

4 Modelo proposto

4.1. Descrição geral do modelo

O modelo proposto considera dados referentes a diversas instâncias de tempo. A partir de agora, t representa o instante no qual foi adquirida a imagem a ser interpretada, $t-1$ um instante anterior e Δt o intervalo de tempo transcorrido entre $t-1$ e t . Por analogia, o intervalo de tempo transcorrido entre $t-2$ e t é igual a $2\Delta t$.

A figura 3 apresenta a estrutura simplificada do modelo proposto para interpretação de imagens de satélite de baixa resolução.

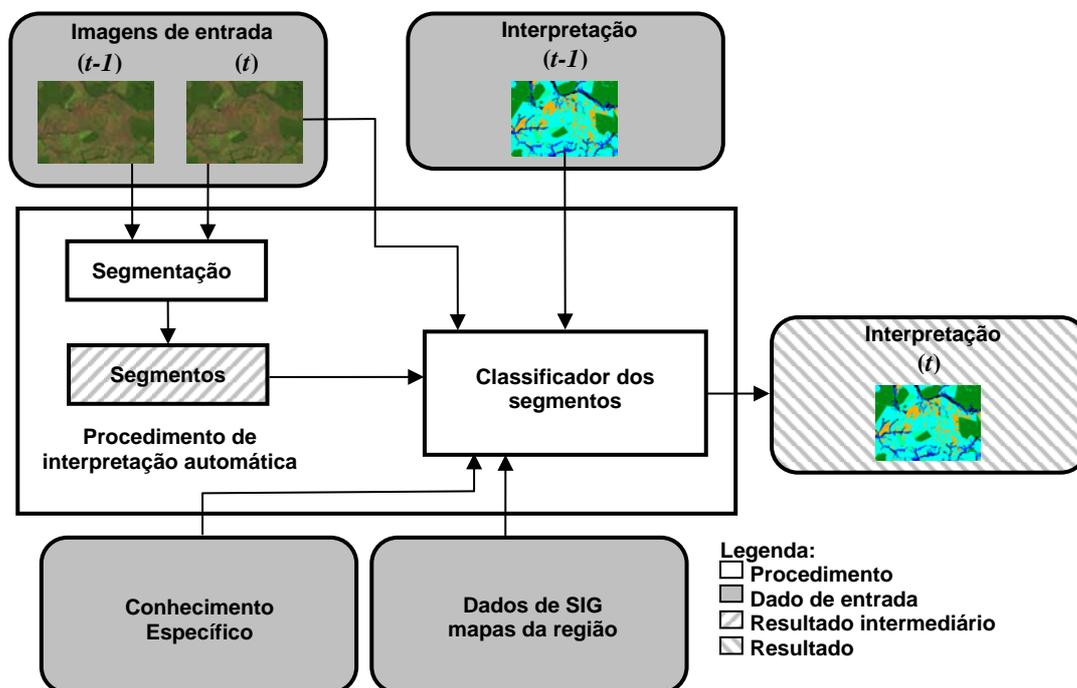


Figura 3 – Procedimento para a interpretação automática de imagens de satélite de baixa resolução

A fim de produzir a interpretação da região de interesse no instante, t , o procedimento proposto emprega: **1)** Conhecimento específico sobre a região de interesse, contendo as classes de cobertura do solo, suas respectivas caracterizações espectrais, contextuais e multitemporais e a lógica empregada na classificação; **2)** Duas imagens registradas adquiridas pelo mesmo satélite, uma no instante t , e outra num instante anterior, $t-1$; **3)** A interpretação apurada da imagem de $t-1$; **4)** Dados de SIG sobre a região de interesse.

O procedimento de interpretação proposto está baseado na classificação de segmentos. Isto permite ao processo de interpretação considerar atributos como forma, textura, e relação espacial entre objetos, num contexto mais apropriado para a representação de conhecimento do que a abordagem clássica de classificação por pixels (Andrade, 2003; Darvish, 2003; Yan, 2003). Portanto, o procedimento proposto começa com a segmentação, que delimita regiões espectralmente homogêneas em ambas as imagens de entrada.

O objetivo central do procedimento de interpretação proposto é reproduzir o raciocínio empregado pelo foto-intérprete ao realizar a interpretação.

