}reas_de_floresta_aluvial}}$ dado pela regra R_{17} :

$$R_{17a} : SE \text{ posico} \in \widetilde{b_{\acute{a}reas_de_floresta_aluvial}} \\ ENT\tilde{A}O \text{ classe} = \widetilde{c_{\acute{a}reas_de_floresta_aluvial}}$$

onde $\widetilde{c_{\acute{a}reas_de_floresta_aluvial}}$  um conjunto nebuloso. Essa regra, de forma anloga a regra R_{5a} , no  explicitada em uma "workspace" prpria.

A Classe rea de Contato: Floresta Ombrfila/Formaes Pioneiras

As reas de Contato: Floresta Ombrfila/Formaes Pioneiras, ou simplesmente rea de Contato, so as ilhas que aparecem no Rio e algumas reas em algumas partes das margens  esquerda e  direita do Rio. As regras so:

$$R_{18} : SE \text{ posição} \in \neg(\text{posição} \in \widetilde{b_{rio}} \text{ OU } \text{posição} \in \widetilde{b_{lado_direito_do_rio}} \text{ OU } \text{posição} \in \widetilde{b_{lado_esquerdo_do_rio}})$$

$$\text{ENTÃO } \text{posição} \in \widetilde{b_{acnr}}$$

onde: $\widetilde{b_{acnr}}$ denota o conjunto nebuloso "áreas de contato no rio".

$$R_{19} : SE \text{ posição} \in \text{componente_conexa_9}$$

$$\text{ENTÃO } \text{posição} \in \widetilde{b_{acdr}}$$

onde: $\text{componente_conexa_9}$ denota o conjunto nebuloso dado pela descrição "componente conexa da área antropizada marcado pela erosão da componente (Direita do Rio E Muito Muito Perto do Rio)" e $\widetilde{b_{acdr}}$ denota o conjunto nebuloso "áreas de contato à direita do rio".

$$R_{20} : SE \text{ posição} \in \text{erosão_2_da_banda_5_à_esquerda_do_rio}$$

$$\text{ENTÃO } \text{posição} \in \widetilde{b_{pacer}}$$

onde: $\text{erosão_2_da_banda_5_à_esquerda_do_rio}$ denota o conjunto nebuloso dado pela descrição "erosão das componentes com radiometria aproximada entre 46 e 51 na imagem filtrada da banda 5 e à esquerda do rio" e $\widetilde{b_{pacer}}$ denota o conjunto nebuloso "possíveis áreas de contato à esquerda do rio".

$$R_{21} : SE \text{ posição} \in \text{componente_conexa_10}$$

$$\text{ENTÃO } \text{posição} \in \widetilde{b_{acer}}$$

onde: $\text{componente_conexa_10}$ denota o conjunto nebuloso dado pela descrição "componente conexa das possíveis áreas de contato à esquerda do rio na banda 5 marcado pela Dilatação da (Erosão da componente (Esquerda do Rio E Muito Muito Perto do Rio))" e $\widetilde{b_{acer}}$ denota o conjunto nebuloso "áreas de contato à direita do rio".

$$R_{22} : SE \text{ posição} \in \widetilde{b_{acnr}}$$

$$\text{OU } \text{posição} \in \widetilde{b_{pacdr}}$$

$$\text{OU } \text{posição} \in \widetilde{b_{acer}}$$

$$\text{ENTÃO } \text{posição} \in \widetilde{b_{\text{áreas_de_contato}}}$$

Pode-se observar pelas regras definidas acima e pela Figura 5.16 que a obtenção das Áreas de Contato necessita de três enfoques diferentes: uma para as ilhas no Rio, uma para as áreas à esquerda e outro para as áreas à direita do Rio. Ao final a união dos três recoloca as áreas em uma mesma imagem.

Pode-se observar também que há uma entrada Flor. Aluv 2 na Figura 5.16. Essa entrada corresponde a regra R_{20} que, por uma questão de praticidade, está computada juntamente com a floresta aluvial e pode ser observada na Figura 5.15.

Para a classe $\widetilde{C_{\text{áreas_de_contato}}}$, uma regra adicional R_{22a} relaciona o conjunto nebuloso $\widetilde{C_{\text{áreas_de_contato}}}$ ao conjunto nebuloso $\widetilde{b_{\text{áreas_de_contato}}}$ obtido na regra R_{22} :

