

## **5**

### **Avaliação experimental do modelo**

O presente capítulo apresenta os experimentos realizados com o propósito de avaliar o método de modelagem de conhecimento multitemporal proposto neste trabalho. Para tanto, inicialmente, são apresentadas as características particulares do sistema desenvolvido e do sítio alvo. Em seguida, são apresentados e discutidos os resultados obtidos nos experimentos realizados.

#### **5.1.**

##### **Procedimento Experimental**

Esta seção apresenta características particulares dos experimentos realizados, englobando os programas empregados, os dados experimentais, as classes da legenda, o conhecimento multitemporal obtido por um especialista em foto-interpretação, o número de ocorrências de cada classe da legenda nas imagens da base de dados e os métodos de seleção dos conjuntos de treinamento.

##### **5.1.1.**

###### **Programas utilizados na preparação do protótipo**

Para o desenvolvimento de um protótipo de interpretação automática de imagens e da ferramenta de ajuste do conhecimento multitemporal proposta foram utilizados os seguintes programas:

- Erdas: utilizado na fase de pré-processamento das imagens;
- eCognition: utilizado na fase de segmentação;
- Matlab: utilizado para o desenvolvimento do procedimento de interpretação e durante a fase de ajuste do conhecimento multitemporal.

A fase final do processo de produção do mapeamento de ocupação do solo deve ser a avaliação da qualidade dos mapas finais, de forma a atribuir-lhes um índice de confiabilidade. O método mais comum para esta avaliação corresponde

à comparação dos resultados produzidos com dados de referência, que traduzem a “verdade de campo”, obtidos diretamente no terreno ou a partir da interpretação visual de especialistas.

### 5.1.2. Base de dados

As imagens empregadas nos experimentos referem-se ao município do Rio de Janeiro sito no estado do Rio de Janeiro.

Nos experimentos são empregadas imagens multiespectrais digitais obtidas pelo sensor TM do satélite Landsat 5, órbita 217 ponto 76. As bandas espectrais utilizadas são 5, 4 e 3. As imagens utilizadas nos experimentos foram adquiridas em:

- 30 de Maio de 1984 (vide figura 13);
- 18 de Janeiro de 1988 (vide figura 14);
- 18 de Abril de 1992 (vide figura 15);
- 16 de Junho de 1996 (vide figura 16);
- 12 de Agosto de 1999 (vide figura 17).




Figura 13 – Imagem Landsat TM adquirida em 1984.



Figura 14 – Imagem Landsat TM adquirida em 1988.




Figura 15 – Imagem Landsat TM adquirida em 1992.



Figura 16 – Imagem Landsat TM adquirida em 1996.



Figura 17 – Imagem Landsat TM adquirida em 1999.

Estas imagens serão referenciadas no restante do trabalho apenas pelo ano de aquisição. De acordo com a seqüência apresentada das imagens, o intervalo de tempo da aquisição entre elas é de aproximadamente quatro anos. Entre as duas últimas, este intervalo é de três anos, mas, neste trabalho, o tempo transcorrido entre elas será considerado de quatro anos para se adequar ao padrão apresentado entre as demais.

Além das imagens, são utilizadas como referência, mapas de uso da terra e cobertura vegetal do município produzidos através de classificação visual compatível com uma escala de 1:50.000 (Engefoto, 2000). Estes mapeamentos foram solicitados pela Prefeitura da Cidade do Rio de Janeiro e são, portanto, oficiais. Tais dados foram disponibilizados pela Secretaria de Meio Ambiente para fins acadêmicos, incluindo a presente pesquisa.

Os mapas temáticos, neste trabalho, são utilizados para validar os resultados obtidos pela interpretação automática.

### **5.1.3. Classes da legenda**

As classes a serem consideradas pelo procedimento de interpretação automática apresentado foram definidas junto a um especialista em foto-interpretação e relatório técnico fornecido pela Secretaria de Meio Ambiente da

cidade do Rio de Janeiro (2000). Estas estão descritas e indicadas abaixo com seus respectivos rótulos:

$\omega_1$ ) Afloramento Rochoso (vide figura 18)

Esta classe inclui as superfícies constituídas por rocha de origem natural e costões rochosos, caracterizados por grande massa compacta de pedra muito dura.

$\omega_2$ ) Água (vide figura 19)

Esta classe representa os tipos de superfícies de natureza predominantemente líquida: lagoas, rios, canais e oceano.


$\omega_3$ ) Área Úmida (vide figura 20)

Composta por: mangues, apicum e outras áreas úmidas com vegetação.


O manguê é caracterizado por plantas adaptadas aos terrenos pantanosos das margens das lagoas e desaguadouros dos rios. Inclui as várias fisionomias de manguê, com vegetação alófito de porte arbustivo-arbóreo, em diferentes estados de conservação.

O apicum inclui as áreas de manguê não cobertas por vegetação, porém com um típico substrato lodoso, sendo parte integrante dos ecossistemas de manguezal.

Além de mangues e apicum, existem outras áreas úmidas com vegetação, abrangendo as áreas com vegetação arbustivo-herbácea – nativa, secundária ou invasora – sobre solos encharcados, seja por deficiência de drenagem, seja por afloramento de lençol freático. Estão presentes em locais de solos permanentemente encharcados ou sujeitos a inundações. Este aspecto faz com que haja certas controvérsias no delineamento e interpretação desta classe de cobertura, uma vez que as condições meteorológicas ou a ocorrência intercalada de estações secas e chuvosas pode interferir neste processo.




(a)




(b)

Figura 18 – Ilustrações da classe afloramento rochoso em imagem Landsat TM.




(a)




(b)

Figura 19 – Ilustrações da classe água em imagem Landsat TM.




(a)




(b)

Figura 20 – Ilustrações da classe área úmida em imagem Landsat TM.






(a)




(b)

Figura 21 – Ilustrações da classe área urbana em imagem Landsat TM.




(a)




(b)

Figura 22 – Ilustrações da classe campo em imagem Landsat TM.




(a)




(b)

Figura 23 – Ilustrações da classe floresta em imagem Landsat TM.



(a)



(b)

Figura 24 – Ilustrações da classe solo exposto em imagem Landsat TM.

#### ω<sub>4</sub>) Área Urbana (vide figura 21)

Esta classe constitui tanto as áreas urbanas consolidadas como as ainda não consolidadas.

Áreas urbanas consolidadas contêm um grupo heterogêneo de alvos espectrais característicos de áreas urbanas densas.

Nas áreas urbanas não consolidadas, a ocupação humana encontra-se esparsa, seja por estarem em processo de ocupação ou ainda por serem áreas onde incidem limitações físicas ou legais para o processo de ocupação urbana. Neste caso, agregam-se as áreas onde a expansão urbana apresenta-se em sua fase inicial, constituindo uma forma de pressão direta para ocupação de áreas próximas aos remanescentes naturais de grande importância para a cidade. Observa-se que este fato ocorre não só em função do déficit habitacional verificado no Município do Rio de Janeiro, através de assentamentos informais, como pela marcante presença de regiões ocupadas com residências de alto nível, muitas vezes construídas em condomínios particulares, que possuem vasta área verde.

#### ω<sub>5</sub>) Campo (vide figura 22)

Inclui as áreas de no mínimo 4ha onde existe o uso agropastoril, além de áreas denominadas campo antrópico de origem antrópica quase em sua totalidade, incluindo campos de capim-colonião, de outras gramíneas, de dicotiledôneas herbáceas, e as de macega.

O campo antrópico ocorre principalmente em áreas marginais aos maciços rochosos, atuando praticamente como uma região de transição entre as áreas urbanas e as ocupadas com florestas.

Esta classe inclui também a vegetação natural rasteira e a floresta em estado inicial de regeneração, que ocorre em locais de solo raso normalmente próximos aos afloramentos de rocha.

#### ω<sub>6</sub>) Floresta (vide figura 23)

Esta classe compreende além de floresta propriamente dita, parques (vegetação em parques públicos) e restinga.

As florestas no Rio de Janeiro são caracterizadas por floresta Ombrófila Densa (Mata Atlântica) pouco alterada ou não alterada, fitofisionomia nativa do Município, podendo também ser uma Floresta Alterada tardia.

Inclui diversas fitofisionomias associadas à alteração das florestas nativas, como raleamento por corte seletivo, ou pequenas áreas de desmatamento, além de associadas às diversas fases sucessionais que seguem a supressão total ou parcial da floresta nativa. Inclui também os bananais que ocupam diversos trechos das encostas, principalmente no Maciço da Pedra Branca, que não podem ser separados das florestas nativas de forma segura, devido à confusão de assinaturas espectrais e interposição espacial entre os dois alvos.

No Município, os resíduos remanescentes de Mata Atlântica pouco ou não alterada compondo florestas ocorrem principalmente nos maciços da Pedra Branca, da Tijuca e de Gericinó.

