

### 3 Metodologia de Classificação

Este capítulo descreve o método de classificação proposto no presente trabalho. O procedimento de classificação baseia-se na combinação de informações relativas a duas datas distintas, com o uso de Redes de Markov Nebulosas (do inglês, *Fuzzy Markov Chains*). São propostos diferentes tipos de ajuste de conhecimento temporal, e de classificação baseada neste conhecimento.

#### 3.1. Descrição geral do modelo

O modelo proposto considera dados referentes a diversos instantes de tempo. Na descrição do modelo, será adotada a seguinte representação:  $t$  denota o instante de aquisição da imagem a ser interpretada,  $t-\Delta t$  um instante anterior e  $t+\Delta t$  um instante posterior, onde  $\Delta t$  representa o intervalo de tempo transcorrido entre  $t-\Delta t$  e  $t$ , e também entre  $t$  e  $t+\Delta t$ .

O procedimento de classificação proposto está baseado na classificação de objetos, ou segmentos. Conforme mencionado na seção 2.1, a classificação por segmentos apresenta vantagens quando comparada à classificação por pixels, no que concerne à representação do conhecimento em termos de atributos, como forma e textura. Os objetos são formados a partir da subdivisão da imagem original em segmentos, que são regiões homogêneas de acordo com determinado atributo de imagem. Portanto, a etapa inicial do procedimento proposto é a segmentação das imagens, de acordo com o atributo de aparência espectral.

O método proposto explora, além da própria imagem a ser classificada obtida no instante  $t$ , a informação contida numa imagem produzida pelo mesmo sensor da mesma área geográfica numa data anterior. O conhecimento do fotointérprete quanto à relação temporal entre estes dois conjuntos de dados será modelado seguindo o método descrito nas seções subseqüentes.

A Figura 1 apresenta a estrutura geral do modelo proposto.

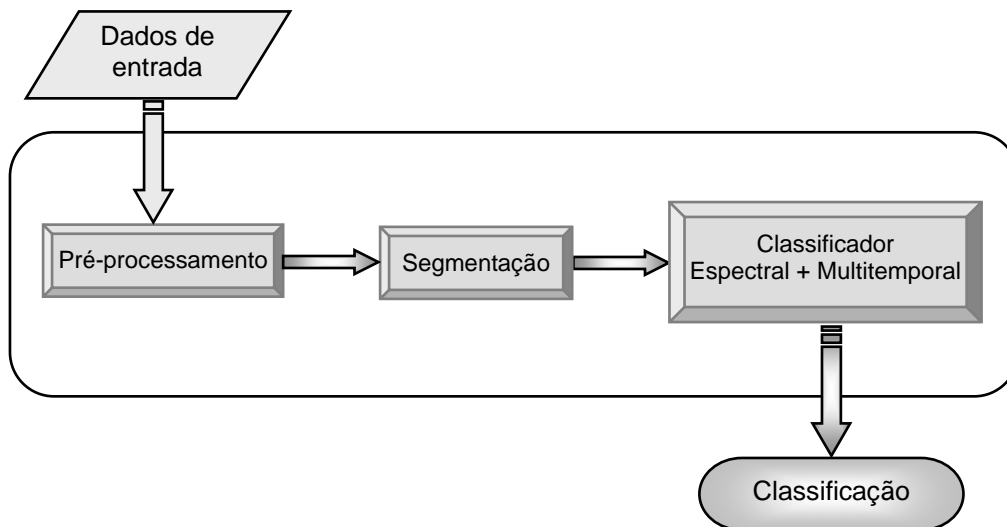


Figura 1– Esquema geral do modelo de classificação.

O principal objetivo do procedimento de classificação proposto é a reprodução do raciocínio multitemporal empregado pelo foto-intérprete ao interpretar a imagem.

### 3.2. Pré-processamento dos dados

Ao se trabalhar com a comparação entre diferentes imagens obtidas em diferentes sensores é necessário fazer algum tipo de correção de maneira a referenciá-las umas às outras, em termos radiométricos e espaciais.

No primeiro caso, é necessário corrigir a variação na intensidade dos pixels, que não é causada pelo objeto ou cena contido na imagem, mas sim por diferenças de iluminação, efeitos atmosféricos e tipos ou calibração de sensores.

No segundo caso, as imagens devem ser geo-referenciadas em uma mesma escala e projeção – no caso do presente trabalho *UTM (Universal Transverse Mercator)* – e um mesmo *datum* – que define origem e orientação do sistema de coordenadas *UTM*, além de sofrer correção de erros gerados por causa da curvatura da Terra e da mobilidade do sensor.

No caso de métodos de classificação supervisionados, como o do modelo utilizado neste trabalho, isto é resolvido, porque as assinaturas espectrais são estimadas a partir de amostras adquiridas por um foto-intérprete, na própria imagem a ser classificada. Por isto, o método de correção radiométrica não é utilizado no presente estudo, já que seus efeitos não modificariam o resultado final dos experimentos.

A seguir é apresentada a descrição apenas da técnica de correção espacial – também chamada correção geométrica.

### **3.2.1 Correção geométrica**

De acordo com Heipke, (2004), a correção geométrica é muito importante na utilização conjunta de mais de uma imagem, já que o referenciamento diferente entre duas imagens pode gerar erros de posição muito grandes, principalmente ao se considerar imagens de média resolução em que um pixel representa 30m de distância.

É imprescindível, nestes casos, que a projeção e o *datum* das imagens seja o mesmo, o que é obtido com o geo-referenciamento. Além disto, deve se utilizar o método de orto-retificação que corrige erros relativos ao terreno, que podem ser causados pela forma geométrica da Terra ou pelo sensor de aquisição das imagens. Neste método é utilizado um Modelo Digital de Terreno (MDT), que é uma representação matemática da distribuição espacial de variação de altitude em uma área, construído a partir de curvas de nível e de medidas altimétricas.