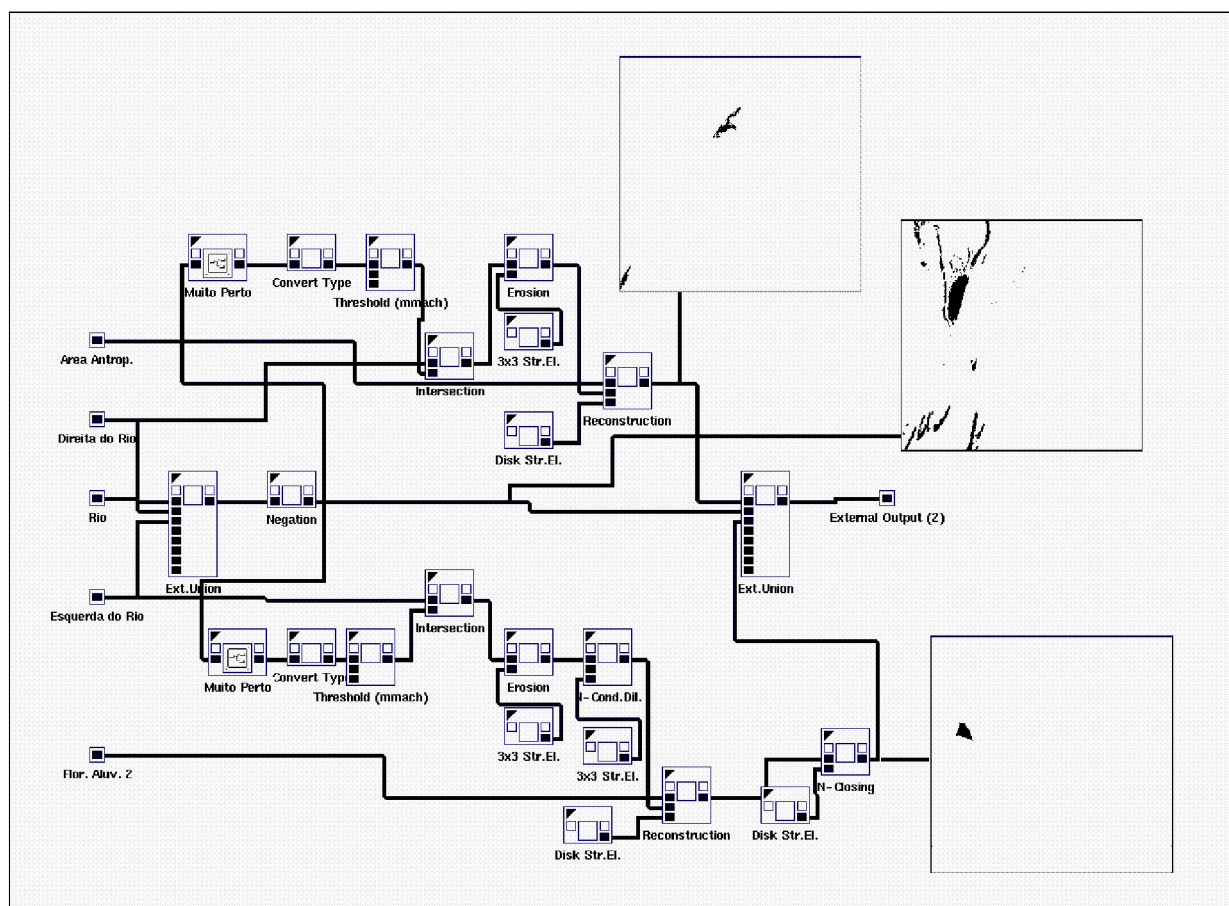


Fig. 5.16: "Workspace" que isola o atributo Área de Contato: Floresta Ombrófila/Formações Pioneiras.

$$R_{22a} : SE \text{ posição} \in \widetilde{b_{\text{áreas_de_contato}}}$$

$$ENTÃO \text{ classe} = \widetilde{c_{\text{áreas_de_contato}}}$$

onde $\widetilde{c_{\text{áreas_de_contato}}}$ é um conjunto nebuloso. Analogamente a regra R_{17a} , essa regra não é explicitada em uma "workspace" própria.

A Classe Área de Mistura

As áreas de mistura são áreas à esquerda do Rio nas quais não é possível para o foto-intérprete distingüí-las tanto sobre as imagens em níveis de cinza como sobre a composição colorida. Nessa última é possível verificar que tal área é a mistura de duas outras: área antropizada e floresta secundária. As áreas de mistura são obtidas por exclusão e as regras são:

$$R_{23} : SE \text{ posição} \in \widetilde{b_{\text{esquerda_do_rio}}}$$

$$E \text{ posição} \in \widetilde{\text{área_norte}}$$

$$ENTÃO \text{ posição} \in \widetilde{b_{\text{anmer}}}$$

onde: $\widetilde{\text{área_norte}}$ denota o conjunto nebuloso dado pela descrição "está ao norte da componente conexa da floresta aluvial marcado por (esquerda do rio E muito muito perto do rio E não rio E floresta aluvial)" e $\widetilde{b_{\text{anmer}}}$ denota o conjunto nebuloso dado pela descrição "áreas ao norte na margem esquerda do rio".

$$R_{24} : SE \text{ posição} \in \widetilde{b_{\text{esquerda_do_rio}}}$$

$$E \text{ posição} \in \neg \widetilde{b_{\text{anmer}}}$$

$$OU \text{ posição} \in \neg \widetilde{b_{\text{áreas_de_floresta_aluvial}}}$$

$$OU \text{ posição} \in \neg \widetilde{b_{\text{área_antropizada}}}$$

$$ENTÃO \text{ posição} \in \widetilde{b_{\text{áreas_de_mistura}}}$$

A regra R_{23} reúne as características na parte norte do lado esquerdo do Rio que pertencem a áreas bem definidas. A regra R_{24} reúne a área obtida pela regra R_{23} , às áreas complementares ao sul que também estão bem definidas. Assim, as áreas ainda não classificadas nessa região são as áreas de mistura - implementada pela negação na Figura 5.17.

Para a classe $\widetilde{c_{\text{áreas_de_mistura}}}$, uma regra adicional R_{24a} relaciona o conjunto nebuloso $\widetilde{c_{\text{áreas_de_mistura}}}$ com o conjunto nebuloso $\widetilde{b_{\text{áreas_de_mistura}}}$ obtido na regra R_{24} :