A classe floresta inclui também os remanescentes de restinga, arbóreo-arbustiva e arbustivo-herbácea, além dos remanescentes de mata-de-caixeta que existem na baixada de Jacarepaguá.

Os parques inclusos nesta classe compreendem áreas com vegetação de campo e porte arbóreo nos grandes parques públicos da cidade.

#### ω<sub>7</sub>) Solo Exposto (vide figura 24)

Inclui as áreas de solo exposto seja por ocorrência de terraplenagem, deslizamentos ou outras causas e as áreas de mineração – pedreiras, saibreiras.

#### **5.1.4. Determinação de objetos**

O processo de segmentação, neste trabalho, foi realizado simultaneamente em todas as imagens em conjunto com seus respectivos mapas temáticos. Ou seja, os objetos foram gerados de forma que cada objeto de uma imagem tivesse um objeto correspondente em cada uma das imagens restantes. Além disso, todos os objetos correspondentes entre si são áreas homogêneas em suas respectivas imagens.

Desta forma, é plausível tratar de multitemporalidade dos objetos, pois imagens de instantes diferentes de tempo possuem objetos que são correspondentes entre si.

Entretanto, os mapas temáticos foram produzidos manualmente em um certo fator de escala. A escala determina uma relação entre as dimensões dos elementos representados no mapa e as correspondentes dimensões reais. Isto significa que, em escalas maiores que a utilizada para produzir os mapas, as delimitações das regiões poderão apresentar algum deslocamento dos limites reais.

A figura 25 refere-se à imagem Landsat de 1999 com as subdivisões feitas manualmente durante a produção do respectivo mapa temático. Nota-se que esta imagem em pequena escala parece não conter imprecisão em suas delimitações.




Figura 25 – Imagem Landsat, em pequena escala, com as respectivas subdivisões do mapa temático.

A mesma imagem, em escalas maiores, não apresentarão grandes imprecisões em certas regiões, como mostrado na figura 26.




Figura 26 – Imagem Landsat, em grande escala, com as respectivas subdivisões do mapa temático sem grandes imprecisões.

Contudo, em outras regiões, pode-se encontrar imprecisões intoleráveis para certas aplicações. Alguns exemplos são apresentados da figura 27 à figura 30. Nestas, as áreas com maiores problemas estão circundadas em azul.




Figura 27 – Imagem Landsat, em grande escala, com as respectivas subdivisões do mapa temático com problema de imprecisão.






Figura 28 – Imagem Landsat, em grande escala, com as respectivas subdivisões do mapa temático com problema de imprecisão.




Figura 29 – Imagem Landsat, em grande escala, com as respectivas subdivisões do mapa temático com problema de imprecisão.




Figura 30 – Imagem Landsat, em grande escala, com as respectivas subdivisões do mapa temático com problema de imprecisão.

Em decorrência disto, durante o processo automático de segmentação, foram gerados vários objetos com classificações de referência não confiáveis. Estes objetos estavam localizados nas bordas dos polígonos criados manualmente. Desta forma, pôde-se notar que estes objetos possuíam pequenas áreas e, muitas vezes, eram finos e longos.

Para avaliar um sistema automático, é indispensável o uso de dados confiáveis para serem usados como referência. Por isso, os objetos cuja classificação era duvidosa foram ignorados por este trabalho. Ou seja, estes objetos foram desconsiderados durante os procedimentos de interpretação. Ainda assim, o número de objetos restantes foi suficiente para construir e avaliar o sistema.

Na próxima seção, é apresentado o número de objetos determinado e utilizado neste trabalho.

#### **5.1.5. Ocorrência das classes da legenda**

Os números de objetos utilizados neste trabalho estão indicados na tabela 1. Estes números estão separados por classe e por ano.

Classes	1984	1988	1992	1996	1999
$\omega_1$ ) Afl. Rochoso	12	12	12	12	12
$\omega_2$ ) Água	49	49	49	49	49
$\omega_3$ ) Área Úmida	121	110	101	92	87
$\omega_4$ ) Área Urbana	320	358	390	477	538
$\omega_5$ ) Campo	352	337	334	326	330
$\omega_6$ ) Floresta	581	560	533	494	447
$\omega_7$ ) Solo Exposto	75	84	91	60	47
<b>Total</b>	<b>1510</b>	<b>1510</b>	<b>1510</b>	<b>1510</b>	<b>1510</b>

Tabela 1 – Número de objetos por classe e ano.

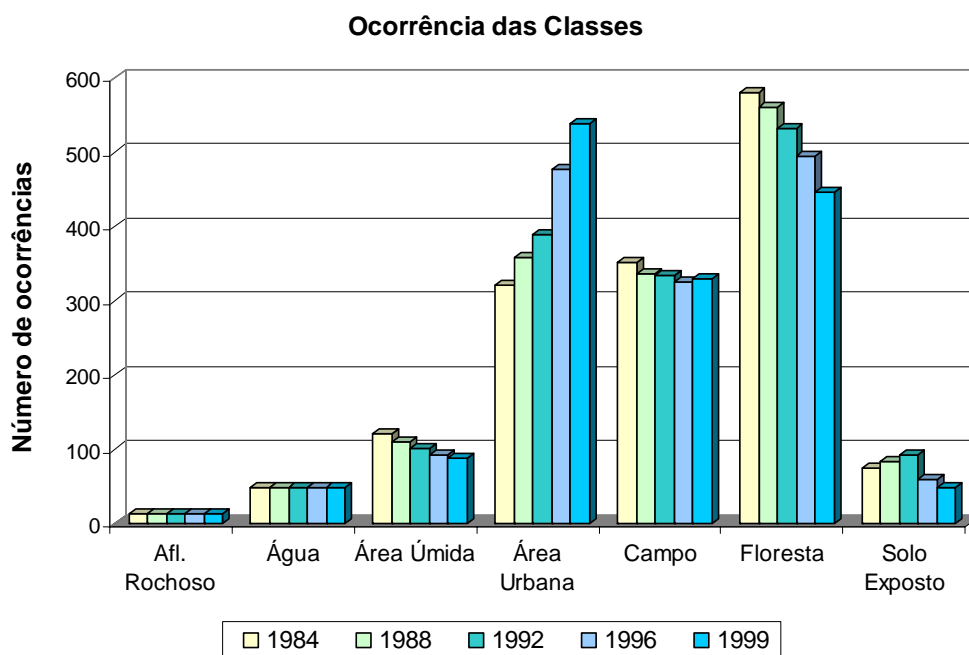


Figura 31 – Níveis de ocorrência das classes de legenda por ano.

O gráfico presente na figura 31 mostra os níveis de mudanças ocorridas em cada ano por classe. A partir deste, nota-se que:

- A classe área úmida vem apresentando uma diminuição gradativa ao longo dos anos. Isto se dá basicamente por dois motivos: 1) processos naturais que ocorrem no ambiente, tornando algumas regiões mais secas; 2) ação antrópica com execução de aterros e obras de drenagem;

- A classe floresta apresenta uma redução significativa. Isto pode ser explicado pela expansão da área urbana decorrente do crescimento populacional;
- Alto crescimento da área urbana que provoca ocupação de outras áreas. Dificultando, por exemplo, a preservação de florestas.

Estes dados obtidos através de imagens de sensores remotos reforçam, portanto, a idéia de que a interpretação deste tipo de imagem pode ser uma poderosa ferramenta de auxílio no ordenamento do uso e ocupação do solo.

Da tabela 2 à tabela 5, é apresentada a evolução da cobertura do solo ao longo dos anos. Elas contêm o número de objetos que no ano referente às linhas pertenciam a uma classe  $\omega_i$  e no ano referente às colunas mudou para a classe  $\omega_j$ ,  $i, j = 1, 2, \dots, 7$  ( $\omega_1$  - afloramento rochoso;  $\omega_2$  - água;  $\omega_3$  - área úmida;  $\omega_4$  - área urbana;  $\omega_5$  - campo;  $\omega_6$  - floresta;  $\omega_7$  - solo exposto).

		1988							
		$\omega_1$	$\omega_2$	$\omega_3$	$\omega_4$	$\omega_5$	$\omega_6$	$\omega_7$	Total
1984	$\omega_1$	12	0	0	0	0	0	0	12
	$\omega_2$	0	49	0	0	0	0	0	49
	$\omega_3$	0	0	106	0	12	0	3	121
	$\omega_4$	0	0	0	320	0	0	0	320
	$\omega_5$	0	0	4	25	303	0	20	352
	$\omega_6$	0	0	0	9	7	560	5	581
	$\omega_7$	0	0	0	4	15	0	56	75
	Total	12	49	110	358	337	560	84	1510

Tabela 2 – Evolução da cobertura do solo do ano de 1984 para 1988.