4.2. Conhecimento específico

Entende-se como conhecimento específico, o conhecimento acumulado pelo estudo teórico e, principalmente, através de experiência empírica que torna um indivíduo hábil ou mais competente para realizar uma tarefa específica; no caso deste trabalho, a interpretação de imagens de satélite de baixa resolução.

4.2.1. Modalidades de conhecimento

Neste trabalho subdivide-se o conhecimento específico nas seguintes modalidades:

1) Classes da legenda – Enumera e descreve as classes de uso e cobertura do solo a serem identificadas na imagem.

2) Conhecimento espectral – basicamente as assinaturas espectrais de cada uma das classes da legenda.

3) *Conhecimento contextual* – Indica a informação contextual relevante para a discriminação de classes da legenda com assinatura espectral semelhante.

4) *Conhecimento Multitemporal* – Dada a classificação do segmento em $t-1$, relaciona as possíveis classificações em t e suas respectivas possibilidades. A teoria das possibilidades, introduzida em (Zadeh, 1978), constitui um contexto que permite tratar dos conceitos de incerteza de um modo não probabilista.

5) *Vetor de atributos* – conjunto dos n atributos considerados por um foto-intérprete para a classificação dos segmentos.

6) *Regras de inferência* – Regras que descrevem a lógica utilizada na interpretação visual. Basicamente, modela o raciocínio do foto-intérprete combinando diferentes itens de conhecimento espectral, contextual e multitemporal no processo de interpretação.

Os itens de conhecimento específico utilizados na interpretação automática de imagens de satélite de baixa resolução devem ser obtidos junto a especialistas em fotointerpretação, manejo agrônômico, ecologia e, até mesmo, por moradores da região de interesse através de entrevistas, questionários, etc.

4.2.2.

Extração automática do conhecimento espectral

Os aspectos contextual e multitemporal do conhecimento são em geral dependentes da área sob análise, mas independem da imagem particular a ser classificada. O conhecimento espectral, ao contrário, é afetado pelas condições em que a imagem é obtida. Fatores atmosféricos, problemas de calibração do sensor, níveis de umidade do solo, entre outros, podem implicar em que uma mesma classe de uso e cobertura do solo tenha respostas espectrais muito distintas em imagens de uma mesma região obtidas em datas diferentes. Esta dificuldade é contornada nos métodos de classificação supervisionados, em que as assinaturas espectrais são estimadas a partir de amostras coletadas pelo foto-intérprete da própria imagem a ser classificada. Esta coleta das amostras é, contudo, usualmente um procedimento manual.

Nesta seção, introduz-se uma extensão ao esquema proposto na seção 4.1 que visa automatizar o processo de estimação das assinaturas espectrais

(conhecimento espectral). Trata-se de um método automático para a seleção de amostras, com base exclusivamente nas duas imagens, obtidas nos instantes t e $t-1$ e na classificação confiável da imagem $t-1$. O método de detecção automática de mudança aplicado neste trabalho deve ser capaz de detectar a mudança de resposta espectral nos segmentos delimitados pelo procedimento de segmentação.

Em linhas gerais, este método submete os objetos produzidos pela segmentação a um processo automático de detecção de mudanças, retorna os segmentos que pertencem a uma mesma classe (estáveis) e os que pertencem a duas classes diferentes nos instantes $t-1$ e t (alterados). O classificador de segmentos utiliza os segmentos estáveis como conjunto de treinamento para estimar as assinaturas espectrais das classes de interesse.

A maior parte das abordagens propostas na literatura para detecção automática de mudanças (Cazes, 2004; Coppin, 2001; Feitosa, 2001; Fung, 1987) baseiam-se nas seguintes hipóteses: **1)** O percentual de área onde ocorreu mudança de classe entre $t-1$ e t é pequeno; **2)** Os eventos naturais e antrópicos alteram diferentemente a resposta espectral das classes; **3)** As imagens em $t-1$ e t estão registradas.

A figura 4 ilustra o procedimento de detecção automática de mudanças.