No presente trabalho, a orto-retificação é feita em conjunto com o método de registro. Este método é empregado para referenciar as grades de pixels de uma imagem em relação à outra. No caso de um conjunto de imagens, deve-se escolher uma delas como referência, e então fazer o registro de cada uma das outras em relação a esta escolhida. A correção é realizada a partir da comparação entre alguns pontos de controle (escolhidos arbitrariamente) e seu posicionamento nas imagens e no mapa (MDT), computando as distorções presentes e estimando uma transformação polinomial adequada para corrigir todos os pontos da imagem em relação à referência e ao MDT.

Uma descrição detalhada dos métodos de correção geométrica foge ao escopo deste trabalho, e pode ser encontrada em Lillesend (1999).

### **3.3. Segmentação**

Conforme descrito na seção 3.1, este trabalho se baseia na classificação por objetos, ou segmentos.

Podem ser encontrados diversos métodos de segmentação na literatura, (Cocquerez, 1995; Gonzalez, 1993; Jähne 1991; Sonka, 1999; Vincent, 1991). Dentre eles, alguns muito utilizados são os baseados em textura, em limiares (*Thresholding*) e na similaridade espectral. O método baseado no crescimento de regiões (*Region Growing*) e o método por divisão e fusão (*Region Splitting e Merging*) merecem destaque. Um método recentemente utilizado é o *watersheds* (divisor de águas), que considera a imagem em tons de cinza como uma superfície topográfica, cuja terceira dimensão é a intensidade do pixel, e faz uma analogia do processo de segmentação com a inundação desta superfície.

O processo de segmentação, neste trabalho, utilizou o aplicativo *eCognition* – *Copyright Definiens Imaging 2004* – e foi realizado simultaneamente para todas as imagens em conjunto com seus respectivos mapas temáticos. Desta forma, cada objeto de uma imagem tem, necessariamente, um objeto correspondente em cada uma das outras imagens. Além disso, todos os objetos correspondentes entre si são áreas homogêneas em suas respectivas imagens. Este procedimento é necessário para viabilizar a análise multitemporal das imagens deste trabalho.

Os mapas temáticos foram produzidos manualmente em um certo fator de escala, que determina uma relação entre as dimensões dos elementos representados no mapa e as correspondentes dimensões reais. Sendo assim, em escalas maiores que a utilizada nos mapas, as delimitações das regiões destes poderão apresentar algum deslocamento dos limites reais. Em algumas regiões, podem ser encontradas imprecisões intoleráveis, como mostra a Figura 2.




Figura 2 – Imagem Landsat, em grande escala, com as respectivas subdivisões do mapa temático com problema de imprecisão.

Com isto, os objetos que pertencem às regiões de borda dos polígonos dos mapas temáticos apresentam classificações de referência não confiáveis. Por esta razão, estes objetos foram desconsiderados no presente trabalho, já que para avaliar um sistema automático é indispensável o uso de dados de referência confiáveis. Ainda assim, o número de objetos restantes utilizados foi suficiente para construir e avaliar o sistema.

### **3.4. Modelo de Classificação**

O método de classificação multitemporal proposto basicamente combina o resultado de duas classificações monotemporais. Estas podem ser produzidas não só a partir de atributos espectrais como também de atributos espaciais, que expressam características geométricas entre os objetos da imagem e a distribuição espacial entre eles. Contudo, já que o objetivo central deste trabalho é avaliar a contribuição do conhecimento multitemporal na acurácia da classificação, daqui em diante considera-se apenas atributos espectrais para descrever cada objeto numa data particular. Assim o termo “espectral” será utilizado neste texto para designar a informação monotemporal, enquanto o termo “temporal” será

empregado para referência à relação entre conjuntos de dados monotemporais de duas datas distintas.

O modelo proposto utiliza conceitos da Teoria dos Conjuntos Nebulosos (Zadeh, 1965) para a representação das diferentes modalidades de conhecimento. Esta escolha se deve à simplicidade de implementação e à capacidade de representar o conhecimento de especialistas humanos, que é, via de regra, subjetivo, vago, qualitativamente incompleto e impreciso.

No presente trabalho, o problema de classificação pode ser formulado da seguinte maneira.

Sejam  $\mathbf{I}_t$  e  $\mathbf{I}_{t-\Delta t}$  duas imagens de uma mesma área geográfica obtidas respectivamente nos instantes  $t$  e  $t-\Delta t$ . Denota-se com o símbolo  $\Omega = \{\omega_1, \dots, \omega_n\}$  o conjunto das  $n$  classes da legenda. A tarefa do classificador multitemporal consiste em produzir a classificação precisa (*crisp*)  $\mathbf{C}_t$  de cada um dos objetos da imagem  $\mathbf{I}_t$ , baseando-se nos atributos do objeto em ambas as datas.

O modelo de classificação proposto divide o conhecimento em duas modalidades, segundo as quais são efetuadas as classificações: espectral e temporal, conforme ilustra a Figura 3.

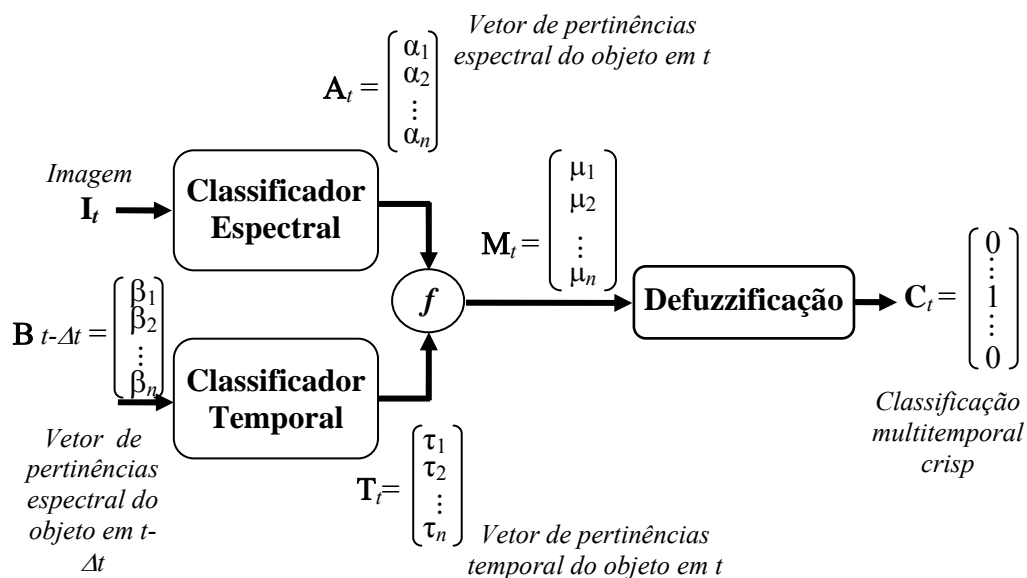


Figura 3 – Esquema geral do classificador multitemporal.

