

4 Modelo proposto

4.1 Introdução

Este capítulo apresenta o modelo proposto no trabalho para interpretação de imagens de sensores remotos baseada em conhecimento.

4.2 Descrição geral do modelo

O modelo proposto é orientado a objetos, o que envolve a segmentação prévia da imagem.

Com a segmentação devidamente realizada parte-se para os procedimentos de classificação. O modelo de classificação divide-se em três fases, como mostra a Figura 10.

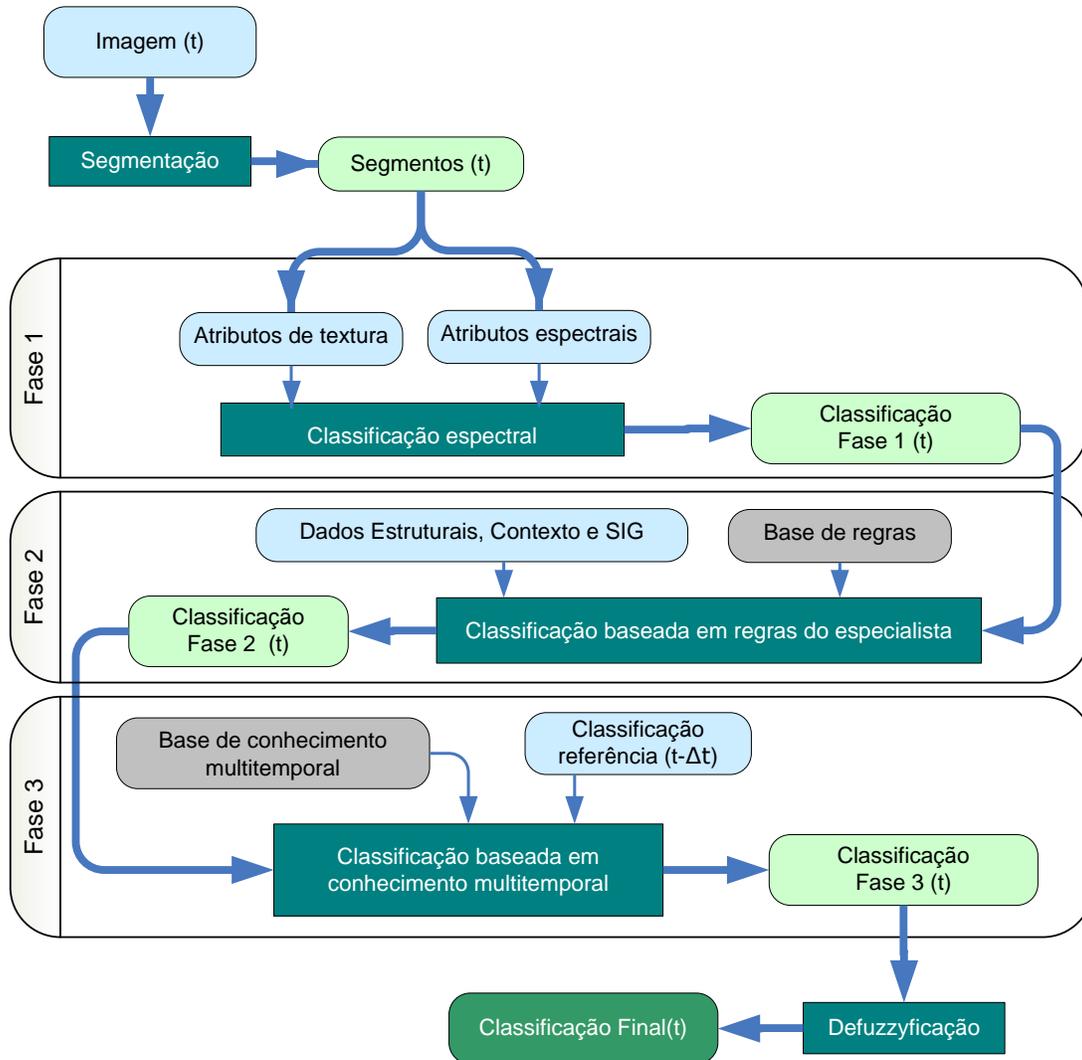


Figura 10 – Modelo de interpretação baseado em conhecimento para imagens de alta resolução.