		1992							
		$\omega_1$	$\omega_2$	$\omega_3$	$\omega_4$	$\omega_5$	$\omega_6$	$\omega_7$	Total
1988	$\omega_1$	12	0	0	0	0	0	0	12
	$\omega_2$	0	49	0	0	0	0	0	49
	$\omega_3$	0	0	95	4	6	0	5	110
	$\omega_4$	0	0	0	358	0	0	0	358
	$\omega_5$	0	0	6	9	303	0	19	337
	$\omega_6$	0	0	0	5	17	533	5	560
	$\omega_7$	0	0	0	14	8	0	62	84
	Total	12	49	101	390	334	533	91	1510

Tabela 3 – Evolução da cobertura do solo do ano de 1988 para 1992.

		1996							
		$\omega_1$	$\omega_2$	$\omega_3$	$\omega_4$	$\omega_5$	$\omega_6$	$\omega_7$	Total
1992	$\omega_1$	12	0	0	0	0	0	0	12
	$\omega_2$	0	49	0	0	0	0	0	49
	$\omega_3$	0	0	89	7	5	0	0	101
	$\omega_4$	0	0	0	390	0	0	0	390
	$\omega_5$	0	0	3	45	282	0	4	334
	$\omega_6$	0	0	0	5	33	494	1	533
	$\omega_7$	0	0	0	30	6	0	55	91
	Total	12	49	92	477	326	494	60	1510

Tabela 4 – Evolução da cobertura do solo do ano de 1992 para 1996.

		1999							
		$\omega_1$	$\omega_2$	$\omega_3$	$\omega_4$	$\omega_5$	$\omega_6$	$\omega_7$	Total
1996	$\omega_1$	12	0	0	0	0	0	0	12
	$\omega_2$	0	49	0	0	0	0	0	49
	$\omega_3$	0	0	80	9	1	0	2	92
	$\omega_4$	0	0	0	477	0	0	0	477
	$\omega_5$	0	0	7	32	283	0	4	326
	$\omega_6$	0	0	0	7	40	447	0	494
	$\omega_7$	0	0	0	13	6	0	41	60
	Total	12	49	87	538	330	447	47	1510

Tabela 5 – Evolução da cobertura do solo do ano de 1996 para 1999.

### 5.1.6. Indicador de desempenho

A partir da classificação produzida e da classificação de referência, neste trabalho, será utilizado o indicador de desempenho descrito abaixo:

- Taxa de reconhecimento: indica, para cada classe da legenda, o percentual dos objetos corretamente classificados considerando os dados de referência. Serão indicadas também as taxas de reconhecimento média e global. A primeira refere-se à média aritmética das taxas de reconhecimento classe a classe e, a

última, refere-se à taxa de reconhecimento desconsiderando a divisão por classe.

A próxima seção apresenta o procedimento de seleção dos conjuntos de treinamento e, em seguida, serão mostrados os resultados experimentais e sua respectiva análise. Vale mencionar que, ao longo deste capítulo, os resultados são apresentados de forma resumida. Os resultados são apresentados detalhadamente nos apêndices.

### **5.1.7. Seleção dos conjuntos de treinamento**

Este procedimento tem como objetivo escolher um número representativo de objetos com classificação conhecida para cada classe da legenda. Estes objetos são o chamado conjunto de treinamento. A partir do conjunto de treinamento, é possível ajustar os parâmetros que distinguem as classes entre si dentro de classificadores supervisionados.

Neste trabalho, a seleção do conjunto de treinamento é necessária para ajustar os parâmetros:

- da classificação puramente espectral;
- das funções de pertinência do conhecimento espectral na classificação considerando conhecimentos espectral e multitemporal.

Em interpretação de imagens de sensores remotos, existem duas formas básicas para a seleção dos conjuntos de treinamento: a manual, que é feita pela classificação visual de alguns objetos pelo especialista, e a automática, realizada por algoritmos de detecção de mudança.

Neste trabalho, foi feita uma simulação para o método de seleção manual, onde são escolhidos 10% dos objetos de cada classe de forma aleatória para representar o conjunto de treinamento.

O método de seleção automática utiliza uma imagem auxiliar pré-classificada e a partir dela, são identificados os objetos que não mudaram na imagem a ser classificada. Estes objetos são atribuídos às mesmas classes da imagem auxiliar. No presente trabalho, foi adotado o método automático proposto em Cazes et al. (2004).

Na seção 5.3.1, serão discutidos os dois métodos de seleção, manual e automático, a partir de resultados experimentais.

## 5.2. Descrição do conhecimento multitemporal

O procedimento geral de interpretação foi apresentado no capítulo 3. A presente seção discute como este procedimento geral foi adequado à aplicação utilizada nesta avaliação. Especial atenção é dada à modelagem do conhecimento multitemporal.

Como já mencionado anteriormente, o conhecimento multitemporal busca modelar o conhecimento de um especialista humano quanto às possíveis mudanças de classes ao longo do tempo. Desta forma, dentro do problema apresentado, foi estabelecido junto a um especialista, as possíveis mudanças de classe dentro do intervalo de tempo  $\Delta t$  de aproximadamente 4 anos. As seguintes considerações foram feitas pelo especialista em sensoriamento remoto e profundo conhecedor da área de teste:

- Os objetos pertencentes às classes afloramento rochoso ( $\omega_1$ ) e água ( $\omega_2$ ) não mudam de classe. Portanto, o conhecimento multitemporal permite que os objetos pertencentes à estas classes sejam facilmente identificados. Uma vez que, nas condições normais consideradas pelo conhecimento multitemporal, os objetos atribuídos a estas classes permanecerão como tal. Além de que, os objetos pertencentes às demais classes não poderão, dentro do intervalo de tempo determinado, se tornar afloramentos rochosos ou água.
- Um objeto poderá pertencer à classe área úmida ( $\omega_3$ ) se, e somente se, na classificação de  $\Delta t$  anos antes do instante desejado, o objeto tenha pertencido às classes área úmida ou campo.
- Para que um objeto seja atribuído à classe área urbana ( $\omega_4$ ), ele pode ter sido anteriormente coberto por qualquer classe, com exceção de afloramento rochoso e água. No entanto, uma vez que o objeto tenha sido classificado como área urbana, este não mais mudará para outra classe.
- Atribuir-se-á à classe campo ( $\omega_5$ ), apenas os objetos que anteriormente tenham sido vinculados às classes área úmida, campo, floresta ou solo exposto.

- Para que um objeto seja da classe floresta ( $\omega_6$ ), sua classe anterior deve ser também floresta.
- A classe solo exposto é restrita aos objetos que pertenceram anteriormente às classes área úmida, campo, floresta e solo exposto.

Então o diagrama de transição de estados resultante para o intervalo de tempo de aproximadamente 4 anos é apresentado na figura 32.




Figura 32 – Diagrama de transição de estados do problema com intervalo de tempo de aproximadamente 4 anos.

O diagrama de transição de estados da figura 32 diz respeito a um intervalo de tempo de aproximadamente 4 anos. O diagrama tomaria outra configuração, se o intervalo de tempo considerado fosse outro. É, por exemplo, possível inferir do diagrama da figura 32, que para intervalos de oito anos, além das transições indicadas, é também possível que:

- objetos pertencentes à classe floresta passem a pertencer à classe área úmida;
- objetos da classe solo exposto tornem-se pertencentes à área úmida.



Conforme proposto por Mota (2004), para complementar o conhecimento multitemporal, é atribuído a cada arco do diagrama de transição de estados um valor referente à possibilidade de sua ocorrência.

### **5.3. Resultados Experimentais**

Deste ponto em diante, são apresentados os resultados obtidos a partir de experimentos realizados com os dados reais do município do Rio de Janeiro.

#### **5.3.1. Classificação espectral**

Nesta seção, são apresentados os resultados provenientes da classificação dos objetos utilizando somente a informação espectral. O classificador utilizado baseia-se na distância de Mahalanobis (Duda et al., 2001). A escolha deste classificador se deve ao fato de que a função de pertinência utilizada para o conhecimento espectral no procedimento de interpretação (apresentado no capítulo 3) é, também, baseada na distância de Mahalanobis.

A tabela 6 apresenta as taxas de reconhecimento obtidas pela classificação puramente espectral com seleção manual do conjunto de treinamento. A última coluna da tabela, denominada “geral”, refere-se à média aritmética dos resultados apresentados nas demais colunas. Observa-se que este tipo de classificador não proporciona um desempenho satisfatório, pois a taxa geral média é de aproximadamente 58%. Isto se deve ao uso de conhecimento insuficiente, pois algumas classes se confundem ao considerar apenas o conhecimento espectral como, por exemplo, as classes área úmida e solo exposto, assim como as classes floresta e campo.

Classes	1988	1992	1996	1999	Geral
$\omega_1$ ) Afl. Rochoso	91,7	33,3	66,7	41,7	58,3
$\omega_2$ ) Água	89,8	81,6	65,3	83,7	80,1
$\omega_3$ ) Área Úmida	31,8	44,6	48,9	59,8	46,3
$\omega_4$ ) Área Urbana	70,1	41,3	54,9	72,3	59,7
$\omega_5$ ) Campo	32,0	50,3	31,6	55,2	42,3
$\omega_6$ ) Floresta	59,3	67,2	85,0	82,3	73,5
$\omega_7$ ) Solo Exposto	60,7	62,6	55,0	6,4	46,2
Média	62,2	54,4	58,2	57,3	58,0
Global	55,1	55,2	59,8	68,9	59,7

Tabela 6 – Avaliação da classificação utilizando apenas o conhecimento espectral a partir da distância de Mahalanobis com seleção manual do conjunto de treinamento.