Um classificador espectral produz para cada objeto da imagem  $\mathbf{I}_t$  um vetor  $\mathbf{A}_t = \{\alpha_1, \dots, \alpha_n\}$ , contendo as pertinências a cada uma das classes da legenda. O

vetor de pertinência do mesmo objeto no instante anterior  $t-\Delta t$  é denotado por  $\mathbf{B}_{t-\Delta t} = \{\beta_1, \dots, \beta_n\}$ . Cabe notar aqui que  $\mathbf{B}_{t-\Delta t}$  terá sido produzido por um classificador espectral do mesmo tipo aplicado à imagem  $\mathbf{I}_{t-\Delta t}$ .

Um classificador temporal produz um vetor  $\mathbf{T}_t = \{\tau_1, \dots, \tau_n\}$ , que expressa as pertinências do objeto no instante  $t$  a partir da classificação  $\mathbf{B}_{t-\Delta t}$  do instante anterior. As duas classificações relativas ao instante  $t$  são combinadas por uma função  $f$  que faz a fusão dos resultados  $\mathbf{A}_t$  e  $\mathbf{T}_t$  produzindo o vetor de pertinência  $\mathbf{M}_t = \{\mu_1, \dots, \mu_n\}$ . O resultado final da classificação é obtido aplicando-se um defuzzificador, que atribui o objeto à classe  $\omega_i$ , para a qual  $\mu_i > \mu_j$  para todo  $i, j = 1, \dots, n$ , e  $i \neq j$ .

Nas seções seguintes é feita a descrição, em detalhe, de cada uma das etapas do classificador proposto.

### 3.4.1 Classificação espectral

Como mencionado na seção anterior, há diversos tipos de atributos que podem ser utilizados na classificação de imagens, tais como textura, resposta espectral ou atributos espaciais. Como o objetivo deste trabalho é avaliar a contribuição do classificador temporal proposto para o desempenho da classificação, escolheu-se um classificador que só utiliza resposta espectral, pela simplicidade de implementação.

Vários classificadores espectrais poderiam ser aqui aplicados em combinação com o modelo temporal proposto, porém, também em benefício da simplicidade, utilizou-se um método similar ao classificador de máxima probabilidade, um dos mais comumente empregados.

O classificador espectral aplicado neste trabalho corresponde ao procedimento semi-supervisionado descrito em Mota (2004), de aquisição automática do conhecimento espectral. Este procedimento emprega a seleção automática de amostras, com base exclusivamente nas imagens  $\mathbf{I}_t$  e  $\mathbf{I}_{t-\Delta t}$  e na classificação *crisp*  $\mathbf{C}_{t-\Delta t}$  da imagem anterior em  $t-\Delta t$ .

Um método de detecção automática de mudança indica os objetos produzidos pela segmentação que pertencem a uma mesma classe (inalterados) e

os que pertencem a duas classes diferentes nos instantes  $t-\Delta t$  e  $t$  (alterados). O classificador utiliza os segmentos inalterados como conjunto de treinamento para estimar as assinaturas espectrais das classes de interesse.

Com os conjuntos de treinamento assim formados, estimam-se a média  $m_i$  e a matriz de covariância  $\Sigma_i$ , para cada classe  $\omega_i$ . Admite-se que cada classe pode ser adequadamente modelada por uma distribuição Normal  $N(m_i, \Sigma_i)$ . Utiliza-se uma propriedade deste tipo de distribuição, segundo a qual a distância de Mahalanobis ao centróide de uma população com distribuição  $N(m_i, \Sigma_i)$  é uma variável aleatória com distribuição Chi-quadrado com  $p$  graus de liberdade, onde  $p$  é a dimensão do espaço de atributos. Daí decorre que a probabilidade de que um padrão  $x$  pertencente à população  $\omega_i$  esteja a uma distância

$$(x - m_i)^T \Sigma_i^{-1} (x - m_i) \leq \chi_p^2(\gamma) \quad \text{Equação (1)}$$

do centróide é igual a  $(1-\gamma)$  onde,  $\chi_p^2(\gamma)$  é o percentil  $(100\gamma)$  da função Chi-quadrado com  $p$  graus de liberdade (Duda, 2001).

Assim, o classificador espectral atribui grau de pertinência do padrão  $x$  à classe  $\omega_i$  o valor de  $\gamma$  que satisfaz a equação (2) :

$$(x - m_i)^T \Sigma_i^{-1} (x - m_i) = \chi_p^2(\gamma) \quad \text{Equação (2)}$$

O resultado obtido com este procedimento é o conjunto  $\mathbf{A}_t = [\alpha_1, \dots, \alpha_n]^T$  em que  $\alpha_i$  é a pertinência espectral do objeto à classe  $\omega_i$ , para  $i=1,2,\dots,n$ . Cada pertinência  $\alpha_i$  é um valor real no intervalo  $[0,1]$ , e para pelo menos um  $i$ ,  $\alpha_i \neq 0$ .