Os dados de entrada para o modelo apresentado é a imagem a ser analisada obtida em um determinado instante de tempo t e a classificação de uma imagem da mesma área obtida em um instante de tempo anterior $t-\Delta t$.

Na primeira fase do modelo realiza-se uma classificação supervisionada dos segmentos baseando-se na informação espectral e nos atributos de textura. A classificação produz para cada objeto um vetor com os graus de pertinência a cada uma das classes da legenda.

Da segunda fase em diante utilizam-se modelos de conhecimento de um especialista. Computacionalmente esse conhecimento é modelado por meio de regras

nebulosas. Agrega-se ao resultado produzido na primeira fase dados de SIG e outros atributos estruturais relacionados à forma e arranjo espacial dos segmentos..

Na terceira e última fase aplica-se o conhecimento multitemporal. Este se baseia na classificação da área de estudo em um instante de tempo anterior $t-\Delta t$ e utiliza estimativas de possibilidades de transições entre classes durante o intervalo de tempo Δt .

Após a terceira fase é realizada a defuzzificação que gera o resultado final da classificação.

Os resultados produzidos por uma fase são usados como entrada para a fase seguinte. A primeira fase prevê a utilização de algum método supervisionado absolutamente convencional. Nas seções seguintes descrevem-se as fases 2 e 3 do modelo.

4.2.1

Fase 1: Classificação automática supervisionada baseada em dados espectrais e textura

Nessa Fase um classificador supervisionado é introduzido ao modelo para prover uma primeira classificação com base em dados espectrais e parâmetros de textura. Os padrões classificados constituem-se dos segmentos ou objetos representados pela segmentação da imagem original. A resposta espectral (nas bandas disponíveis) é medida como uma média no objeto.

Esse classificador então é treinado por um conjunto de treinamento previamente selecionado. Uma vez treinado os dados de teste são classificados obtendo o resultado da classificação da primeira fase.

4.2.2

Fase 2: Classificação baseada em regras do especialista



Figura 11 - diagrama detalhado do procedimento de interpretação na fase 2.

A Figura 11 mostra a fase 2 do modelo proposto. Em linhas gerais a classificação nesta fase é feita por um conjunto de regras nebulosas elaboradas pelo especialista, que têm como entrada o resultado da classificação na fase 1, atributos de contexto, dados de SIG e atributos estruturais dos objetos. O conjunto de regras é específico a imagem ou mesmo a região analisada, podendo assim ser considerado como uma entrada do procedimento. Esse conjunto de regras mapeia a entrada do sistema (todos os atributos disponíveis) as saídas (classes) coerentes.

Entre os parâmetros que podem ser utilizados para a criação da base de regras destacam-se: os atributos de contexto; atributos estruturais, por exemplo, excentricidade, área, relação da área com o perímetro e dados gerais de SIG.

O classificador baseado em regras nebulosas envolve uma série de funções de pertinência cuja forma é definida por um conjunto de parâmetros. Os valores adequados para estes parâmetros são freqüentemente definidos pelo método tradicional de tentativa-e-erro. Neste trabalho eles são estimados por um método automático de ajuste.

4.2.3

Fase 3: Representação de conhecimento multitemporal

Na terceira fase do modelo proposto inclui-se o conhecimento multitemporal no processo de classificação automática. O conhecimento multitemporal é modelado conforme a proposta em [68], [69] e [70], isto é, através das possibilidades de transição

entre classes em um determinado intervalo de tempo. Um diagrama de transição de estados, como o da Figura 12, representa pictoricamente o modelo de conhecimento multitemporal para um dado intervalo Δt .