$$R_{24a} : SE \text{ posição} \in \widetilde{b_{\text{áreas_de_mistura}}}$$

$$ENTÃO \text{ classe} = \widetilde{c_{\text{áreas_de_mistura}}}$$

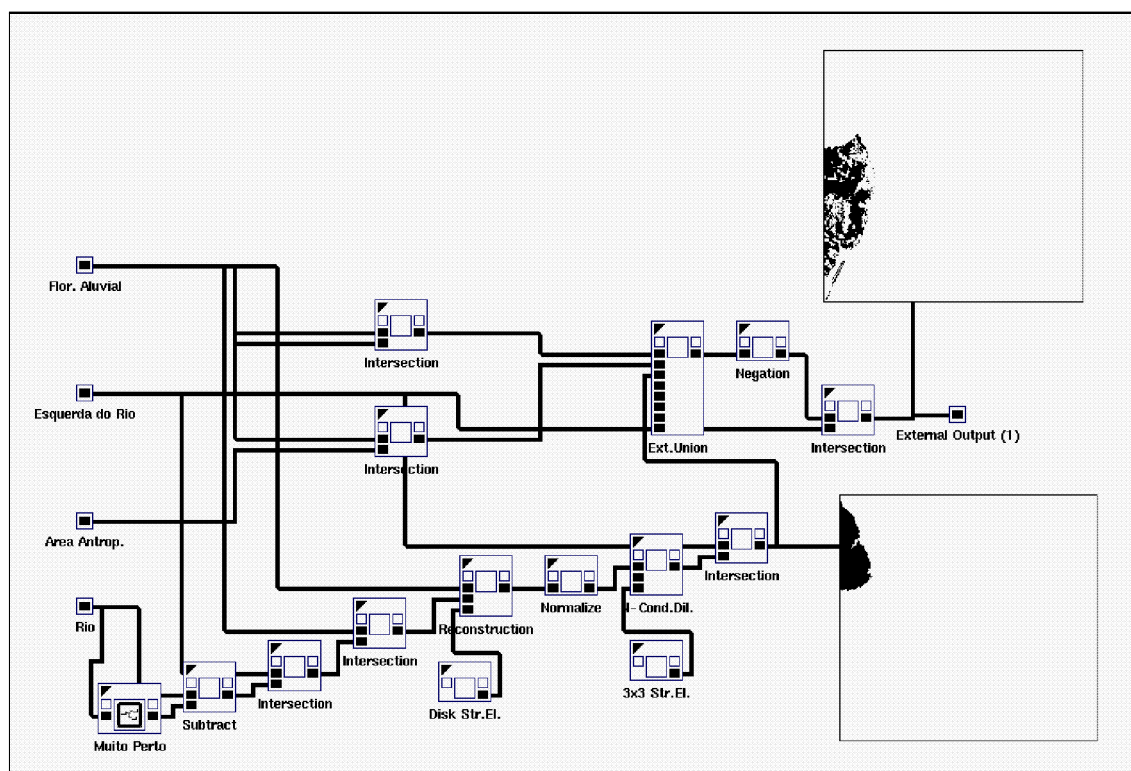


Fig. 5.17: "Workspace" que isola o atributo Áreas de Mistura.

onde $\widetilde{c_{\text{áreas_de_mistura}}}$ é um conjunto nebuloso. Analogamente a regra R_{22a} , essa regra não é explicitada em uma "workspace" própria.

A Classe Vegetação Secundária

A classe $c_{\text{vegetação_secundária}}$ é obtida por exclusão das demais classes. A regra é:

$$\begin{aligned}
 R_{25} : & \text{SE } \text{posição} \in \neg \widetilde{b_{\text{rio}}} \\
 & \text{OU } \text{posição} \in \neg \widetilde{b_{\text{área_antropizada}}} \\
 & \text{OU } \text{posição} \in \neg \widetilde{b_{\text{floresta_ombrófila_densa_submontana}}} \\
 & \text{OU } \text{posição} \in \neg \widetilde{b_{\text{áreas_de_floresta_aluvial}}} \\
 & \text{OU } \text{posição} \in \neg \widetilde{b_{\text{áreas_de_contato}}} \\
 & \text{OU } \text{posição} \in \neg \widetilde{b_{\text{áreas_de_mistura}}} \\
 & \text{ENTÃO } \text{classe} = c_{\text{vegetação_secundária}}
 \end{aligned}$$

Para esta classe, não há a necessidade de uma "workspace", visto que todos os "pixels" que não foram atribuídos a uma outra classe qualquer será atribuído a classe Vegetação Secundária.

5.4.2. As Áreas Classificadas

A "caixinha" "Áreas Classificadas" agrega todas as informações e as acomoda em uma única imagem. Como todas as imagens de entrada são imagens binárias uma simples união delas resultaria também numa imagem binária. Por isso, é feito um conjunto de operações algébricas para diferenciar cada entrada e atribuir um nível de cinza. Ao final, as imagens são somadas resultando em uma imagem em níveis de cinza que é colorida pela "caixinha" "Thematic Map" e exibida por "Classif. Final".

Vale observar que a sobreposição de classes, como Área Antropizada e Cidade de Aveiro (a segunda é um subconjunto da primeira) é resolvida por uma hierarquia na confecção da imagem final que resolve possíveis conflitos. Por exemplo, a classe Rio que é obtida em primeiro lugar, recebe o nível mais baixo dos níveis de cinza e assim por diante. Se alguma outra classe tem algum ponto com interseção com a classe Rio, a opção é que esse ponto seja classificado com o nível mais baixo, ou seja, como Rio.

6. COMPARAÇÃO COM UM MAPA DE REFERÊNCIA

”Nós cientistas precisamos especialmente da imaginação.
Não bastam a matemática e a lógica: necessitamos
algo de estética e poesia”

Maria Mitchell (1818-1889).

A aplicação da abordagem proposta neste trabalho (vide Capítulo 4) com o conhecimento modelado pelas regras da Seção 5.4 deram como resultado a classificação final ilustrada na Figura 6.1 e, na Figura 6.2, estão as legendas da classificação. Pode-se verificar que as cores utilizadas na classificação visual são as mesmas utilizadas aqui para melhor visualização comparativa.

A classificação visual da Figura 5.3, conforme descrita na Seção 5.2, é o mapa de referência utilizado para efeito de comparação. Deve-se salientar que a imagem de referência não serviu de base para a classificação apresentada na Figura 5.3. Na Figura 6.3 pode-se observar as diferenças espaciais da classificação. Pode-se notar que boa parte dos erros ocorre nas fronteiras entre as classes. Uma provável causa para os erros de menor magnitude é a digitalização manual da imagem de referência. A digitalização manual é imprecisa e pode induzir aos erros nas fronteiras entre as classes. Erros pontuais são devidos ao fato que o fotointérprete mapeia áreas classificadas e não consegue observar a imagem pontualmente. Os erros de maior magnitude induzem a conclusão de que possivelmente, há a necessidade de regras mais específicas para resolver esse problema. No entanto, dependendo da(s) classes(s) de interesse, esse resultado já pode ser considerado plenamente satisfatório.