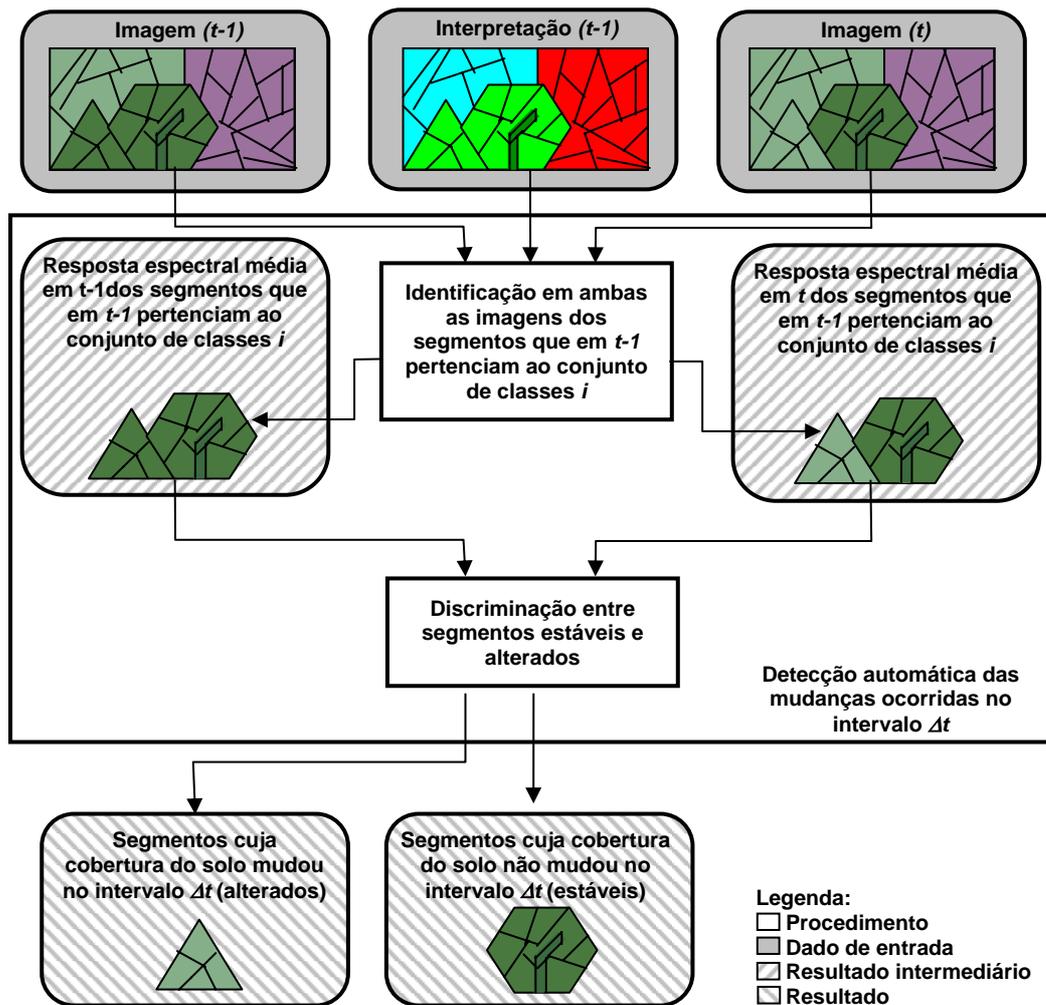


Figura 4 – Detecção automática de mudanças

O procedimento de detecção automática de mudanças considera os segmentos definidos na etapa anterior, as imagens de $t-1$ e t e a classificação em $t-1$ e identifica como resultado os segmentos estáveis e os segmentos alterados. Como decorrência da hipótese 2), adota-se em geral um procedimento de detecção das mudanças que leva em conta a classificação em $t-1$.

Inicialmente, são selecionados, em ambas imagens, os segmentos correspondentes a uma classe (ou grupo de classes com resposta espectral similar), conforme definido na classificação em $t-1$. Avalia-se em seguida a alteração na resposta espectral média de cada segmento na imagem adquirida em $t-1$ para a imagem adquirida em t . Para isso, é aplicada alguma função critério, comparando o valor correspondente da função com um dado limiar, são discriminados os segmentos entre *estáveis* e *alterados*. Este procedimento é repetido para cada classe (ou grupo de classes) de interesse. Deve ser, neste

momento, mencionado que o modelo proposto permite que a escolha da função critério seja feita de acordo com as características do problema. Portanto, fica, por enquanto, em aberto a escolha da função critério. No capítulo 5, será definida a função critério empregada no experimentos.