Como já foi dito na seção anterior, este mesmo classificador pode ser utilizado para produzir o conjunto de pertinências  $\mathbf{B}_{t-\Delta t}$ , quando aplicado à imagem  $\mathbf{I}_{t-\Delta t}$ , no caso da classificação multitemporal que utiliza como informação prévia as pertinências de cada classe.



### 3.4.2 Classificação multitemporal

Neste trabalho o conhecimento multitemporal diz respeito à possibilidade de um objeto pertencer a uma determinada classe num instante  $t$ , considerando a informação da classe à qual o objeto pertencia num instante anterior  $t-\Delta t$  (ou posterior  $t+\Delta t$ ).

A representação deste conhecimento pode ser feita através do diagrama de transições de classes. Um diagrama de transição de classes pode ser definido como um grafo, em que cada nó representa uma classe da legenda, e os arcos as possíveis transições. A Figura 4 apresenta um exemplo de diagrama de transição de classes.




Figura 4 – Exemplo de Diagrama de Transição de Classes.

A cada transição, conforme proposto em Mota (2004), é atribuído um valor  $p_{ij} \in [0,1]$ , que denota a possibilidade de que um segmento pertencente à classe  $\omega_i$  num dado determinado instante  $t-\Delta t$  passe a pertencer à classe  $\omega_j$  no instante posterior  $t$ , sendo  $i, j = 1, \dots, n$ , e  $n$  o número de classes da legenda.

O conhecimento multitemporal pode ser representado por uma matriz  $\mathbf{P} = \{p_{ij}\}$ ,  $n \times n$ , de possibilidades de transição de classes (MPT), em que cada linha  $i$  indica o conjunto de possibilidades de transição da classe  $\omega_i$  no instante  $t-\Delta t$  para cada classe  $\omega_j$  – correspondente a cada coluna  $j$  – no instante posterior  $t$ .

A Figura 5 mostra a forma da MPT.

$$\mathbf{P} = \begin{pmatrix} p_{11} & p_{12} & \dots & p_{1n} \\ p_{21} & p_{22} & \dots & p_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ p_{n1} & p_{n2} & \dots & p_{nn} \end{pmatrix}$$

Figura 5 – Matriz de Possibilidades de Transição de Classes.

Vale observar que, se  $\mathbf{P}$  é a MPT relativa à imagem de  $\mathbf{I}_{t-\Delta t}$  para a imagem  $\mathbf{I}_t$ , então  $\mathbf{P}^T$  – a transposta de  $\mathbf{P}$  – representa a MPT no sentido inverso do tempo, ou seja, de  $\mathbf{I}_t$  para  $\mathbf{I}_{t-\Delta t}$ . Esta propriedade será explorada mais adiante na seção 3.5, que trata das estimativas das possibilidades de transição.

A modelagem deste conhecimento no classificador proposto utiliza o conceito de Redes de Markov Nebulosas (RMN), conforme apresentado em Avrachenkov (2002).

Um sistema baseado em RMN pode ser entendido como um conjunto de estados que a cada instante de tempo troca o estado corrente de acordo com a lei de transição da RMN, dada por uma relação fuzzy que depende do estado anterior e das possibilidades (nebulosas) de transição associadas a ele. Cada estado corresponde a um evento observado no sistema. No caso do presente trabalho, cada estado corresponde a uma classe.

O classificador temporal calcula as pertinências de cada objeto da imagem, conforme a descrição a seguir. Dado o vetor de pertinências  $\mathbf{B}_{t-\Delta t} = [\beta_{t-\Delta t,1}, \beta_{t-\Delta t,2}, \dots, \beta_{t-\Delta t,n}]^T$  do objeto no instante  $t-\Delta t$ , o classificador temporal calcula o vetor de pertinências  $\mathbf{T}_t$  segundo a fórmula

$$\mathbf{T}_t = \mathbf{B}_{t-\Delta t} * \mathbf{P} = [\tau_1, \tau_2, \dots, \tau_n]^T, \quad \text{Equação (3)}$$

onde o operador  $*$  corresponde ao máximo dos produtos. Ou seja,  $\mathbf{T}_t = \{\tau_k\}$ , onde

$$\tau_k = \max(\beta_1 \times p_{1k}, \beta_2 \times p_{2k}, \dots, \beta_n \times p_{nk}) \quad \text{Equação (4)}$$

com  $k = 1, 2, \dots, n$ , sendo  $n$  o número de classes da legenda.

Estimar o valor destas possibilidades é difícil mesmo para um especialista com grande conhecimento do sítio alvo.

Na estimativa da MPT atribui-se às transições impossíveis – definidas pelo especialista – possibilidade nula. Sendo assim, as ligações correspondentes a estas transições são suprimidas no diagrama. Por exemplo, na Figura 4, objetos da classe  $\omega_l$  não trocam jamais de classe. O especialista também pode apontar para cada classe a transição mais provável. Nas aplicações de classificação de imagens de sensores remotos o mais provável, em geral, é não ocorrer mudança na classe. Portanto, os valores  $p_{ii}$  da diagonal principal são os valores máximos de cada linha e coluna da MPT. Assim, atribui-se valor “1” para a possibilidade da transição mais provável.

Os valores de possibilidade restantes para formar a MPT são estimados no presente trabalho, de maneira automática, utilizando algoritmos genéticos (Holland, 1975), treinados a partir de imagens de datas diferentes da imagem analisada, conforme descrito na seção 3.5.1.

### 3.4.3 Fusão do conhecimento espectral e multitemporal

Após as etapas de classificação espectral e temporal, o classificador proposto realiza a fusão de ambos os resultados.

Isto é feito com uma operação de agregação *fuzzy* (Klir 1995), que combina os vetores de pertinências nebulosas  $\mathbf{A}_t$  e  $\mathbf{T}_t$ , resultando no vetor  $\mathbf{M}_t = [\mu_1, \mu_2, \dots, \mu_n]^T$ , de pertinências.