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. Por esse motivo, a análise de resultados será realizada também sob a ótica de coeficientes de comparação existentes na literatura e apresentados a seguir.




Fig. 6.1: Resultado final da classificação.

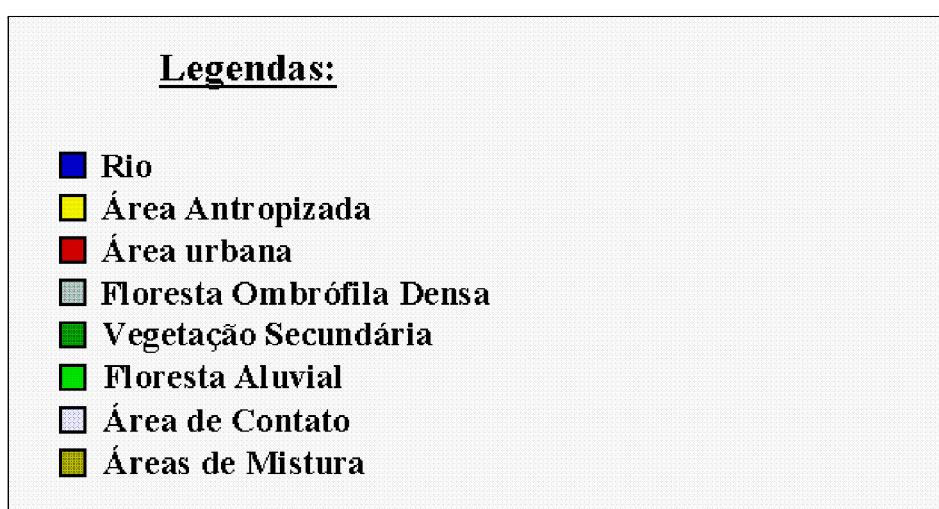


Fig. 6.2: Legendas da classificação da Figura 6.1.




Fig. 6.3: Localização espacial dos erros de classificação.

6.1. Os coeficientes de comparação

”A boa fotointerpretação de uma imagem depende da experiência e da habilidade individual do fotointérprete” (Congalton e Mead, 1983). Como o intérprete atua sobre aspectos qualitativos da imagem, é inevitável que a subjetividade do fotointérprete atue sobre o seu julgamento. Também, por razões óbvias, o julgamento se dá em regiões da imagem e não pontualmente. Por essas razões, sempre existirão diferenças na fotointerpretação de uma mesma cena por dois fotointérpretes diferentes. Para medir estatisticamente essas diferenças ou verificar a consistência de um mesmo fotointérprete ao longo do tempo, surgiram índices ou coeficientes (Congalton e Mead, 1983).

Neste caso especificamente, para verificar numericamente as diferenças da classificação de um fotointérprete e do método apresentado, usaremos três desses coeficientes ou índices: Exatidão Global, Kappa e Tau (Brites et al., 1996). Todos são baseados na matriz de erros para cada classificação, tomando como referência a interpretação visual.

6.1.1. O Coeficiente de Exatidão Global

O Coeficiente de Exatidão Global leva em consideração a relação do número total de pontos coincidentes pelas duas classificações pelo número total de pontos da imagem. Seria a relação mais intuitiva de concordância.

Sejam, M o número de classes presentes na imagem, N o número total de pontos da imagem e n_{ij} os elementos da matriz de erros das duas classificações ($0 < i, j \leq M$). O Coeficiente de Exatidão Global G é dado por:

$$G = \frac{\sum_{i=1}^M n_{ii}}{N},$$

com variância σ_G^2 dada por:

$$\sigma_G^2 = \frac{G(1 - G)}{N}.$$

A crítica mais severa a esse coeficiente é o seu ”otimismo”. Por não observar as relações entre as classes, mesmo com acerto muito pequeno em classes com um número pequeno de pontos, o coeficiente pode refletir valores acima do real. Isso se deve ao fato de analisar as informações apenas da diagonal principal da matriz de erros.

6.1.2. O Coeficiente Kappa

O coeficiente Kappa K procura ponderar as concordâncias, levando em consideração as classes presentes na imagem. É dado por:

$$P_0 = \frac{\sum_{i=1}^M n_{ii}}{N}; \quad P_c = \frac{\sum_{i=1}^M n_{i+} n_{+i}}{N^2};$$

$$K = \frac{P_0 - P_c}{1 - P_c},$$

onde n_{i+} é o total da linha i da matriz de erros e n_{+i} é o total da coluna i da mesma matriz. A variância σ_K^2 dada por:

$$\theta_3 = \frac{\sum_{i=1}^M n_{ii}(n_{i+} + n_{+i})}{N^2}; \quad \theta_4 = \frac{\sum_{i=1}^M n_{ii}(n_{i+} + n_{+i})^2}{N^3}$$

$$\sigma_G^2 = \frac{P_0(1 - P_0)}{N(1 - P_c)^2} + \frac{2(1 - P_0) + 2P_0P_c - \theta_3}{N(1 - P_c)^3} + \frac{(1 - P_0)^2\theta_4 - 4P_c^2}{N(1 - P_c)^4}.$$

Para efeito de cálculos, pode ser utilizada uma forma aproximada pela primeira parcela apenas. Mas, nos cálculos realizados nesse trabalho, foi utilizado a forma completa da variância. A crítica a esse coeficiente é o seu "pessimismo", que se deve ao fato de incorporar a informação da diagonal principal além do restante da matriz.