Como já foi mencionado, as médias das repostas espectrais dos segmentos estáveis na imagem do instante t são utilizadas como amostras de treinamento para estimar as assinaturas espectrais em t de cada classe de interesse. Trata-se portanto de um método automático para extração do conhecimento espectral a partir das imagens em t e $t-1$ e da classificação em $t-1$. A figura 5, derivada da figura 3, apresenta o procedimento automático para geração do conhecimento espectral (linhas pontilhadas).

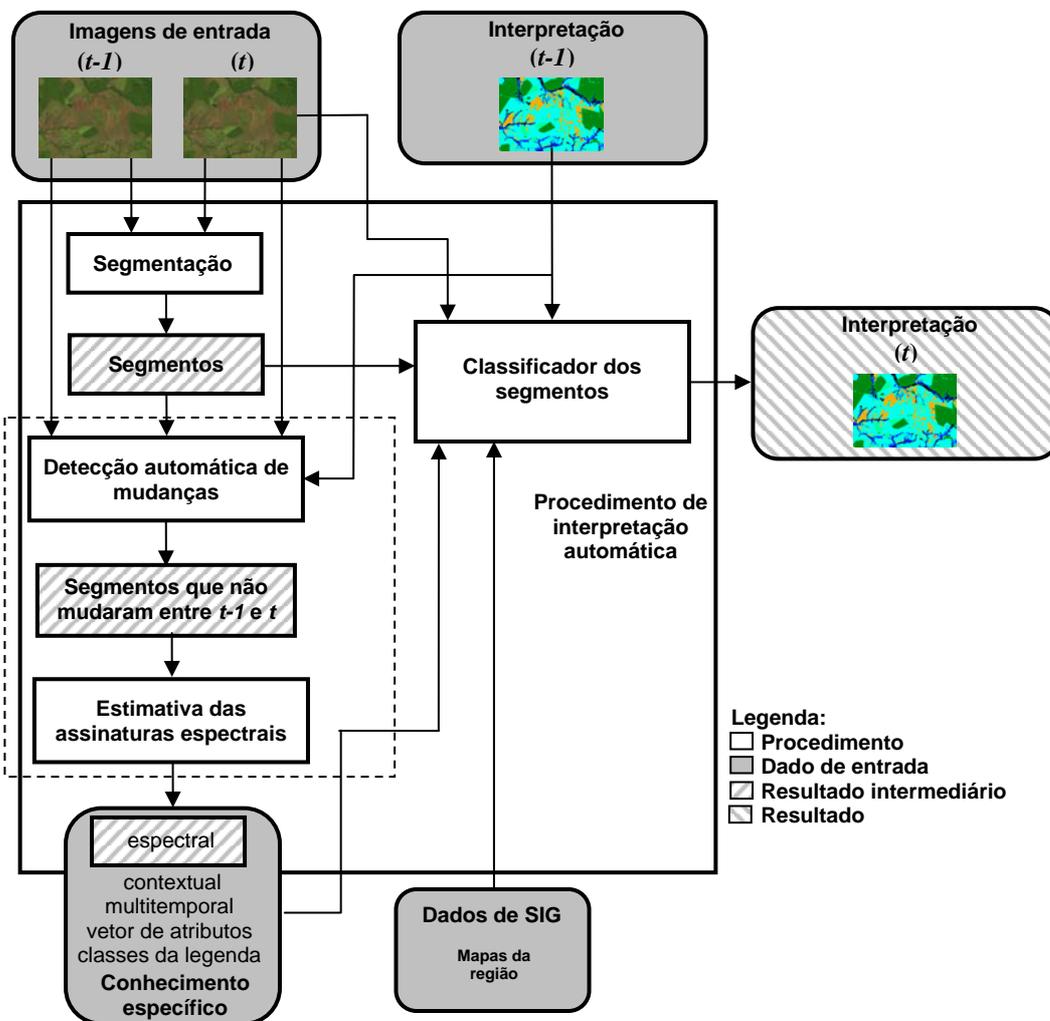


Figura 5 – Procedimento de interpretação automática de imagens de sensores remotos de baixa resolução, incluindo o método automático de seleção de amostras de treinamento.