A função média geométrica foi adotada como função de agregação neste trabalho. Logo, o vetor de pertinências resultante da agregação das classificações espectral e temporal é:

$$\mathbf{M}_t = f(\mathbf{A}_t, \mathbf{T}_t) = [(\alpha_1 \tau_1)^{1/2}, (\alpha_1 \tau_2)^{1/2}, \dots, (\alpha_n \tau_n)^{1/2}]^T \quad \text{Equação (5)}$$

### 3.4.4 Regra de decisão

A etapa final do classificador proposto é a inferência que transforma o vetor  $\mathbf{M}_t$  no vetor  $\mathbf{C}_t$  de pertinências *crisp*, conforme apresentado na Figura 3. Esta operação é chamada *defuzzificação*, e, neste trabalho, atribui o objeto à classe  $\omega_i$  para a qual  $\mu_i$  é máximo. Logo, o vetor  $\mathbf{C}_t$  será dado pela Equação (6):

$$\mathbf{C}_t = (c_{t,1}, \dots, c_{t,n})^T \quad \text{onde} \quad \begin{cases} c_{t,i} = 1, & \text{caso } \mu_i = \max_j \{\mu_j\} \\ c_{t,i} = 0, & \text{caso contrário} \end{cases} \quad \text{Equação (6)}$$

Cabe realçar que, devido à função de *defuzzificação* utilizada, a média geométrica poderia ser substituída pelo produto, sem alterar o resultado final da classificação, já que a raiz quadrada não altera a ordem dos valores.

## 3.5. Estimativa dos parâmetros do modelo

Este trabalho investiga diferentes maneiras de estimativa dos parâmetros do modelo temporal. A seguir são apresentados o método utilizado e os três tipos de métodos de estimativa analisados.

### 3.5.1 Estimativa com Algoritmos Genéticos

Conforme já dito anteriormente, neste trabalho a estimativa dos valores de cada elemento da MPT é feita empregando algoritmos genéticos (AG).

Os AGs são modelos computacionais inspirados pela teoria da evolução, usualmente empregados em problemas de otimização complexos, principalmente quando estes envolvem um grande número de variáveis que acarretam um espaço de busca de solução de dimensão elevada. Estes modelos simulam os mecanismos de seleção natural, reprodução e mutação, encontrados na natureza. A representação de cada solução possível do problema é feita com uma cadeia de

símbolos, chamada cromossomo, que denota um indivíduo da população formada por todas as soluções possíveis.

Neste trabalho o cromossomo é definido por uma cadeia de números reais, representando as possibilidades de transição de classes. Assim, cada posição (gene) do cromossomo representa um  $p_{ij}$  a ser estimado. A população inicial é gerada aleatoriamente, de acordo com limites estabelecidos, neste caso, o intervalo  $[0,1]$ .

A reprodução dos indivíduos, que dá origem à nova geração, é feita por operadores genéticos. No caso deste trabalho é realizada a troca parcial da população, que substitui os  $M$  piores indivíduos, onde  $M$  é um valor arbitrário menor que o tamanho da população. Esta técnica garante que a geração seguinte tenha, no mínimo, soluções tão aptas quanto a atual.

A seleção é feita a partir de uma função objetivo, que avalia a aptidão de cada indivíduo. Foi adotado, como função objetivo, o indicador *taxa de reconhecimento* descrito em Jensen (1996), que é o percentual dos segmentos de cada classe corretamente classificados pelo modelo de acordo com a classe de referência. Poder-se-ia utilizar a taxa de reconhecimento global de objetos, ou qualquer outra medida de desempenho. Foi escolhida a taxa média de reconhecimento  $T_R$  por classe. Esta taxa é definida na Equação (7).

$$T_R = \frac{\sum_{k=1}^n \Gamma_k}{n} \quad \text{Equação (7)}$$

onde  $n$  é o número de classes da legenda e  $\Gamma_k$  é a taxa de reconhecimento da classe  $\omega_k$  definida pela Equação (8).

$$\Gamma_k = \frac{H_k}{n_k} \quad \text{Equação (8)}$$

onde  $H_k$  é o número de objetos atribuídos corretamente à classe  $\omega_k$  pelo procedimento de classificação automático e  $n_k$  é o número real de objetos pertencentes à classe  $\omega_k$ .

A solução final é constituída dos indivíduos que produzem o melhor valor de avaliação, neste caso, a maior taxa de reconhecimento.

### 3.5.2 Ajuste *Forward*

A estimativa da MPT com ajuste *forward* segue a descrição das seções anteriores, em que se utiliza como entrada do classificador proposto:

- uma imagem  $I_{t'}$  do mesmo sensor e da mesma área geográfica e adquirida num instante  $t'$ ,
- a correspondente classificação  $C_{v_{t'}}$  de referência, conhecida *a priori*, e
- o vetor de pertinências espectral  $B_{t'-\Delta t}$  dos objetos às classes da legenda no instante  $t'-\Delta t$ .

A Figura 6 ilustra o modelo empregado neste tipo de estimativa.

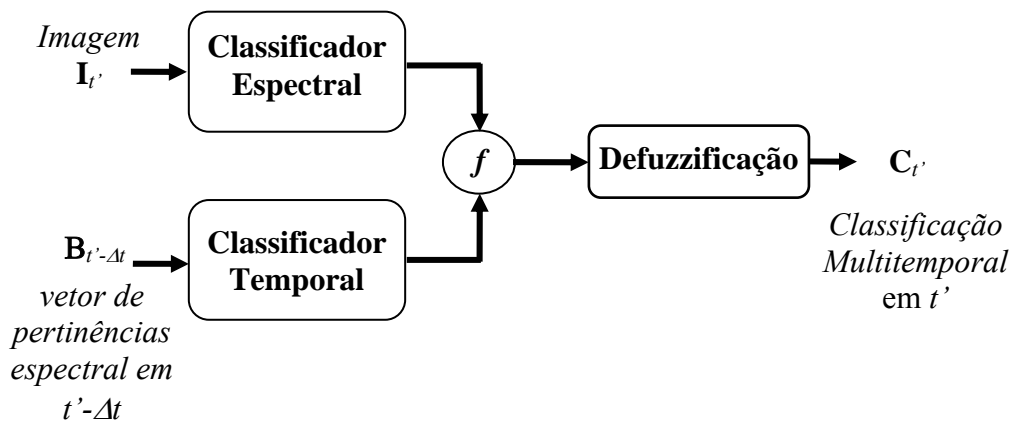


Figura 6 – Esquema do ajuste *forward*.