6.1.3. O Coeficiente Tau

O coeficiente Kappa T foi o último dos três a aparecer (Ma e Redmond, 1995) e foi uma tentativa de melhorar o teste Kappa. É dado por:

$$P_0 = \frac{\sum_{i=1}^M n_{ii}}{N};$$

$$T = \frac{P_0 - 1/M}{1 - 1/M},$$

e variância σ_T^2 dada por:

$$\sigma_T^2 = \frac{P_0(1 - P_0)}{N(1 - 1/M)^2}.$$

Em análise comparativa, Brites et al. (1996) conclui que esse deva ser o índice que melhor reflete a exatidão dos processos de classificação.

6.2. Resultados

A matriz de erros é utilizada para verificar as atribuições de classes entre duas classificações, tomando-se uma delas como referência. A matriz de erros em termos absolutos entre as imagens classificada e de referência é apresentada na Tabela 6.1.

TABELA 6.1 - MATRIZ DE ERROS DA IMAGEM CLASSIFICADA EM RELAÇÃO À IMAGEM DE REFERÊNCIA.

Imagem Referência	Classif.							
	Á. Antr.	Fl. Om.	Vg. Sec.	Rio	C. Av.	Fl. Al.	Á. Cont.	Á. Mist
Á. Ant.	14499	1532	5673	201	201	200	99	2332
Fl. Om	367	73884	5170	0	0	0	0	0
Vg. Sec.	2326	4294	35396	16	38	55	17	0
Rio	547	0	1054	75035	0	3	2797	150
C. Av.	383	0	71	1	395	0	0	0
Fl. Al.	385	91	1584	0	0	1776	0	1153
Á. Cont.	120	0	331	1194	0	0	6091	167
Á. Mist	2070	0	6	75	0	247	19	8156

Os coeficientes de exatidão para cada classe isoladamente, em relação a imagem de referência são dados na Tabela 6.2.

TABELA 6.2 - COEFICIENTE DE EXATIDÃO PARA AS CLASSES NA IMAGEM CLASSIFICADA.

Classe	Exatidão(%)
Área Antropizada	59.0928
Flor. Omb. Densa	93.0283
Veg. Secundária	83.9922
Rio	94.2817
Cidade de Aveiro	46.4706
Flor. Aluvial	35.5983
Ár. de Contato	77.0720
Áreas de Mistura	77.1399

Segundo Brites et al. (1996), e como já mencionado, esses três coeficientes guardam entre si uma relação. Para efeito de comparação, utilizou-se os três coeficientes e os resultados são mostrados na Tabela 6.3.

TABELA 6.3 - VALORES PERCENTUAIS DOS COEFICIENTES E RESPECTIVAS VARIÂNCIAS POR COEFICIENTE.

Coeficientes	Valores (%)	Variância
Kappa	81.6150	$7.8613 \cdot 10^{-7}$
Tau	84.1061	$6.2553 \cdot 10^{-7}$
Exat. Global	86.0928	$4.7892 \cdot 10^{-7}$

Observa-se a existência de uma diferença numérica entre os coeficientes, mas de uma maneira geral, pode-se concluir que a classificação alcançou padrões bastante aceitáveis, na casa dos 80%. Como em Brites et al. (1996) conclui-se que o coeficiente que melhor reflete a exatidão dos processos de classificação é o coeficiente Tau, pode-se concluir que a semelhança entre a imagem classificada e a imagem de referência seja na ordem de 84%.

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 5.3

7. CONCLUSÕES FINAIS E SUGESTÕES

”Um livro é um cérebro que fala;
fechado, é um amigo que espera;
esquecido, uma alma que perdoa;
destruído, é um coração que chora”

Provérbio hindú.

7.1. Conclusões Finais

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.

A inexistência de uma linguagem para a comunicação do sistema com o usuário não é exatamente uma desvantagem frente a sistemas como o ICARE. Pela facilidade de interação do usuário com o ambiente Cantata do Khoros e a forma de modelagem das regras da Seção 4.2.1, a inserção de novas regras ao sistema, bem como a confecção de um outro sistema é simplificada.

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, diferentemente de outros trabalhos citados aqui como (Desachy, 1991) e (Mascarilla, 1995). A invariância a translação dos operadores simplifica 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.

O classificador implementado mostrou uma boa relação custo-benefício. O aperfeiçoamento dos resultados poderia depender de regras ainda mais específicas, implicando conseqüentemente em um aumento do custo computacional. Deve-se notar que a não utilização de fontes externas de informação, no caso analisado, é um importante fator para a boa relação custo-benefício. Porém, a utilização dessas fontes poderia aumentar a acurácia do classificador. Por exemplo, pode-se adicionar bandas correspondentes a informações geográficas de um Sistema de Informações Geográficas (SIG), ou ainda uma banda com informações de uma pré-classificação por um método numérico de classificação. Porém, deve-se observar que a elevação do custo computacional das regras adicionais para tratar essas fontes adicionais de informação pode aumentar a relação custo-benefício. A aplicação apresentada no Capítulo 5 não se utilizou de toda a potencialidade do algoritmo e espera-se que se utilizada os resultados seriam melhores do que os apresentados.

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 "toolbox" MMACH, reduzindo o tempo de desenvolvimento do primeiro protótipo e facilitando o desenvolvimento do classificador final.

Visualmente e estatisticamente, os resultados obtidos são satisfatórios. No entanto, não é possível dizer que esse tipo de classificador possa se adequar a qualquer tamanho da imagem da mesma região. A exigência de interação com o usuário requer um conhecimento que ele não necessariamente poderá fornecer, que é o conhecimento de "componentes conexas". Não cabe a denominação essa interação como uma supervisão na classificação no seu sentido clássico¹, mas sim, no sentido de uma classificação semi-automática ou interativa.