4.3. Classificador dos segmentos

Segundo Kuncheva (2000), sistemas de lógica nebulosa são modelos transparentes para a implementação de raciocínio lógico. Assim sendo, neste trabalho, um sistema de lógica nebulosa é empregado, para modelar no *classificador dos segmentos* o raciocínio empregado pelo foto-intérprete no processo de interpretação.

Segundo Mendel, em (1995), de uma maneira geral, para a construção de sistemas baseados na lógica nebulosa é necessário: **1)** empregar variáveis lingüísticas segundo proposto por Zadeh (1965) – variáveis cujos valores não são números, mas sim palavras ou sentenças expressas numa linguagem natural; **2)** Quantificar os rótulos das variáveis lingüísticas – rótulos lingüísticos são os “valores” que podem ser assumidos por uma dada variável lingüística; **3)** Definir os conectores lógicos (“não”, “e” e “ou”); **4)** Definir as implicações; **5)** Definir a combinação de regras. A figura 6 apresenta a estrutura e os componentes do classificador dos segmentos.

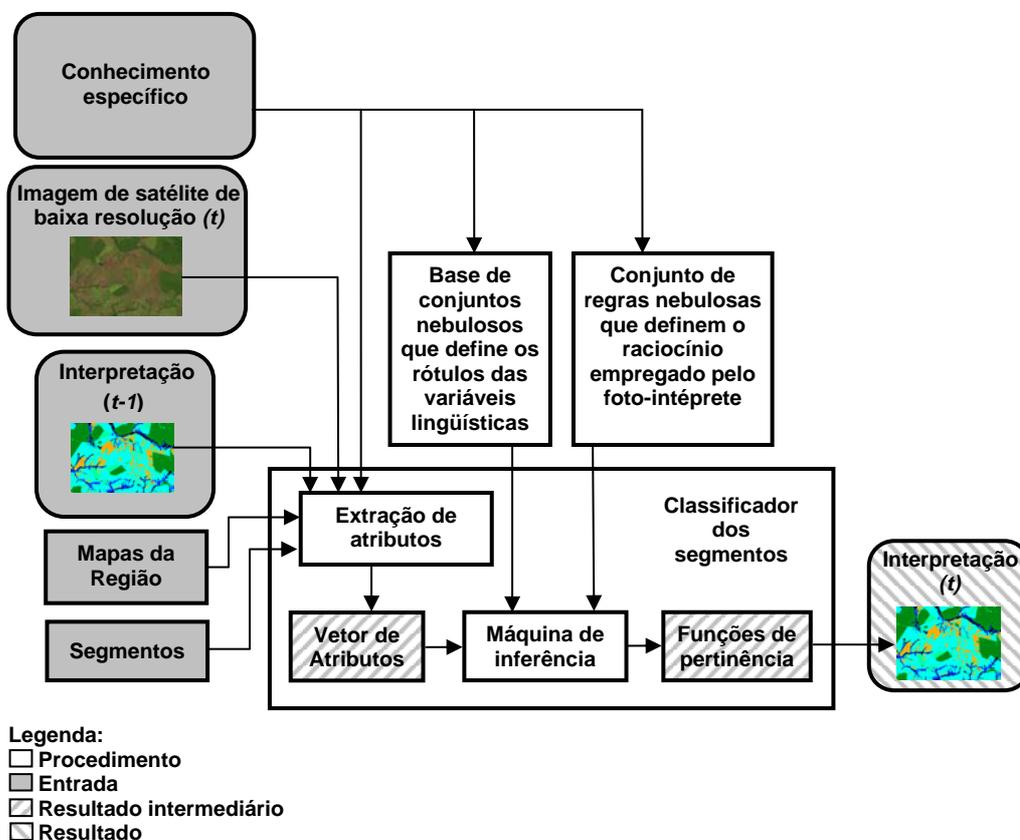


Figura 6 – Classificador dos segmentos

A fim de produzir a interpretação da cena em t , o classificador de segmentos recebe como entradas: **1)** conhecimento específico; **2)** imagens de satélite de baixa resolução em t e $t-1$; **3)** a interpretação da imagem em $t-1$; **4)** os segmentos, e **5)** os mapas temáticos da região de interesse.