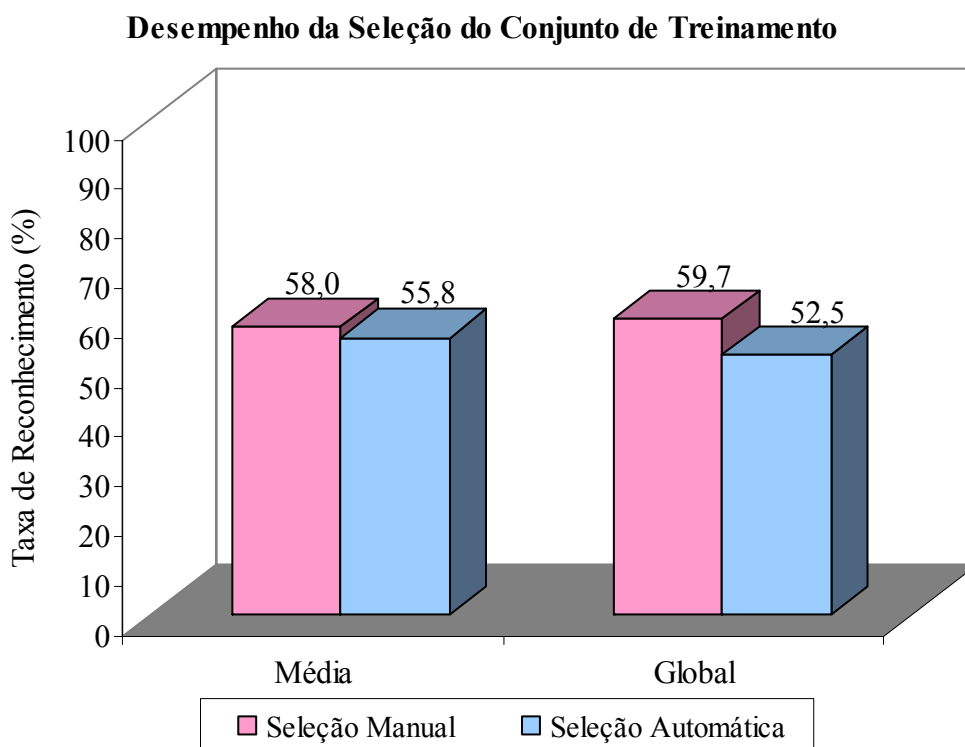


Figura 33 – Desempenho do classificador de Mahalanobis puramente espectral utilizando seleção manual e automática dos conjuntos de treinamento.

Para se ter idéia da eficiência das formas de seleção dos conjuntos de treinamento, foi realizado um experimento com o classificador de Mahalanobis para cada um dos métodos de seleção. Neste tipo de experimento, foram utilizadas

as imagens referentes aos anos de 1988 a 1999. A figura 33 apresenta um resumo dos resultados obtidos a partir destes experimentos expresso pela taxa média e taxa global de reconhecimento. Os dados deste gráfico referem-se ao desempenho médio das classificações ano a ano. Os resultados completos da classificação com seleção automática do conjunto de treinamento encontram-se no apêndice I.

Observa-se que a seleção automática do conjunto de treinamento produziu resultados ligeiramente inferiores à seleção manual. Contudo, o desempenho do método automático de seleção está suficientemente próximo ao da seleção manual, considerando a finalidade a que se destina. Além de tornar este processo mais rápido, a seleção automática poupa o especialista da exaustiva tarefa de pré-classificar um conjunto de objetos para cada classe. Por isso, os resultados apresentados no restante do trabalho baseiam-se na escolha automática do conjunto de treinamento para a classificação espectral.

### 5.3.2.

#### **Classificação empregando conhecimentos espectral e multitemporal**

Nesta seção, serão apresentados os experimentos realizados para avaliar o ajuste automático das possibilidades de transição de acordo com a metodologia proposta neste trabalho através de algoritmos genéticos.

A figura 34 ilustra como os experimentos, utilizando conhecimento multitemporal ajustado por algoritmos genéticos, foram realizados. Primeiramente, o ajuste do conhecimento multitemporal é feito baseado na interpretação de uma imagem obtida num instante  $t_1$  e na interpretação (classificação de referência) desta mesma cena num instante  $t_1 - \Delta_1 t$ . Como resultado do ajuste, tem-se a matriz relacional, que representa o conhecimento multitemporal para um intervalo de tempo  $\Delta_1 t$ . Então, para avaliar os valores de possibilidades obtidos, uma outra imagem em um instante  $t_2$  é interpretada utilizando uma informação multitemporal num instante  $t_2 - \Delta_2 t$ , onde  $\Delta_2 t$  é múltiplo de  $\Delta_1 t$ . Neste caso, o conhecimento multitemporal com intervalo de tempo  $\Delta_2 t$  utilizado na interpretação da imagem em  $t_2$  é inferido a partir do conhecimento multitemporal com intervalo de tempo  $\Delta_1 t$ . Esta inferência está descrita na seção 3.5.5.

Algoritmos genéticos são estocásticos, por isso os valores encontrados podem variar de execução para execução. Portanto, para cada conjunto de dados utilizado no processo de avaliação dos valores candidatos à solução, o método foi executado vinte vezes.

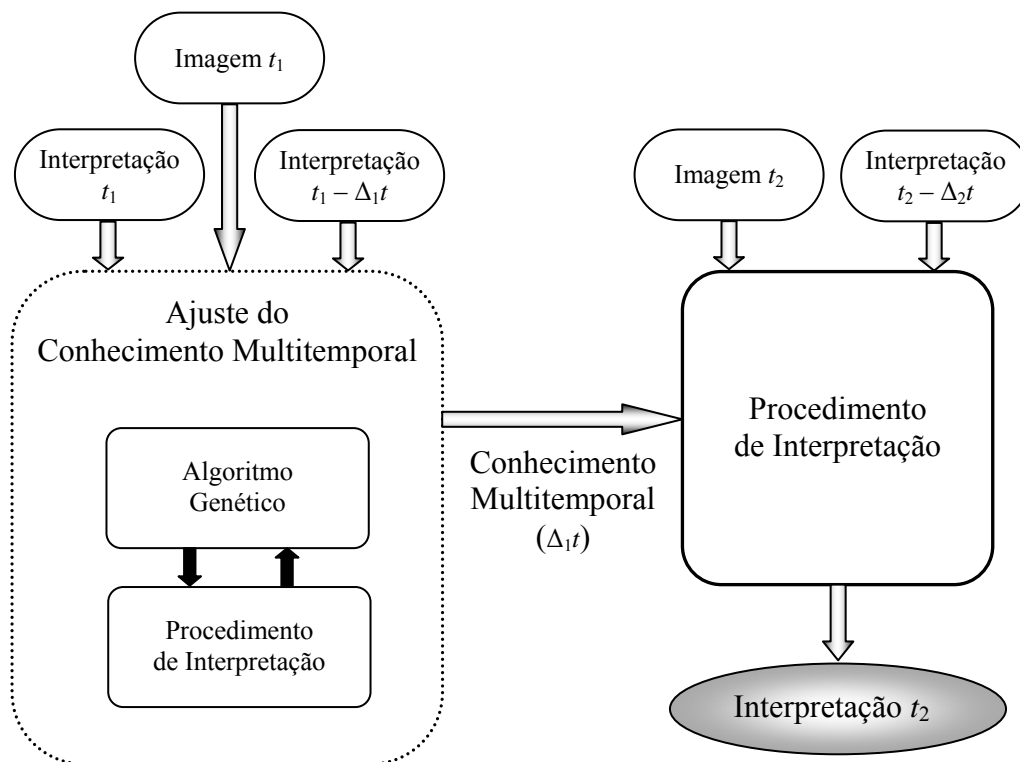


Figura 34 – Procedimento de interpretação utilizando o conhecimento multitemporal ajustado por algoritmo genético.

### 5.3.2.1.

#### Contribuição do conhecimento multitemporal em termos de transições possíveis e impossíveis.

O tipo de experimento desta seção avalia o uso de diagramas de transição de estados no sentido proposto por Pakzad et al. (2003). Neste caso, a todas as transições possíveis é atribuído o valor “1” e às demais, as transições impossíveis de ocorrerem no intervalo de tempo determinado, é atribuído o valor “0”. Este é o caso em que o conhecimento multitemporal reduz tão somente o espaço de busca do problema. Neste trabalho, este conhecimento multitemporal é referenciado como “crisp”.