Uma vez pronta e funcionando a "workspace", não é possível dizer que ela não terá dificuldades em tratar cenas da mesma região tomadas em diferentes datas, ainda que não surjam novas classes. Isso é devido a aspectos do próprio sistema que envolve um conhecimento armazenado sobre a área em questão que implicitamente possui uma data. Pequenas variações podem ser contornadas, porém, se tempos depois as áreas forem bastante modificadas, esse classificador pode não fornecer resultados confiáveis. Por exemplo, se uma parte da Floresta Densa der lugar a Vegetação Secundária, a aplicação desse classificador poderá

¹ neste trabalho, entende-se que a supervisão clássica se dá em uma etapa inicial do trabalho de classificação quando o operador passa os parâmetros para o classificador.

resultar em erros de classificação.

7.2. Sugestões para Trabalhos Futuros

Para o prosseguimento futuro desse trabalho, pode-se sugerir:

- Verificar qual é o aumento do custo computacional com uma base de regras mais específica e outras fontes de informação (como planos de um SIG ou uma pré-classificação) e se o aumento da precisão é significativo.
- Estender o classificador para toda a área da Floresta Nacional do Tapajós com o auxílio de outros especialistas.
- Modelar os conjuntos nebulosos referentes às informações radiométricas através de amostragens na própria imagem, gerando histogramas, posteriormente probabilidades e finalmente, transformando-as em possibilidades (Dubois e Prade, 1988; Dubois et al., 1993).
- Remodelar o sistema especialista introduzindo graus de credibilidade às regras e adotando uma abordagem mais geral, seja dentro da teoria dos conjuntos nebulosos, ou na teoria das Evidências de Dempster-Shafer.
- Verificar se a associação a um classificador numérico (como pós-classificador, ou mesmo em conjunto) pode aumentar significativamente a precisão da classificação.

8. REFERÊNCIAS BIBLIOGRÁFICAS

- Banon, G. J. F.; Barrera, J. Decomposition of mappings between complete lattices by mathematical morphology. Part I: general lattices. **Signal Processing**, v. 30, n. 2, p. 299-327, 1993.
- Banon, G. J. F.; Barrera, J. **Bases da morfologia matemática para a análise de imagens**. notas de aula do curso CAP-313. São José dos Campos: INPE, 3. período de 1994.
- Banon, G. J. F. **Characterization of translation invariant elementary morphological images**. São José dos Campos: INPE, 1995. (INPE-5616-RPQ/671).
- Baridó, M. P. F. **Uma comparação entre diferentes métodos multivariados de classificação**. 189 p. Dissertação (Mestrado em Matemática) - Universidade Federal do Rio de Janeiro, 1989.
- Barrera, J.; Banon, G. J. F.; Lotufo, R. A. A Mathematical Morphology Toolbox for the KHOROS System: Specifications for Version 1.2b. Campinas: **Workshop'95 de Morfologia Matemática**. 1995.
- Béreau, M.; Dubuisson, B. A fuzzy extended k-Nearest Neighbors rule. **Fuz. Sets and Syst.**, v. 44, n. 1, p. 17-32, 1991.
- Bezdek, J. C.; Chuah, S. K.; Leep, D. Generalized k-Nearest Neighbor rules. **Fuz. Sets and Syst.**, v. 18, n. 2, p. 237-256, 1986.
- 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.
- Buchanan, B. G.; Shortliffe, E. H. **Rule-based expert systems, the MYCIN experiments of Stanford heuristics programming project**. Reading: Addison-Wesley, 1985.
- Congalton, R. G.; Mead, R. A. A quantitative method to test for consistency and correctness in photointerpretation. **Photogram. Engin. and Rem. Sens.**, v. 49, n.1, p. 69-74, 1983.
- Cooper, D. B.; Freeman, J. H. On the asymptotic improvement in the outcome of supervised learning provided by additional nonsupervised learning. **IEEE Trans. on Comp.**, v. 19, 1970.
- 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.
- Driankov, D.; Hellendorn, H.; Reinfrank, M. **An introduction to fuzzy control**. New York: Springer Verlag, 1993.
- Dubois, D.; Prade, H. **Fuzzy sets and systems - theory and applications**. New York: Academic Press, 1980.
- Dubois, D.; Prade, H. **Possibility theory. An approach to computerized processing of uncertainty**. New york: Plenum, 1988.

- Dubois, D.; Prade, H. What are fuzzy rules and how to use them. **Fuz. Sets and Syst.**, v. 84, n. 2, p. 169-185, 1996.
- Dubois, D.; Prade, H.; Sandri, S. A.; On possibility/probability transformations. In Lowen, R.; Roubens, M. ed. **Fuzzy Logic: State of Art**. Kluwer, New York: 1993, p. 103-112.
- Dunn, J.C. A graph theoretic analysis of pattern classification via Tamura's fuzzy relations. **IEEE Trans. Syst. Man. Cybern.**, v. 4, n. 3 p. 310-313, May, 1974.
- Fisher, R. A. The use of multiple measurements in taxonomic problems. **Ann. Eugen.** v. 7, p. 178-188, 1936 .
- Frery, A. **Algumas ferramentas estatísticas na síntese, processamento e análise de imagens de radar de abertura sintética**. São José dos Campos. 242 p. (INPE-5548-TDI/534). Tese (Doutorado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, 1993.
- Fu, K. S.; Yu, T. S. **Statistical pattern classification using contextual information**. New York: Research Studies Press, 1980.
- Fukunaga, K. **Introduction to statistical pattern recognition**, San Diego: Academic Press, 1990.
- Fundação Instituto Brasileiro de Geografia e Estatística (IBGE). **Manual Técnico da Vegetação Brasileira**. Rio de Janeiro, 1992. (Série manuais técnicos em geociências, 1)
- Fundação Instituto Brasileiro de Geografia e Estatística (IBGE). **Cidades e Vilas do Brasil**, Rio de Janeiro, 1995.
- Granger, C. An application of Possibility Theory to Object Recognition. **Fuz. Sets and Syst.**, v. 28, n. 3, p.:51-362, 1988.
- Haralick, R. M.; Shanmugam, K.; Dinstein, I. H.; Textural Features for Image Classification. **IEEE Trans. on Syst., Man and Cyber.** v. 3, n. 5 p. 610-621, 1973.