No método aqui proposto, a modelagem das regras, das variáveis lingüísticas e dos rótulos das variáveis lingüísticas (conjuntos nebulosos correspondentes aos rótulos que representam os conceitos associados às variáveis lingüísticas), relativas ao conhecimento contextual e multitemporal é realizada manualmente e é parte integrante do conhecimento específico. Esta modelagem permanece válida por longos períodos e se aplicará a quaisquer duas imagens da mesma área obtidas em datas separadas por Δt . Por outro lado, os conjuntos nebulosos que definem os rótulos das variáveis lingüísticas associadas ao conhecimento espectral devem ser modelados para cada par de imagens particular, eventualmente de forma automática, conforme proposto na seção 4.2.2.

No *classificador de segmentos*, calcula-se o vetor que contém os atributos do segmento em questão. Em seguida, a máquina de inferência calcula com base nas regras de inferência, nos conjuntos nebulosos e nos atributos os valores da pertinência do segmento em questão a cada uma das classes da legenda. O classificador atribui ao segmento em questão o rótulo da classe que possui o maior grau de pertinência para o segmento. A seção a seguir discute a máquina de inferência em detalhes.

4.3.1. Máquina de Inferência

Seja $\Omega = \{\omega_1, \dots, \omega_c\}$ o conjunto das c classes da legenda e $\mathbf{x} = [x_1, \dots, x_n]^T \in \mathfrak{R}^n$ o vetor dos n atributos que descrevem um segmento em particular, onde, cada componente de \mathbf{x} expressa um atributo do segmento. Matematicamente, a classificação corresponde ao mapeamento descrito na eq. (2).

$$D : \mathfrak{R}^n \rightarrow \Omega \quad \text{Eq. (2)}$$

A descrição a seguir da máquina de inferência, baseia-se no modelo canônico de classificador apresentado em (Duda, 2001).

Sendo apresentado o vetor \mathbf{x} em sua entrada o classificador produz em sua saída c valores de pertinência $g_1(\mathbf{x}), \dots, g_c(\mathbf{x})$ de \mathbf{x} associados a cada uma das funções discriminantes g_1, \dots, g_c que descrevem a semelhança de \mathbf{x} a cada uma das c classes da legenda. A regra de máxima pertinência associa \mathbf{x} à classe correspondente ao maior valor de pertinência.

Em sistemas nebulosos (Mendel, 1995) como o classificador proposto, os atributos (e.g. cor, distância, altitude) ou conjuntos de atributos (e.g. coordenadas do centro de gravidade de um objeto) são representados pelo que Zadeh (1965) chama de variáveis lingüísticas v_1, \dots, v_r , onde $1 \leq r \leq n$. Assim sendo, $\mathbf{x} = [\mathbf{x}_1^T, \dots, \mathbf{x}_r^T]^T$, onde \mathbf{x}_r é o vetor coluna que compreende os atributos associados à variável lingüística v_r .

Por sua vez, cada variável lingüística está associada a diferentes rótulos lingüísticos (e.g. baixa, média e alta). Cada rótulo lingüístico representa um conceito definido por um conjunto nebuloso. K_j representa o número de rótulos lingüísticos associados à j -ésima variável lingüística (v_j) e $A_{j,i}$ representa o i -ésimo conjunto nebuloso associado à variável lingüística v_j , onde $i = 1, \dots, K_j$ e $j = 1, \dots, r$. O conjunto de todos os rótulos lingüísticos compõe o vocabulário, A , onde $A_{j,i} \in A \therefore j = 1, \dots, r$ e $i = 1, \dots, K_j$.

O sistema nebuloso escolhido para modelar o raciocínio lógico do foto-intérprete emprega regras SE-ENTÃO. Em geral, tais regras são organizadas da seguinte forma:

SE (ANTECEDENTES) ENTÃO (CONSEQÜENTES).

Basicamente, os antecedentes expressam as condições a serem satisfeitas, enquanto os conseqüentes expressam os desdobramentos ocorridos caso os antecedentes sejam satisfeitos.