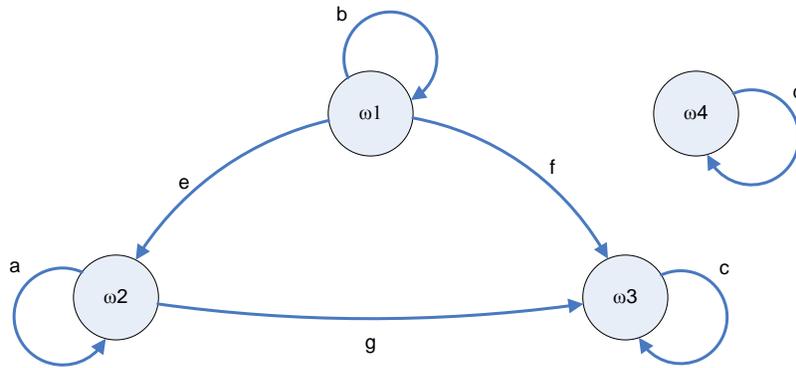


Figura 12 – Exemplo de diagrama de transição de estados para 4 classes

Os nós ω_1 , ω_2 , ω_3 e ω_4 correspondem às classes da legenda e os arcos às mudanças de classes que podem ocorrer em um determinado intervalo de tempo Δt .

Associa-se a cada arco da Figura 12 um valor entre 0 e 1, representado na figura pelas letras a , b , c , d , e , f e g , que expressam as possibilidades de ocorrência da correspondente transição; zero indica transição impossível e 1 a transição com maiores chances de ocorrência.

O diagrama de transição de estados define a chamada Matriz de Transição $T = \{\tau_{ij}\}_{i,j=1}^n$, onde cada linha corresponde à classe do objeto no instante $t-\Delta t$ e as colunas às classes a que o mesmo objeto pode pertencer num instante posterior t . Os elementos da matriz são as respectivas possibilidades de transição τ_{ij} . A matriz de transição relativa ao diagrama da Figura 12 é dada por:

$$T = \begin{bmatrix} b & e & f & 0 \\ 0 & a & g & 0 \\ 0 & 0 & e & 0 \\ 0 & 0 & 0 & d \end{bmatrix} \quad \text{Eq.(4)}$$

A classificação multitemporal admite conhecida a classificação ω_i do segmento no instante anterior. Os valores de pertinências produzidos nesta terceira fase são dados pelo produto de cada elemento da i -ésima linha da matriz de transição pelo correspondente valor de pertinência produzido na fase 2. Se, por exemplo,

${}^2x = (x_1, \dots, x_n)$ é o vetor com os valores de pertinência gerados na fase 2 em relação a cada uma das n classes, as pertinências da fase 3 em que se explora a informação multitemporal será dada por:

$${}^3x = (\tau_{i1} {}^3x_1, \tau_{i2} {}^3x_2, \dots, \tau_{in} {}^3x_n), \quad \text{Eq.(5)}$$

Uma questão relevante a esta altura, diz respeito à estimativa dos valores de possibilidade de transição τ_{ij} . Isto se faz com o auxílio de um especialista conhecedor da dinâmica das classes na área alvo. Ele indica as transições impossíveis, e, portanto com possibilidade nula, e para cada classe de partida a transição mais provável, que recebe possibilidade igual a 1.

Resta estimar ainda as possibilidades de ocorrências das demais transições possíveis. Neste trabalho consideram-se duas abordagens. A primeira abordagem, que chamaremos de *crisp*, consiste em simplesmente atribuir valor 1 a todas as transições possíveis. Esta alternativa tem meramente o efeito de reduzir o espaço de busca na classificação.

A segunda alternativa, que chamaremos *nebulosa*, admite valores entre 0 e 1 para as possibilidades de transição. Estes valores podem ser estimados através de tentativas-e-erros ou utilizando algum método de busca automático. No presente trabalho utiliza-se o mesmo procedimento adotado em [69], baseado em algoritmos genéticos.