A classificação  $C_{v_{t'}}$  da imagem no instante  $t'$  é utilizada aqui como referência para se avaliar a acurácia da classificação  $C_{t'}$  produzida pelo classificador multitemporal. Este ajuste do conhecimento temporal é feito de modo a maximizar alguma medida de desempenho do classificador, calculada a partir de  $C_{v_{t'}}$  e  $C_{t'}$ . Conforme dito na seção 3.5.1, a medida aqui utilizada é a *taxa de reconhecimento*.

### 3.5.3 Ajuste *Backward*

O classificador *backward* é análogo ao *forward*, com a diferença de que o sentido do tempo é inverso, ou seja, para trás. Ele se baseia na observação apresentada na seção 3.4.2, de que, se  $\mathbf{P}$  é a matriz de transição de classes que descreve as transições do instante  $t'-\Delta t$  para o instante  $t'$ , então a matriz  $\mathbf{P}^T$  descreve as transições no sentido inverso, isto é, do instante  $t'$  para o instante  $t'-\Delta t$ .

Na maioria dos casos práticos, o vetor de pertinências espectral  $\mathbf{B}_{t'-\Delta t}$  utilizado no método *forward* é obtido pela aplicação sobre a imagem  $\mathbf{I}_{t'-\Delta t}$  do mesmo procedimento de classificação que produz o vetor de pertinências espectrais  $\mathbf{A}_{t'}$  a partir da imagem  $\mathbf{I}_{t'}$ . Resultam, neste caso, as seguintes conclusões:

- a) se  $\mathbf{B}_{t'-\Delta t}$  está disponível, então  $\mathbf{I}_{t'-\Delta t}$  também estará.
- b) pelo mesmo raciocínio  $\mathbf{B}_{t'} = \mathbf{A}_{t'}$ .

Se, além disso, for possível obter um número suficiente de segmentos da imagem  $\mathbf{I}_{t'-\Delta t}$  cuja classificação  $\mathbf{C}_{t'-\Delta t}$  é conhecida *a priori*, será, também possível estimar a MPT invertendo o sentido do tempo.

Baseando-se nisso, o método *backward* de estimativa da MPT utiliza como dados de treinamento:

- a imagem  $\mathbf{I}_{t'-\Delta t}$  relativa ao instante  $t'-\Delta t$ ,
- a correspondente classificação  $\mathbf{C}_{t'-\Delta t}$  no instante  $t'-\Delta t$ ,
- o vetor de pertinências espectral  $\mathbf{B}_{t'}$  relativas ao instante  $t'$ ,

A Figura 7 ilustra o modelo empregado neste tipo de estimativa.

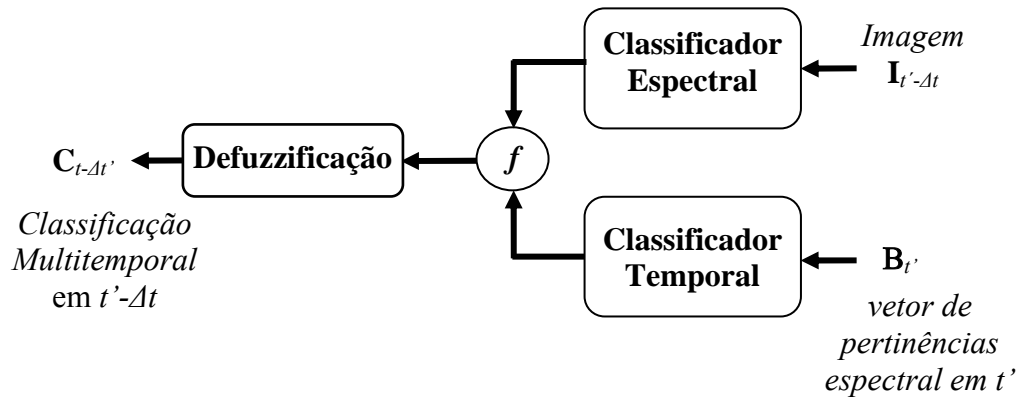


Figura 7 – Esquema do ajuste *backward*.

No método *backward* a estimativa da MPT se dá de modo análogo ao explicado no método *forward*, lembrando que a matriz estimada no caso *backward* é a transposta da matriz estimada no método *forward*.

### 3.5.4 Ajuste *Forward-Backward*

Este classificador agrega os dois tipos anteriores, no que se refere ao ajuste do conhecimento multitemporal. Seus parâmetros de entrada são:

- a imagem  $\mathbf{I}_{t'}$  num instante  $t'$ ,
- a imagem  $\mathbf{I}_{t'-\Delta t}$  num instante  $t'-\Delta t$ ,
- a classificação  $\mathbf{Cv}_{t'}$  (de referência) da imagem no instante  $t'$ ,
- a classificação  $\mathbf{Cv}_{t'-\Delta t}$  (de referência) da imagem no instante  $t'-\Delta t$ ,
- o vetor de pertinências espectral  $\mathbf{B}_{t'}$  do instante  $t'$  e
- o vetor de pertinências espectral  $\mathbf{B}_{t'-\Delta t}$  do instante  $t'-\Delta t$ .

A Figura 8 ilustra o modelo empregado neste tipo de estimativa.