No presente modelo, os rótulos lingüísticos e as regras representam explicitamente as diversas modalidades de conhecimento prévio empregadas no processo de interpretação a ser executado pela chamada máquina de inferência. Neste trabalho, empregam-se somente regras com um único conseqüente, conforme apresentado na eq. (3).

$$R_k : \text{SE } (v_1 \text{ é } A_{1,i(1,k)}) \text{ E } \dots \text{ E } (v_r \text{ é } A_{r,i(r,k)}) \text{ ENTÃO classe é } \omega_o \text{ com } g_{o,k}(\mathbf{x}) \quad \text{Eq. (3)}$$

onde o índice $i(j, k)$ indica qual o rótulo lingüístico associado à variável v_j na regra R_k e $g_{o,k}(\mathbf{x})$ representa o grau de pertinência atribuído ao padrão \mathbf{x} em relação à classe ω_o pela regra R_k . Neste contexto, o antecedente que expressa a condição $(v_r \text{ é } A_{r,i(r,k)})$ retorna valor de pertinência do valor medido da variável v_r ao conjunto nebuloso que modela o rótulo $A_{r,i(r,k)}$. O operador E combina os diversos valores de pertinência produzindo $g_{o,k}(\mathbf{x})$.

Vale mencionar que cada regra define o grau de pertinência de uma única classe, enquanto várias regras podem associar diferentes graus de pertinência a uma mesma classe.

Especificamente neste problema, as regras utilizadas possuem antecedentes espectrais, contextuais e multitemporais. O operador de combinação de antecedentes E é modelado pelo produto dos graus de pertinência dos valores das variáveis lingüísticas, v_j , relacionados na regra R_k aos correspondentes rótulos lingüísticos, $A_{j,i(j,k)}$.

O cálculo do grau de pertinência do vetor \mathbf{x}_j , correspondente à variável lingüística v_j relativamente ao rótulo $A_{j,i}$ é feito por um procedimento conhecido como fuzzificação. No presente trabalho, o procedimento de fuzzificação é especificado para cada par variável lingüística-rótulo lingüístico de acordo com os conceitos lingüísticos definidos pelos especialistas.

O grau de pertinência relacionado à classe ω_o correspondente à regra R_k , representado por $g_{o,k}(\mathbf{x})$, pode ser calculado pela eq. (4)

$$g_{o,k}(\mathbf{x}) = \mu_{1,i(1,k)}(\mathbf{x}_1) \times \mu_{2,i(2,k)}(\mathbf{x}_2) \times \dots \times \mu_{r,i(r,k)}(\mathbf{x}_r) \quad \text{Eq. (4)}$$

onde $\mu_{j,i(j,k)}(\mathbf{x}_j)$ é o grau de pertinência dos atributos \mathbf{x}_j correspondentes à variável v_j relativamente ao rótulo $A_{j,i(j,k)}$ da regra R_k . O grau de pertinência final da classe ω_o é dado pela eq. (5)

$$g_o(\mathbf{x}) = \max \{ g_{o,k} \} \quad \text{Eq. (5)}$$

onde max considera todas as regras que possuem no conseqüente a classe ω_o .

4.3.2.

Representação do conhecimento no classificador dos segmentos

A fim de possibilitar a reprodução do raciocínio empregado na interpretação das imagens é necessário definir junto aos especialistas da região de interesse: **1)** as classes da legenda, $\Omega = \{\omega_1, \dots, \omega_c\}$; **2)** as regras, contendo antecedentes espectrais, contextuais e multitemporais, associadas a cada classe da legenda $R_k \mid g_{o(k)} = g_i$; **3)** o conjunto de atributos dos segmentos a serem medidos, isto é $\mathbf{x} = \{x_1, \dots, x_n\}^T$; **4)** o vocabulário, A ; **5)** representar explicitamente o vocabulário através de conjuntos nebulosos A_{ji} para $j = 1, \dots, n$ e $i = 1, \dots, K_j$, onde K_j representa o número de rótulos associado a variável lingüística j . Neste trabalho, o vocabulário espectral é representado automaticamente, conforme descrito na seção 4.2.2, já os vocabulários contextual e multitemporal são representados manualmente de forma explícita.