Figura 35 – Comparação das taxas de reconhecimento média dos anos de 1988 a 1999 pelas classificações utilizando apenas o conhecimento espectral e utilizando os conhecimentos espectral e multitemporal crisp.

A figura 35 mostra um gráfico comparativo das taxas de reconhecimento da interpretação utilizando apenas o conhecimento espectral, usando o classificador por distância de Mahalanobis, e a interpretação baseada em conhecimento espectral e multitemporal com  $\Delta t \equiv 4$  anos. As taxas de reconhecimento apresentadas, neste gráfico, são resultado da média aritmética das interpretações das imagens referentes aos anos de 1988, 1992, 1996 e 1999. Neste caso, a imagem de 1984 não foi incluída devido a não disponibilidade de sua respectiva classificação anterior. Os resultados obtidos por ano encontram-se no apêndice II (tabela 20).

Este gráfico ilustra claramente o ganho de desempenho obtido graças à inclusão do conhecimento multitemporal no processo de interpretação. As duas primeiras classes (afloramento rochoso e água), por exemplo, puderam ser totalmente identificadas de forma correta. Isto porque o conhecimento

multitemporal (figura 32), neste caso, restringe ambas as classes. Uma vez que um objeto é atribuído a uma destas classes, ele deverá continuar pertencendo a mesma classe, além disso, nenhum objeto atribuído a outra classe poderá mudar para uma destas. Observando, ainda, a figura 35 nota-se que, com exceção da classe solo exposto, em todas as classes, a taxa de reconhecimento teve um aumento significativo. As taxas de reconhecimento média por classe e global aumentaram em 20,4% e 25,8%, respectivamente.

Estes resultados já demonstram os benefícios do uso de conhecimento multitemporal. As próximas seções tratam dos experimentos que utilizam valores nebulosos para as possibilidades de transição no modelo do conhecimento multitemporal.

### **5.3.2.2. Contribuição do conhecimento multitemporal com valores nebulosos de possibilidade de transição**

Esta seção avalia o uso de valores nebulosos para as possibilidades de transição. Diferentemente do conhecimento multitemporal crisp apresentado anteriormente, os valores de possibilidade empregados nas próximas seções admitem valores contínuos. O conhecimento multitemporal, neste caso, é referenciado, neste trabalho, como nebuloso. Quando não houver no texto a especificação do tipo de conhecimento multitemporal empregado, este estará relacionado ao caso nebuloso. Os resultados, aqui apresentados, referem-se aos obtidos ao aplicar o conhecimento multitemporal nebuloso ajustado pelo método apresentado.

Conforme mencionado anteriormente, para cada conjunto de dados utilizado na fase de aquisição do conhecimento multitemporal, o método foi executado vinte vezes. Isto resultou em vinte conjuntos de valores de possibilidades. Cada um destes vinte conjuntos de valores foi aplicado no conhecimento multitemporal na fase de interpretação de uma imagem cujos dados não foram utilizados na primeira fase. Desta forma, as próximas seções mostrarão apenas um resumo dos resultados obtidos. Mais detalhes sobre estes resultados são encontrados no apêndice III.

### 5.3.2.2.1. Estimando possibilidades a partir de intervalos de 4 anos

O experimento considerado nesta seção diz respeito às possibilidades de transição num intervalo de tempo de 4 anos. Ambos os conhecimentos multitemporais, o ajustado pelo AG e o utilizado na interpretação de teste, correspondem a um intervalo de tempo de quatro anos.

Interpretação	Ajuste
1984-1988	1992-1996
	1996-1999
1988-1992	1984-1988
	1996-1999
1992-1996	1984-1988
	1988-1992
1996-1999	1984-1988
	1988-1992
	1992-1996

Tabela 7 – Datas dos conjuntos de dados utilizados nos experimentos de ajuste do conhecimento multitemporal com intervalo de quatro anos.

A tabela 7 indica os dados utilizados nos experimentos relacionados a esta seção. A primeira coluna indica o par de datas dos dados utilizados para a interpretação de teste, enquanto a segunda apresenta os pares de datas dos dados utilizados na fase de ajuste do conhecimento multitemporal. Em cada par de datas, a segunda refere-se à imagem cuja interpretação é efetuada e a primeira corresponde à data da informação multitemporal.

A tabela 8 apresenta, para cada imagem de teste, além dos resultados das interpretações cujo conhecimento multitemporal é crisp, as médias das taxas de reconhecimento de todos os experimentos efetuados com o conhecimento multitemporal nebuloso. Com relação às colunas correspondentes as taxas de reconhecimento, a primeira linha indica os dois anos cujos dados foram utilizados no procedimento de interpretação. O primeiro ano refere-se à interpretação de referência utilizada como informação multitemporal para classificação da imagem

correspondente ao segundo ano. A última coluna corresponde à média dos resultados encontrados nas demais.

Classe	Conhecimento	1984	1988	1992	1996	Geral
	Multitemporal	- 1988	- 1992	- 1996	- 1999	
ω <sub>1</sub> ) Afl. Rochoso	crisp	100,0	100,0	100,0	100,0	100,0
	nebuloso	100,0	100,0	100,0	100,0	100,0
ω <sub>2</sub> ) Água	crisp	100,0	100,0	100,0	100,0	100,0
	nebuloso	100,0	100,0	100,0	100,0	100,0
ω <sub>3</sub> ) Área Úmida	crisp	27,3	38,6	26,1	60,9	38,2
	nebuloso	50,1	61,1	63,2	56,4	57,7
ω <sub>4</sub> ) Área Urbana	crisp	95,3	93,3	86,8	92,4	91,9
	nebuloso	88,4	86,5	93,0	92,5	90,1
ω <sub>5</sub> ) Campo	crisp	71,8	77,5	67,2	69,4	71,5
	nebuloso	89,1	86,6	84,4	91,9	88,0
ω <sub>6</sub> ) Floresta	crisp	72,1	73,9	85,8	87,9	80,0
	nebuloso	94,8	96,1	90,8	87,2	92,2
ω <sub>7</sub> ) Solo Exposto	crisp	60,7	70,3	68,3	8,5	52,0
	nebuloso	65,3	57,6	54,0	84,9	65,4
Média	crisp	75,3	79,1	76,3	74,2	76,2
	nebuloso	83,9	84,0	83,6	87,6	84,8
Global	crisp	74,8	78,2	78,3	81,9	78,3
	nebuloso	87,8	87,7	87,0	87,8	87,6

Tabela 8 – Desempenho das interpretações com conhecimento multitemporal de quatro anos empregando os valores de possibilidade crisp e os valores nebulosos ajustados por algoritmos genéticos.

Observando a tabela 8, nota-se que, na maioria das taxas de reconhecimento, o uso do conhecimento multitemporal nebuloso aumenta o desempenho do procedimento de interpretação.

O gráfico ilustrado na figura 36, apresenta uma comparação entre o uso do conhecimento multitemporal crisp e nebuloso através das taxas médias de



reconhecimento. Estas taxas correspondem aos dados encontrados na linha da tabela 8 denominada “média”.




Figura 36 – Gráfico comparativo dos desempenhos das interpretações com conhecimento multitemporal para intervalo de quatro anos empregando os valores de possibilidade crisp e os valores de possibilidades nebulosas ajustados por algoritmos genéticos.

Nota-se claramente neste gráfico que, em todos os casos apresentados, o uso do conhecimento multitemporal nebuloso proporciona uma importante melhora na acurácia da interpretação comparado com o uso do crisp. A taxa média de reconhecimento aumentou entre 4,9% (1988-1992) e 13,4% (1996-1999), tendo um aumento médio de 8,6%.

Como o algoritmo genético foi executado vinte vezes para cada experimento, na tabela 9 são apresentados os resultados do uso do conhecimento multitemporal nebuloso identificados como “pior caso”, “média” e “melhor caso”. O critério de desempenho usado para identificar estes casos é a taxa média de reconhecimento por classe. Sendo assim, o pior caso apresenta a média dos resultados por ano onde a taxa média de reconhecimento é inferior às demais. Neste sentido, o melhor caso refere-se ao melhor resultado obtido. A coluna identificada como média, apresenta a média aritmética de todos os experimentos.

Nesta tabela, são apresentadas novamente as taxas médias de reconhecimento da classificação cujo conhecimento multitemporal é crisp.

Classes	Puramente Espectral	Com conhecimento multitemporal crisp	Com conhecimento multitemporal nebuloso ajustado por AG		
			pior caso	média	melhor caso
$\omega_1$ ) Afl. Rochoso	83,3	100,0	100,0	100,0	100,0
$\omega_2$ ) Água	60,2	100,0	100,0	100,0	100,0
$\omega_3$ ) Área Úmida	23,4	38,2	53,9	56,8	58,8
$\omega_4$ ) Área Urbana	58,2	91,9	89,8	89,9	89,9
$\omega_5$ ) Campo	26,3	71,5	88,2	88,1	88,2
$\omega_6$ ) Floresta	66,5	80,0	92,3	92,5	93,0
$\omega_7$ ) Solo Exposto	73,0	52,0	63,1	65,4	69,2
Média	55,8	76,2	83,9	84,7	85,6
Global	52,5	78,3	87,2	87,6	88,0

Tabela 9 – Desempenho das interpretações com conhecimento multitemporal de quatro anos empregando os valores de possibilidade ajustados por algoritmos genéticos.