- 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.
- Ho, T. K.; Hull, J. J.; Srihari, S. N. Decision combination in multiple classifier systems. **IEEE Trans. on Patt. Anal. and Mach. Intel.**, v. 16, p. 66-75, 1994.
- Instituto Nacional de Pesquisas Espaciais (INPE) **Manual do Spring - v 2.0.2**. [online]. <<http://www.inpe.br/spring/teoria/classif/classif.htm>>, 14 de Março de 1997.
- James, M. **Classification Algorithms**. New York: John Wiley & Sons, 1985.
- Johnson, R. A.; Wichern, D. W. **Applied Multivariate Statistical Analysis**. New York: Prentice-Hall Inc., 1982.
- Kandel A. **Fuzzy Mathematical Technics with Applications**. New York: Addison-Wesley, 1986.
- Kent, J. T.; Mardia, K. V. Spatial classification using fuzzy membership Models. **IEEE Trans. on Patt. Anal. and Mach. Intel.**, v. 10, p. 659-671, 1988.
- Khoral Research Inc. **Khoros Pro: Installation Guide**. Albuquerque: Khoral Research Inc., 1996, 81 p.
- Kissiov, V. T.; Hajitodorov, S. T. A fuzzy version of the K-NN method. **Fuz. Sets and Syst.**, v. 49, n.3, p. 323-329, 1992.
- Kruse, R.; Schwecke, E.; Heinsohn, J.; **Uncertainty and vagueness in knowledge based systems**. Berlin: Springer-Verlag, 1991.

- Ma, Z.; Redmond, R.L. Tau coefficients for accuracy assessment of classification of remote sensing data. **Photogrammetric Engineering and Remote Sensing**, v. 61, n. 4, p. 453-439, 1995.
- 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, 1996.
- Mascarenhas, N. D. A.; Velasco, N. D. A.; Processamento Digital de Imagens. In: Escola Brasileiro-Argentina de Informática, 4. Termas de Rio Hondo: Argentina, 1989. **Tutorial**.
- 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. **Implementação de um sistema contextual de classificação de imagens orbitais compatível com o sistema SITIM**. Campina Grande. 100 p. Dissertação (Mestrado em Engenharia Elétrica). Universidade Federal da Paraíba, 1992.
- Moraes, R. M. Image classification using Mathematical Morphology. In: Simpósio Brasileiro de Computação Gráfica e Processamento de Imagens, 9, Caxambu: 1996. **Anais** p. 357-358.
- Mustavi, M. T.; Chan, K. H.; Hummels, D. M. and Kalantri, K. On the Generalization Ability of Neural Network Classifiers. **IEEE Trans. on Patt. Anal. and Mach. Intel.** v. 16, p. 659-663, 1994.
- Projeto RADAMBRASIL; **Amazônia Legal** [s.l.]: Ministério das Minas e Energia, 1983. (mapa color: 144,5 cm x 117,5 cm. Escala 1:2.500.000).

- Queiroz, G. A. F.; Tozzi, C. L.; Langone, F Avaliação morfológica e morfométrica de axônios mielínicos utilizando classificador *fuzzy*. In: Simpósio Brasileiro de Computação Gráfica e Processamento de Imagens, 10, Campos do Jordão: 1997. **Anais**. No prelo.
- 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.
- Rudorff, B.F.T.; Palme, U.W.; Duarte, V.; Krug, T.; Tardin, A.T.; Batista, G.T.; Medeiros, J.S.; Godoy Jr., M. **Sensoriamento Remoto na Detecção de áreas plantadas e perdas na produção agrícola no município de Irecê - BA**. São José dos Campos: INPE, 1986. 78 p. (INPE - 3877-RPI/156).
- Saebo, H.V.; Braten, K.; Hjort, N.L.; Llewellyn, B.; Mohn, E.; **Contextual Classification of Remotly Sensed Data : Statistical Methods and Development of a System**. Oslo: Norwegian Computing Center, 1985 (Report n.768).
- Sandri, S.; Banon, G.J.F.; Moraes, R. M.; Candeias, A. L. B. Concepção de uma arquitetura de sistemas especialistas nebulosos para classificação de imagens. In: Simpósio Brasileiro de Automação Inteligente, 2, 1996. **Anais**. São Paulo: Sociedade Brasileira de Automática, 1996, p. 441-446.
- Sandri, S. Introdução à lógica "fuzzy". In: Simpósio Brasileiro de Automação Inteligente, 3, Vitória: 1997. **Tutorial**. São Paulo: Sociedade Brasileira de Automática, 1997.
- Senne, E. L. F. **Motor de Inferência para Sistemas Especialistas**. São José dos Campos, 176 p. (INPE-4465-TDL/321). Tese (Doutorado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, 1988.
- Serra, J. **Image Analysis and Mathematical Morphology**. Londres: Academic, 1982.

- Simpson, P. K. **Artificial Neural Systems**. New York: Pergamon Press, 1990.
- Swain, P.H. and Davis, S.M. **Remote Sensing - The Quantitative Approach**. New York: Mc-Graw Hill, 1978.
- Tucker, C. J.; A comparison of satellite sensor bands for vegetation monitoring. **Photogram. Engin. and Rem. Sens.**, v. 44, 1978.
- Vincent, L. **Algorithmes morphologiques a base de files d'attente et de lacets. Extension aux graphes**. Paris. Tese (Doutorado em Morfologia Matemática) - L'Ecole Nationale Supérieure des Mines de Paris, 1990.
- 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.
- Young, T. Y. and Fu, K. S. **Handbook of Pattern Recognition and Image Processing**. New York: Academic Press, 1986, 705 p.
- Zadeh, L. A. Fuzzy Sets, **Information and Control**, v. 8, p. 338-353, 1965.
- Zadeh, L. A.; PRUF-A meaning representation language for natural languages. **Int. J. Man-Machine Stud.**, v. 10, p. 395-460, 1978.