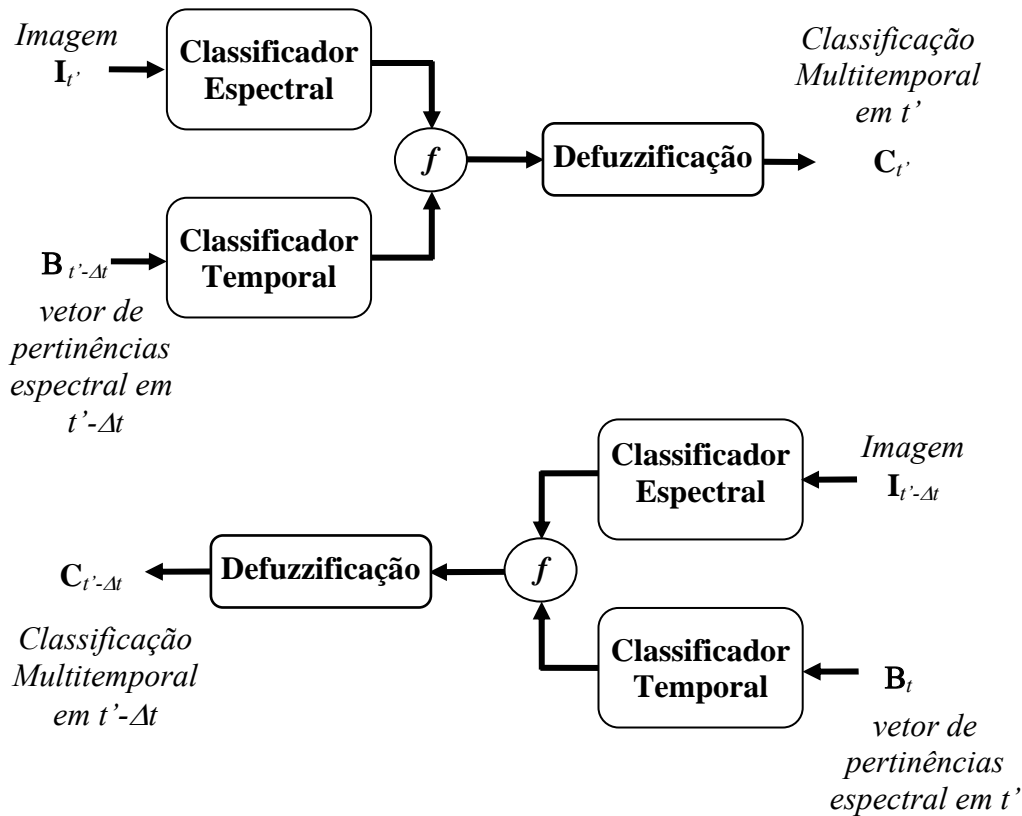


Figura 8 – Esquema do ajuste *forward-backward*.

O ajuste do conhecimento multitemporal é feito através do algoritmo genético, cuja função avaliação é a taxa de reconhecimento média aritmética das classes - Equação (7), no sentido para a frente para o instante  $t'$  utilizando informação temporal do instante  $t'-\Delta t$ , e no sentido inverso para o instante  $t'-\Delta t$  utilizando informação temporal do instante  $t'$ . O procedimento produz os valores da MPT válidos para ambos os sentidos.

O método de estimativa *forward-backward* utiliza mais informação do que os métodos anteriores. Espera-se por isso que aquele seja mais eficiente do que estes, como confirmam os experimentos apresentados no próximo capítulo.

### 3.6. Classificação utilizando vetor de pertinências *crisp*

Este classificador de pertinências *crisp* é um caso particular do classificador generalizado, em que o vetor de pertinências  $\mathbf{B}_{t-\Delta t}$  é substituído pela classificação *crisp*  $\mathbf{C}\mathbf{v}_{t-\Delta t}$  da imagem.

O procedimento de classificação é idêntico ao anteriormente apresentado, diferenciando-se apenas pela utilização da classificação *crisp* da imagem anterior, ao invés da classificação nebulosa.

Este tipo de classificação, utilizando vetor de pertinências *crisp* é idêntico ao apresentado em Campos (2005).

### 3.7. Classificação para intervalos maiores

O modelo de classificação apresentado na seção 3.4 pressupõe um intervalo de tempo fixo,  $\Delta t$ , separando a data da imagem anterior e a data da imagem posterior.

Porém, por diversas razões nem sempre se dispõe de uma série de imagens obtidas a intervalos regulares de tempo. Isto pode ser devido, por exemplo, a nuvens no momento da passagem do satélite sobre o sítio alvo.

Sendo assim, pode ocorrer que se tenha a MPT estimada para um intervalo  $\Delta t$ , mas o intervalo entre a data da imagem a ser classificada e da mais recente imagem disponível da mesma área e sensor ser igual a um múltiplo inteiro  $\lambda\Delta t$  de  $\Delta t$ .

Para tais casos, é desejável poder estimar a MPT para este intervalo  $\lambda\Delta t$  baseando-se na MPT estimada para o intervalo  $\Delta t$ . Este trabalho utiliza uma propriedade das Redes de Markov Nebulosas e propõe um método para estimar a MPT relativa a um intervalo  $\lambda\Delta t$  com  $\lambda$  inteiro a partir de outra MPT relativa a intervalo igual a  $\Delta t$ , conforme descrito a seguir.

Admite-se que a MPT é invariante no tempo, ou seja, depende apenas do intervalo considerado, mas independe das datas das imagens utilizadas, desde que

estas sejam separadas por  $\Delta t$ . Esta é certamente uma hipótese falsa no caso geral, mas para muitos casos práticos reais é uma simplificação aceitável.

A classificação para um intervalo  $\lambda\Delta t$  pode ser vista como a replicação do modelo básico apresentado na seção 3.4,  $\lambda$  vezes. Por exemplo, para  $\lambda=2$ , o classificador toma a forma mostrada na Figura 9.