Analisando o desempenho por classe, observa-se que a única classe em que houve queda na taxa de reconhecimento, mas ainda assim modesta, é a classe área urbana. A interpretação das duas primeiras classes (afloramento rochoso e água) continua com o mesmo desempenho em todos os casos, pois estas não sofrem mudança dentro do intervalo de tempo determinado e, então, o conhecimento multitemporal crisp é suficiente para identificá-las corretamente. Para as demais classes, o desempenho da interpretação tem um aumento importante ao utilizar o conhecimento multitemporal nebuloso. Entre estas, a classe cujo ganho de desempenho foi menor, no pior caso, refere-se ao solo exposto com 11,2 %. No melhor caso, obteve-se um ganho de 20,6 % no desempenho da interpretação da classe área úmida. Nota-se, portanto, que o método proposto contribui com um aumento importante na acurácia da interpretação de imagens de sensores remotos.

Os resultados revelam também que a diferença por classe entre o pior e o melhor caso é pequena, indicando que os resultados apresentados pelo método proposto são estáveis.

### 5.3.2.2. Estimando possibilidades a partir de intervalos superiores a 4 anos

Outro tipo de experimento realizado avalia a contribuição do conhecimento multitemporal para intervalos de tempo maiores do que 4 anos entre as datas consideradas. Neste caso, para cada experimento, o conhecimento multitemporal utilizado tanto na fase de ajuste dos valores de possibilidade como na fase de teste possui o mesmo intervalo de tempo. A tabela 10 indica os dados utilizados nos experimentos relacionados a esta seção.

Interpretação	Ajuste
1984-1992	1988-1996
1988-1996	1984-1992 1992-1999
1992-1999	1984-1992 1988-1996
1984-1996	1988-1999
1988-1999	1984-1996

Tabela 10 – Datas dos conjuntos de dados utilizados nos experimentos de ajuste do conhecimento multitemporal com intervalos de tempo superiores a quatro anos.

A tabela 11 apresenta os resultados obtidos através deste tipo de experimento e o resultado médio da classificação utilizando conhecimento multitemporal com intervalo de tempo de 4 anos. Nesta tabela, os dados são resultantes da média das taxas de reconhecimento dos respectivos experimentos.

Classes	Puramente Espectral	Com conhecimento multitemporal nebuloso		
		$\Delta t = 4$ anos	$\Delta t = 8$ anos	$\Delta t = 12$ anos
$\omega_1$ ) Afl. Rochoso	83,3	100,0	100,0	100,0
$\omega_2$ ) Água	60,2	100,0	100,0	100,0
$\omega_3$ ) Área Úmida	23,4	56,8	57,1	54,1
$\omega_4$ ) Área Urbana	58,2	89,9	80,6	78,3
$\omega_5$ ) Campo	26,3	88,1	82,0	75,7
$\omega_6$ ) Floresta	66,5	92,5	92,4	92,1
$\omega_7$ ) Solo Exposto	73,0	65,4	58,8	46,2
Média	55,8	84,7	81,6	78,1
Global	52,5	87,6	83,2	80,5

Tabela 11 – Desempenho por classe em função do intervalo de tempo do conhecimento multitemporal utilizado no procedimento de interpretação.




Figura 37 – Gráfico de desempenho por classe em função do intervalo de tempo que separa a informação multitemporal da imagem a ser classificada.

O gráfico da figura 37 ilustra uma comparação entre as taxas médias de reconhecimento da classificação puramente espectral e das classificações apresentadas na tabela 11. Através dele, observa-se que o aumento do intervalo de tempo traz, em geral, uma redução na acurácia da interpretação. Este resultado não surpreende. Intuitivamente é de se esperar que a informação da classificação mais recente tenha mais impacto sobre a classificação de uma imagem atual do que a informação de uma classificação mais remota no passado. Contudo, nota-se que, ao comparar com a classificação puramente espectral, mesmo usando uma informação multitemporal relativamente remota, o conhecimento multitemporal contribui com um aumento importante na acurácia da interpretação.

### 5.3.2.2.3. Estimando possibilidades a partir de mais de um par de datas

Outro conjunto de experimentos visou avaliar o impacto de utilizar mais de um par de datas (data da informação multitemporal e da imagem a ser interpretada) separadas por um mesmo intervalo de tempo como base para estimar as possibilidades de transição. A tabela 12 apresenta os dados utilizados nos experimentos relacionados a esta seção.

Interpretação	Ajuste
1984-1988	1992-1996 / 1996-1999
1988-1992	1984-1988 / 1996-1999
1992-1996	1984-1988 / 1988-1992
	1984-1988 / 1988-1992
1996-1999	1984-1988 / 1992-1996
	1988-1996 / 1992 -1996

Tabela 12 – Datas dos conjuntos de dados utilizados nos experimentos de ajuste do conhecimento multitemporal com intervalo de tempo de quatro anos a partir de dois pares de datas.

A tabela 13 e a figura 38 mostram os valores médios das taxas de reconhecimento por classe obtidos em todos os experimentos realizados desta seção.

Classes	Um par de datas	Dois pares de datas
$\omega_1$ ) Afl. Rochoso	100,0	100,0
$\omega_2$ ) Água	100,0	100,0
$\omega_3$ ) Área Úmida	56,8	62,0
$\omega_4$ ) Área Urbana	89,9	90,3
$\omega_5$ ) Campo	88,1	86,8
$\omega_6$ ) Floresta	92,5	94,0
$\omega_7$ ) Solo Exposto	65,4	57,6
Média	84,7	84,4
Global	87,6	88,1

Tabela 13 – Desempenho das interpretações com conhecimento multitemporal para um intervalo de quatro anos considerando dados de um e dois pares de datas para estimar possibilidades de transição.

**Desempenho utilizando dados de um e dois pares de datas na estimativa das possibilidade de transição**

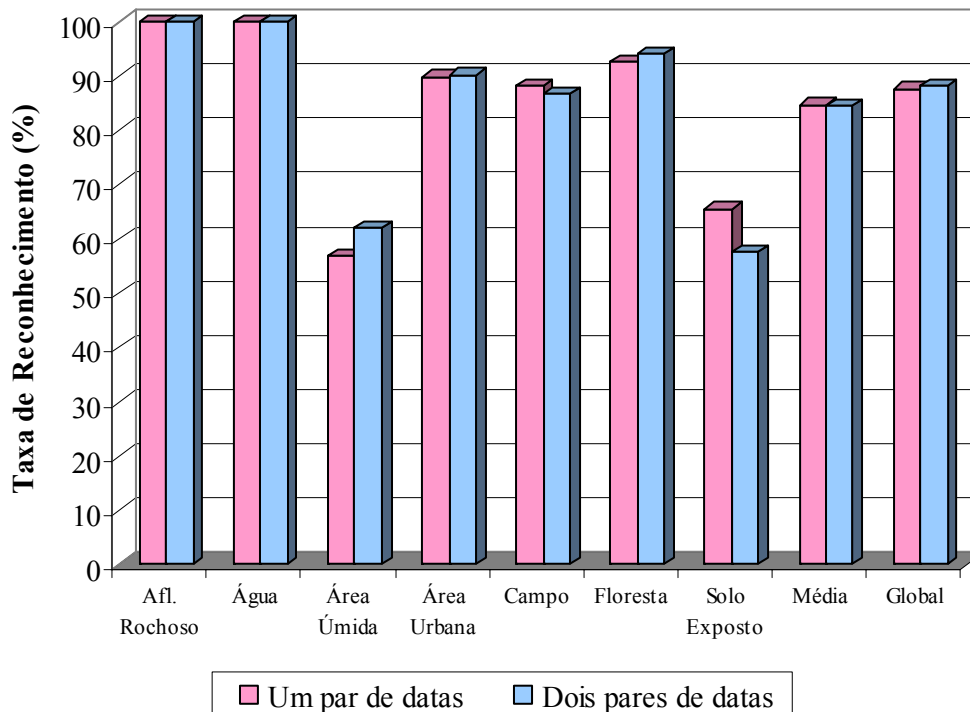


Figura 38 – Gráfico comparativo do desempenho utilizando dados de um e dois pares de datas na fase de estimativa das possibilidades de transição.

Nota-se, a partir deste tipo de experimento, que algumas classes tiveram um ganho na acurácia, enquanto outras perderam ao usar dois pares de datas. A taxa média de desempenho diminuiu apesar de ter sido em apenas 0,3%. Já a taxa global teve um ganho, quando comparada com o uso de apenas um par de datas. Contudo, neste caso, o ganho também não é de grande significância (0,5%).