A. APÊNDICE - AS BANDAS DO SATÉLITE LANDSAT

Nesse apêndice daremos um pequeno catálogo dos sensores presentes no satélite Landsat TM, cujas imagens foram utilizadas nesse trabalho. Nesse apêndice também podem ser vistas as relações entre a banda e o tipo de atributo favorecido para a análise. Vale ressaltar ainda, que as informações aqui contidas foram extraídas da "homepage" na Internet da Divisão de Geração de Imagens do INPE. O endereço é: <http://www.dgi.inpe.br/html/landsat.htm>.




Fig. A.1: O satélite LANDSAT

TABELA A.1 - CARACTERÍSTICAS DAS BANDAS ESPECTRAIS DO SATÉLITE LANDSAT 5 E SUAS APLICAÇÕES.

Intervalo Bandaespectral (μm)	Principais características e aplicações das bandas TM do satélite LANDSAT-5.
Intervalo 1: (Bandaespectral 0.45 - 0.52)	Apresenta grande penetração em corpos de água, com elevada transparência, permitindo estudos batimétricos. Sofre absorção pela clorofila e pigmentos fotossintéticos auxiliares. Apresenta sensibilidade a plumas de fumaça oriundas de queimadas ou atividade industrial. Pode apresentar atenuação pela atmosfera.
Intervalo 2: (Bandaespectral 0.52 - 0.60)	Apresenta grande sensibilidade presença de sedimentos em suspensão, possibilitando sua análise em termos de quantidade e qualidade. Boa penetração em corpos de água.
Intervalo 3: (Bandaespectral 0.63 - 0.69)	A vegetação verde, densa e uniforme, apresenta grande absorção, ficando escura, permitindo bom contraste entre as áreas ocupadas com vegetação (ex.: solo exposto, estradas e áreas urbanas). Apresenta bom contraste entre diferentes tipos de cobertura vegetal (ex.: campo, cerrado e floresta). Permite o mapeamento da drenagem através da visualização da mata e entalhe dos cursos dos rios em regiões com pouca cobertura vegetal. É a banda mais utilizada para delimitar a mancha urbana, incluindo identificação de novos loteamentos. Permite a identificação de áreas agrícolas.
Intervalo 4: (Bandaespectral 0.76 - 0.90)	Corpos de água absorvem muita energia nesta banda e ficam escuros, permitindo o mapeamento da rede de drenagem e delineamento de cor- (continua)

TABELA A.1 - conclusão.

Intervalo Bandaespectral (μm)	Principais características e aplicações das bandas TM do satélite LANDSAT-5.
Intervalo 4: (Bandaespectral 0.76 - 0.90)	pos d'água. A vegetação verde, densa e uniforme reflete muita energia nesta banda, aparecendo bem clara nas imagens. Apresenta sensibilidade à rugosidade da copa das florestas e também à morfologia do terreno, permitindo obter informações sobre Geomorfologia, Solos e Geologia. Serve para a análise e mapeamento de feições geológicas e estruturais e para mapear áreas ocupadas com vegetação ou que foram queimadas. Permite a identificação de áreas agrícolas.
Intervalo 5: (Bandaespectral 1.55 - 1.75)	Apresenta sensibilidade ao teor de umidade das plantas, servindo para observar estresse na vegetação causado por desequilíbrio hídrico. Esta banda sofre perturbações em caso de ocorrer excesso de chuva antes da obtenção da cena pelo satélite.
Intervalo 6: (Bandaespectral 10.4 - 12.5)	Apresenta sensibilidade aos fenômenos relativos aos contrastes térmicos, servindo para detectar propriedades termais de rochas, solos, vegetação e água.
Intervalo 7: (Bandaespectral 2.08 - 2.35)	Apresenta sensibilidade à morfologia do terreno permitindo obter informações sobre Geomorfologia, Solos e Geologia. Esta banda serve para identificar minerais com íons hidroxilas. Potencialmente favorável a discriminação de produtos de alteração hidrotermal.

O sensor TM do satélite LANDSAT possui sete bandas, com numeração de 1 a 7, sendo que cada banda representa uma faixa do espectro eletromagnético captada pelo satélite. O satélite LANDSAT apresenta a característica de repetitividade, isto é, observa a mesma área a cada 16 dias. Uma imagem inteira do satélite representa no solo uma área de abrangência de 185 x 185 km. Para o quadrante - um quarto da imagem - a abrangência de 92 x 92 km. A resolução geométrica das imagens nas bandas 1, 2, 3, 4, 5 e 7 de 30 m (isto é, cada "pixel" da imagem representa uma área no terreno de 0,09 ha). Para a banda 6, a resolução é de 120 m (cada "pixel" representa 1,4 ha).

O mapeamento temático a partir de cada uma dessas bandas depende ainda das características da área em estudo (região plana ou acidentada); época do ano (inverno ou verão), iluminação, etc. Os trabalhos de interpretação das imagens tornam-se mais fáceis quando o fotointérprete tem conhecimento de campo.

Características orbitais do satélite LANDSAT:

Altitude = 705 km


Velocidade = 7,7 km/seg

Peso = 2 ton.


Tempo de obtenção de uma cena = 24 seg.

B. APÊNDICE - AS IMAGENS UTILIZADAS


As imagens foram tomadas pelos sensores do satélite Landsat TM em 7 de agosto de 1995, através das bandas 3, 4, 5 e 7. Elas contém a cidade de Aveiro e uma extensa área que denota a presença humana na área. Além da floresta nacional, está presente na imagem uma pequena área na margem oposta do rio. A figura abaixo mostra cada uma das bandas dessa imagem.




Banda 3 do Landsat TM



Banda 4 do Landsat TM



Banda 5 do Landsat TM



Banda 7 do Landsat TM