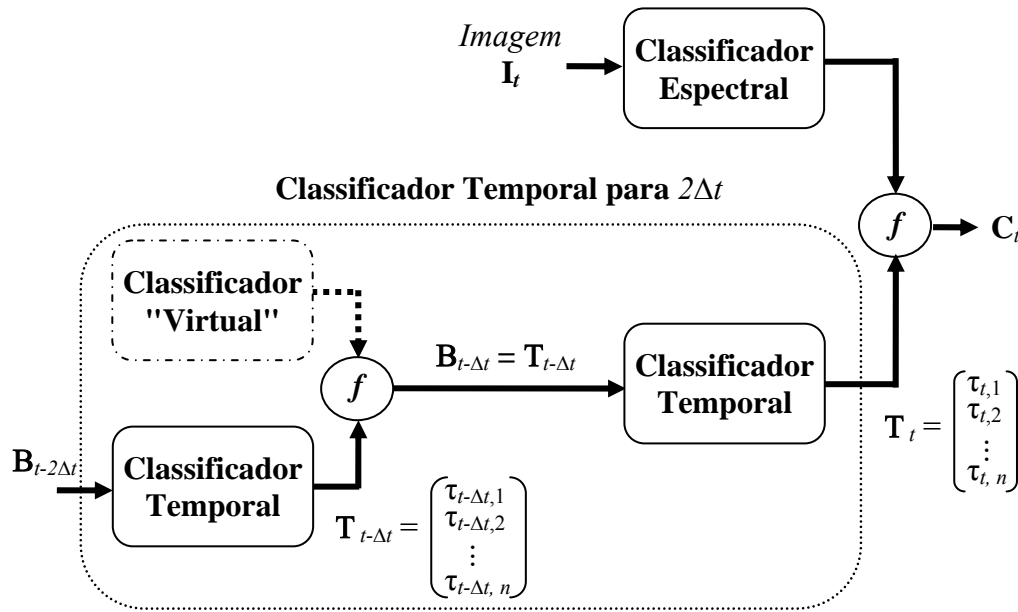


Figura 9 – Exemplo de Modelo de classificação para intervalos maiores.

Neste caso, não se dispõe da imagem  $I_{t-\Delta t}$ , portanto, supõe-se um classificador espectral “virtual”, que repete o resultado do classificador temporal. Sendo assim, admite-se  $M_{t-\Delta t}$  igual a  $T_{t-\Delta t}$ . Seguindo o procedimento apresentado na seção 3.4.2, obtém-se:

$$\mathbf{T}_t = \mathbf{T}_{t-\Delta t} * \mathbf{P} = (\mathbf{B}_{t-2\Delta t} * \mathbf{P}) * \mathbf{P} = \mathbf{B}_{t-2\Delta t} * \mathbf{P}^2. \quad \text{Equação (9)}$$

Generalizando para um múltiplo inteiro  $\lambda$  qualquer, a classificação temporal para um intervalo  $\lambda\Delta t$ , será dada pela equação:

$$\mathbf{T}_t = \mathbf{B}_{t-\lambda\Delta t} * \mathbf{P}^\lambda. \quad \text{Equação (10)}$$

### 3.8. Classificação agregando informação anterior e posterior

O método proposto até aqui explora informação de uma data anterior à da imagem a ser classificada, e podemos, portanto, chamá-lo de *classificação forward*. As mesmas considerações que justificaram o método *backward* para estimativa da MPT permitem concluir que o método de classificação temporal proposto pode ser utilizado explorando informação de uma data posterior (*classificação backward*) à da imagem a ser classificada.

Estando disponíveis tanto uma imagem de uma data anterior quanto de uma data posterior à da imagem a ser classificada, é razoável supor que o uso das três imagens redundará num ganho de desempenho na classificação, em relação aos métodos considerados até aqui que exploram imagens de duas datas apenas.

Esta seção apresenta uma extensão ao modelo proposto que explora tanto informação de uma data anterior quando a de uma data posterior à da imagem a ser classificada.

O método de classificação *forward-backward* consiste em combinar os resultados de um classificador *forward* e de um classificador *backward*.

A agregação de ambas as estimativas é feita com a operação de média geométrica das pertinências obtidas.

Portanto, o vetor de pertinências nebulosas da agregação das classificações espectral e multitemporal é:

$$\mu_i = (\mu_i^{anterior} \times \mu_i^{posterior})^{1/2} \quad \text{Equação (11)}$$

A Figura 10 ilustra a operação deste classificador.

Este esquema *forward-backward* permite explorar mais informação temporal e tem o potencial de apresentar melhor desempenho do que os correspondentes classificadores *forward* ou *backward* individualmente.

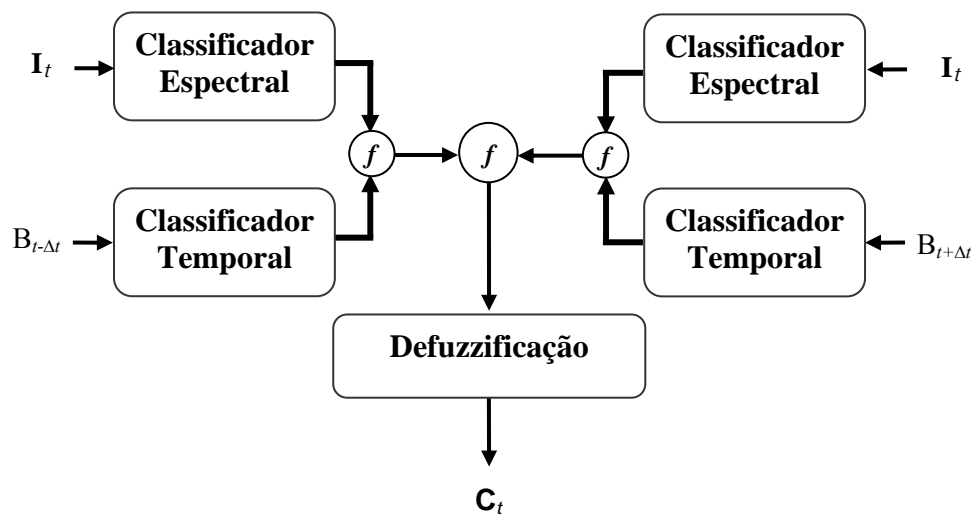


Figura 10 –Modelo de classificação agregando informação anterior e posterior.