A pouca alteração que se observou ao se utilizar dados de um ou dois pares de datas pode ser entendido como o efeito de dois fatores concomitantes.

O primeiro fator é a variação das possibilidades de transição ao longo do tempo. Em outras palavras, é possível que a dinâmica das classes no período decorrido no primeiro par de datas não seja a mesma do período definido pelo segundo par de datas. Nesta hipótese, o par de datas mais distante da imagem que se deseja classificar proveria informação menos atual e, portanto, menos confiável para se basear a estimativa das possibilidades. A inclusão dos dados do par de datas mais remotas seria, sob este ponto de vista, negativo para o desempenho do classificador.

O segundo fator, este positivo, é que ao lançar mão de um segundo par de datas haveria mais dados de treinamento disponíveis, o que poderá compensar o número reduzido de certas transições de classe nos dados oriundos de um único par de datas. Isso contribuiria para melhorar as estimativas das possibilidades de transição.

É difícil, contudo, conjecturar como cada um destes dois fatores afeta o desempenho. Os resultados apresentados nesta seção parecem indicar que eles praticamente se compensaram nos experimentos realizados.

#### **5.3.2.2.4. Estimando possibilidades para intervalos maiores**

Um conjunto de experimentos foi realizado com o objetivo de avaliar a proposta apresentada na seção 3.5.5, que permite estimar possibilidades de transição para intervalos múltiplos de  $\Delta t$ , baseando-se nos valores estimados para  $\Delta t$ . A tabela 14 apresenta os dados utilizados nos experimentos relacionados a esta seção.

Interpretação	Ajuste
1984-1992 ( $\Delta_2t = 8$ anos)	1984-1988 ( $\Delta_1t = 4$ anos) 1996-1999 ( $\Delta_1t = 4$ anos)
1988-1996 ( $\Delta_2t = 8$ anos)	1984-1988 ( $\Delta_1t = 4$ anos) 1988-1992 ( $\Delta_1t = 4$ anos)
1992-1999 ( $\Delta_2t = 8$ anos)	1984-1988 ( $\Delta_1t = 4$ anos) 1988-1992 ( $\Delta_1t = 4$ anos) 1992-1996 ( $\Delta_1t = 4$ anos)
1984-1996 ( $\Delta_2t = 12$ anos)	1984-1988 ( $\Delta_1t = 4$ anos) 1988-1992 ( $\Delta_1t = 4$ anos)
1988-1999 ( $\Delta_2t = 12$ anos)	1984-1988 ( $\Delta_1t = 4$ anos) 1988-1992 ( $\Delta_1t = 4$ anos) 1992-1996 ( $\Delta_1t = 4$ anos)
1984-1999 ( $\Delta_2t = 16$ anos)	1984-1988 ( $\Delta_1t = 4$ anos) 1988-1992 ( $\Delta_1t = 4$ anos) 1992-1996 ( $\Delta_1t = 4$ anos) 1984-1992 ( $\Delta_1t = 8$ anos) 1988-1996 ( $\Delta_1t = 8$ anos)

Tabela 14 – Datas dos conjuntos de dados utilizados nos experimentos de aquisição do conhecimento multitemporal para intervalos de tempo superiores do conjunto de dados de ajuste.

O resumo dos resultados obtidos está representado no gráfico da figura 25.

Nota-se que, neste experimento, o desempenho do processo de interpretação diminui ao se utilizar conhecimento multitemporal inferido de outro com intervalo de tempo menor. Ainda assim, observa-se que, se comparado com uma classificação puramente espectral, o uso do conhecimento multitemporal descrito contribui amplamente para o aumento da acurácia da interpretação. Neste contexto, a partir dos experimentos realizados, as taxas de reconhecimento média e global aumentaram aproximadamente em 23,8 % e 27,7 %, respectivamente.



**Desempenho do Ajuste das Possibilidades de  
Transição a Partir de Conhecimento Multitemporal  
com Intervalo de Tempo Diferente do Definido**

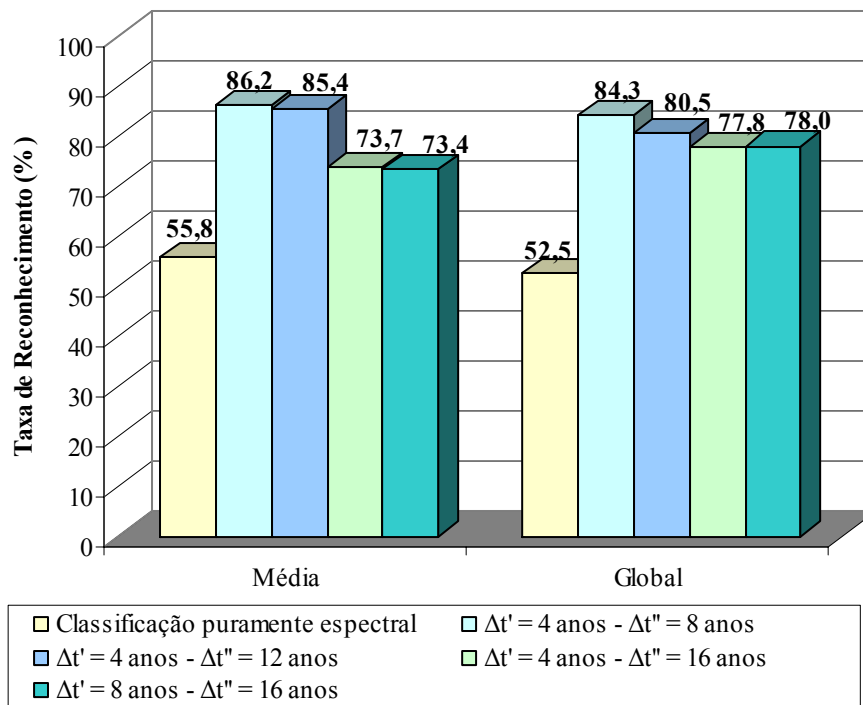


Figura 39 – Desempenho utilizando conhecimento multitemporal inferido a partir de um outro com intervalo de tempo menor.

### 5.3.3. Desempenho do algoritmo genético sob a busca aleatória

Um meio bastante utilizado para avaliar o uso de algoritmo genético em problemas de busca e otimização é fazendo uma comparação deste com o método de busca aleatória. Neste último caso, são geradas soluções um número de vezes igual ao número total de indivíduos gerados pelo algoritmo genético até o fim de uma execução.

Neste trabalho, em cada execução do algoritmo genético foram gerados 10000 indivíduos (100 indivíduos na população x 100 gerações). Desta forma, foram geradas aleatoriamente 10000 soluções ou conjuntos de valores de possibilidade de transição. A tabela 15 mostra o resultado deste experimento através da média da taxa de reconhecimento de cada classe. A figura 40 apresenta estes dados por meio de um gráfico.

Classes	Busca Aleatória	Busca por AG
$\omega_1$ ) Afl. Rochoso	100,0	100,0
$\omega_2$ ) Água	100,0	100,0
$\omega_3$ ) Área Úmida	42,0	57,7
$\omega_4$ ) Área Urbana	84,1	90,1
$\omega_5$ ) Campo	68,9	88,0
$\omega_6$ ) Floresta	76,3	92,2
$\omega_7$ ) Solo Exposto	63,7	65,4
Média	76,4	84,8
Global	78,6	87,6

Tabela 15 – Desempenho das interpretações utilizando valores de possibilidade de transição encontrados por algoritmos genéticos e busca aleatória.

Desempenho de Busca Aleatória vs. Busca por AG

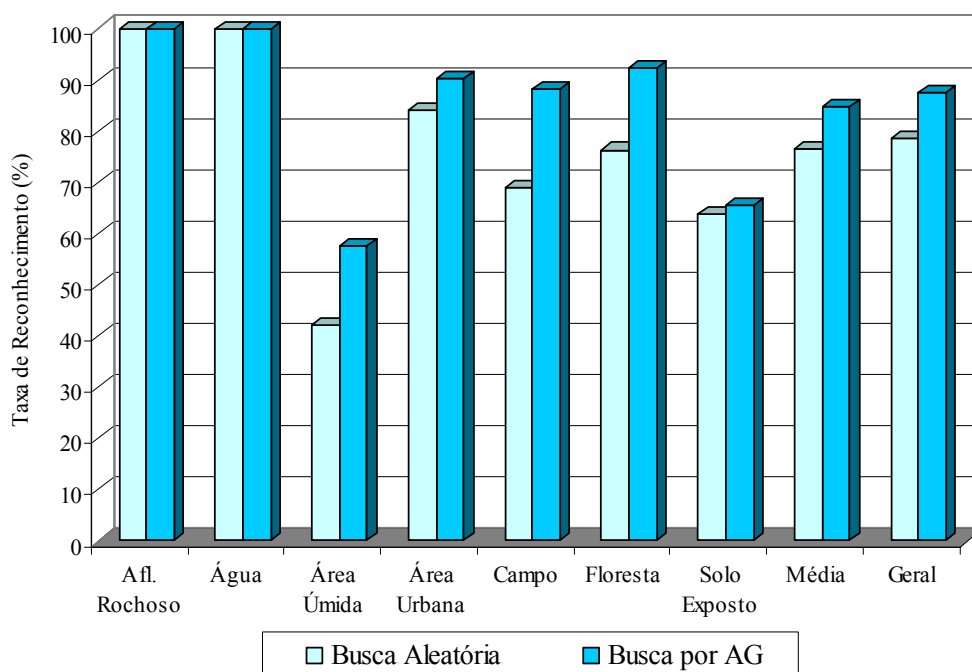


Figura 40 – Gráfico comparativo do desempenho das interpretações utilizando valores de possibilidade de transição encontrados por algoritmos genéticos e busca aleatória.

Nota-se que em todas as classes, a busca dos valores de possibilidade de transição utilizando AG obteve um desempenho superior à simples busca aleatória.

Além de ressaltar a eficiência do uso de AG, o resultado deste experimento mostra a dificuldade em se obter estes valores manualmente através de tentativa-e-erro.

#### **5.3.4. Convergência do algoritmo genético**

Em cada execução de algoritmos genéticos, a população que constitui a primeira geração é usualmente gerada aleatoriamente, pois, na maioria dos casos, não se conhece o comportamento dos valores a serem encontrados. Por isto, a população inicial é composta por indivíduos bastante diversificados. Nas gerações seguintes, a população é gerada basicamente a partir da reprodução dos indivíduos da população anterior privilegiando os julgados mais aptos. Sendo assim, a população tende a evoluir para uma solução singular. Quando a população consiste basicamente de indivíduos similares, é dito que a solução convergiu.

A performance de algoritmos genéticos é freqüentemente analisada a partir de um gráfico de desempenho. Este gráfico é gerado da seguinte forma:

- O algoritmo genético é executado  $N$  vezes ( $N$  é um número inteiro suficiente para se ter um conjunto representativo dos dados);
- Em cada geração é armazenada a avaliação do melhor indivíduo da população;
- Calcula-se a média aritmética das avaliações de todas as execuções por geração e, então, o gráfico é produzido com base nestas médias.

A figura 41 contém o gráfico de desempenho médio através de 20 execuções dos experimentos descritos na seção 5.3.2.2.1. O eixo- $x$  do gráfico indica o número de gerações limitado em 100 e o eixo- $y$  indica a avaliação média do melhor indivíduo da população da respectiva geração. Observa-se, neste gráfico, que a solução converge em torno de noventa gerações. Portanto, pode-se concluir que, nesta aplicação, cem gerações são suficientes para se obter a solução desejada.

### Gráfico de Desempenho da Metodologia de Ajuste do Conhecimento Multitemporal




Figura 41 – Gráfico de desempenho de algoritmos genéticos para o ajuste de valores do conhecimento multitemporal para interpretação de imagens de sensores remotos.

#### 5.3.5.

#### **Análise de estabilidade dos valores de possibilidade de transição produzidos**

Devido, ao fato de que o método descrito para ajuste de conhecimento multitemporal pode apresentar um conjunto de valores de possibilidade diferentes em execuções diferentes, mesmo sob os mesmos aspectos (dados de entrada e parâmetros do AG), esta seção tem a finalidade de analisar a estabilidade destes conjuntos. Os valores de possibilidade de transição discutidos, nesta seção, referem-se ao conhecimento multitemporal com intervalo de tempo de quatro anos. Neste caso, são estimados os valores das possibilidades de transição indicadas na tabela a seguir:

A tabela 17 mostra um resumo dos resultados destes experimentos expresso pela média aritmética e pelo desvio padrão dos valores de possibilidades encontrados.

<b>Rótulos das possibilidades de transição</b>	<b>Transição entre classes</b>	<b>Classificação em <math>t - \Delta t</math></b>	<b>Classificação em <math>t</math></b>
$p_{34}$	$\omega_3 \rightarrow \omega_4$	Área úmida	Área urbana
$p_{35}$	$\omega_3 \rightarrow \omega_5$	Área úmida	Campo
$p_{37}$	$\omega_3 \rightarrow \omega_7$	Área úmida	Solo exposto
$p_{53}$	$\omega_5 \rightarrow \omega_3$	Campo	Área úmida
$p_{54}$	$\omega_5 \rightarrow \omega_4$	Campo	Área urbana
$p_{57}$	$\omega_5 \rightarrow \omega_7$	Campo	Solo exposto
$p_{64}$	$\omega_6 \rightarrow \omega_4$	Floresta	Área urbana
$p_{65}$	$\omega_6 \rightarrow \omega_5$	Floresta	Campo
$p_{67}$	$\omega_6 \rightarrow \omega_7$	Floresta	Solo exposto
$p_{74}$	$\omega_7 \rightarrow \omega_4$	Solo exposto	Área urbana
$p_{75}$	$\omega_7 \rightarrow \omega_5$	Solo exposto	Campo

Tabela 16 – Transições cujos valores de possibilidades devem ser ajustados por algoritmos genéticos.

Os valores de possibilidades encontrados a partir de outros tipos de experimentos – como o uso de mais de um par de imagens e ajuste de conhecimento multitemporal com intervalo de tempo de oito e doze anos – apresentaram, em geral, o mesmo comportamento dos valores apresentados na tabela 17. Portanto, todos os valores de possibilidades encontrados estão apenas no apêndice IV. Uma discussão sobre eles é o mesmo apresentado nesta seção.

A última coluna da tabela 17, denominada “conjunto”, refere-se ao conjunto de valores encontrados em todos os experimentos indicados nas demais colunas. As linhas referentes a “Av.” desta tabela correspondem à avaliação dos valores de possibilidade indicados pelo AG. Esta avaliação equivale à taxa média de reconhecimento adquirida ao empregar os valores de possibilidades encontrados na interpretação da mesma imagem e informação multitemporal utilizados pelo AG.

possibilidades de transição	datas usadas para a estimativa					
	1984-1988	1988-1992	1992-1996	1996-1999	conjunto	
<i>p</i> <sub>34</sub>	média	0,100	0,008	0,091	0,060	0,065
	desvio	0,060	0,008	0,010	0,009	0,047
<i>p</i> <sub>35</sub>	média	0,446	0,043	0,037	0,048	0,144
	desvio	0,024	0,045	0,022	0,032	0,178
<i>p</i> <sub>37</sub>	média	0,700	0,030	0,006	0,031	0,192
	desvio	0,025	0,033	0,004	0,004	0,296
<i>p</i> <sub>53</sub>	média	0,034	0,059	0,054	0,052	0,050
	desvio	0,008	0,014	0,041	0,003	0,023
<i>p</i> <sub>54</sub>	média	0,040	0,031	0,316	0,047	0,109
	desvio	0,013	0,021	0,097	0,008	0,131
<i>p</i> <sub>57</sub>	média	0,067	0,123	0,080	0,152	0,105
	desvio	0,016	0,010	0,024	0,006	0,038
<i>p</i> <sub>64</sub>	média	0,016	0,021	0,067	0,037	0,035
	desvio	0,010	0,011	0,027	0,007	0,025
<i>p</i> <sub>65</sub>	média	0,006	0,011	0,105	0,090	0,053
	desvio	0,003	0,005	0,010	0,004	0,046
<i>p</i> <sub>67</sub>	média	0,193	0,095	0,024	0,088	0,100
	desvio	0,141	0,059	0,014	0,038	0,099
<i>p</i> <sub>74</sub>	média	0,039	0,048	0,029	0,022	0,034
	desvio	0,017	0,018	0,029	0,009	0,022
<i>p</i> <sub>75</sub>	média	0,127	0,126	0,012	0,014	0,070
	desvio	0,029	0,043	0,009	0,007	0,063
Av.	média	97,0	96,0	95,6	94,8	95,8
	desvio	0,1	0,1	0,0	0,0	0,8

Tabela 17 – Resumo dos valores de possibilidade obtidos ajustados através de algoritmos genéticos para conhecimento multitemporal de quatro anos.

Neste trabalho, um desvio padrão de um conjunto de valores para uma possibilidade é considerado alto quando for superior a 0,050.

Observando a tabela 17, nota-se que, em geral, os valores convergiram para uma solução semelhante, pois o desvio padrão da maioria dos valores de possibilidade encontrados é pequeno.

Os valores de possibilidades cujo desvio padrão encontrado é alto, correspondem a casos de máximo local. Isto pode ser verificado ao observar as avaliações dos conjuntos de valores nas últimas linhas da tabela. Nota-se que a avaliação para cada par de datas usado para estimativa dos valores é estável ao longo das execuções.

Conclui-se, a partir destes dados, que um desvio padrão alto nos valores de possibilidade de transição não implica em uma variação importante no desempenho da interpretação e, portanto, o método apresentado é estável.