



MINISTÉRIO DA CIÊNCIA E TECNOLOGIA
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

INPE-10104-TDI/895

**SEGMENTAÇÃO DE IMAGEM MULTIESPECTRAL
UTILIZANDO-SE O ATRIBUTO MATIZ**

Roberto Pinto Souto

Dissertação de Mestrado do Curso da Pós-Graduação em Sensoriamento Remoto,
orientada pelo Dr. Luciano Vieira Dutra, aprovada em 29 de agosto de 2000.

528.711.7

SOUTO, R. P.

Segmentação de imagem multiespectral utilizando-se o atributo matiz / R. P. Souto. – São José dos Campos: INPE, 2000.

171p. – (INPE-10104-TDI/895).

1.Sensoriamento remoto. 2.Cores. 3.Classificação de imagem. 4.Análise estatística. 5.Programação. I.Título.

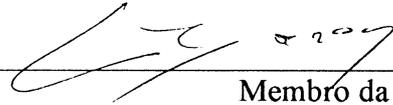
Aprovado pela Banca Examinadora em
cumprimento a requisito exigido para a
obtenção do Título de **Mestre** em
Sensoriamento Remoto

Dr. Luciano Vieira Dutra



Orientador/Presidente

Dr. Gerald Jean Francis Banon



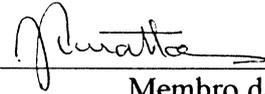
Membro da Banca

Dr. Dalton de Morisson Valeriano



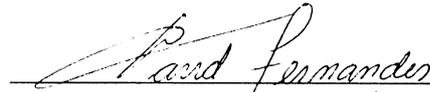
Membro da Banca

Dr. Juércio Tavares Mattos



Membro da Banca

Dr. David Fernandes



Membro da Banca
Convidado

Candidato: Roberto Pinto Souto

São José dos Campos, 29 de agosto de 2000.

In Memoriam
A meus avós Heitor Souto e Irondina Viajor Souto
Dedico este trabalho.

AGRADECIMENTOS

À minha família pela compreensão e apoio na minha escolha de seguir a trilha acadêmica.

Ao Dr. Luciano Vieira Dutra, pela contribuição dada com sua orientação neste trabalho.

Ao amigo Sidnei João Siqueira Sant'Anna pelos conselhos e inestimável ajuda dada na elaboração deste texto.

Aos colegas da turma de 1997 do Sensoriamento Remoto pelo companheirismo e amizade.

Aos pesquisadores do INPE Dr. João Roberto dos Santos, MSc. Madalena Niero, MSc. Pedro Hernandez Filho, MSc. Romeu Simi Jr. e Dr. Tomoyuki Ohara, que deram um grande auxílio na interpretação minuciosa das composições coloridas que lhes foram fornecidas.

Ao Dr. Dalton de Morisson Valeriano, pelos esclarecimentos dados quanto ao método de avaliação de mapas empregado, também quanto a explicações sobre a região de Tremembé analisada.

À Dra. Corina da Costa Freitas pelo auxílio na correção do texto referente à análise estatística.

Ao colega de mestrado Gil Mendes Sales pela idéia de incluir um cálculo de exatidão máxima requerida pelo usuário, de modo que uma classificação continue a ser aprovada.

À Etel pelo carinho, dedicação e atenção que ela dedica a todos os alunos da pós-graduação do SERE.

Aos funcionários da gráfica do INPE pela atenção e dedicação que prestam a quem precisa dos seus ótimos serviços.

A todos os amigos que tive a felicidade de fazer no INPE, que me ajudaram e muito a superar as dificuldades encontradas.

RESUMO

Este trabalho teve como objetivo, a implementação e avaliação de algoritmos de segmentação e classificação de imagens de matiz de composição colorida. Desejava-se averiguar o comportamento do matiz em regiões onde há diferenças na luminosidade em função da topografia do terreno em dois alvos: floresta e urbano. Neste aspecto, os resultados alcançados foram satisfatórios, pois o algoritmo implementado conseguiu resolver estes dois casos na maior parte das vezes. Normalmente as imagens coloridas são resultado de composições com três bandas espectrais. Implementou-se um método que é capaz de obter o valor de matiz diretamente de quaisquer N bandas espectrais. No entanto, nem sempre o acréscimo de bandas resultou em uma classificação melhor. Isto depende de quais bandas se escolhe a fim de gerar a imagem de matiz. Foram gerados resultados de classificação de matiz obtidos através de composições coloridas com três, quatro e cinco bandas espectrais. Avaliou-se também o comportamento do matiz nestas três composições, na distinção do alvo floresta em regiões de relevo muito acidentado, com presença forte de sombra. A avaliação, tanto para o alvo floresta quanto para o urbano, se deu através da comparação dos resultados de classificação com pontos de referência classificados previamente por fotointérpretes. Foi calculado de cada classificação, a partir dos pontos de referência, um coeficiente kappa. Os diversos kappas estimados encontrados foram comparados através de teste de hipótese para se verificar se havia diferenças significativas entre os resultados de classificação de matiz alcançados com três, quatro e cinco bandas. Notou-se que há um desempenho superior usando quatro bandas para distinguir alvo urbano, mas não foram percebidas diferenças significativas no alvo floresta. Mesmo procedimento foi feito para comparar estas classificações de matiz com o método de classificação não-supervisionada Isoseg, implementado no "software" SPRING. Na maior parte das vezes o resultado de matiz superou o Isoseg, havendo no entanto, para cinco bandas, resultados de classificação de Isoseg melhores que no matiz. Paralelamente a esta avaliação por coeficiente kappa, foram desenvolvidos algoritmos de avaliação automatizada dos erros de classificação, levando-se em consideração a distribuição estatística (binomial) destes erros. Basicamente, esta tarefa tem por finalidade saber se o tamanho da amostra de pontos escolhido é adequado. Isto é, se o produtor não corre risco demasiado ao coletar um tamanho pequeno de pontos para avaliar a classificação. Ou ainda se compensa o custo de coletar amostragem muito grande, para correr um risco menor de ver seu mapa rejeitado. Todos recursos de classificação e avaliação são acessados através de uma interface gráfica desenvolvida neste trabalho.

MULTISPECTRAL IMAGE SEGMENTATION USING THE HUE ATTRIBUTE

ABSTRACT

This work had as objective, the implementation and evaluation of segmentation algorithms and classification of hue images from color composit. It was desired to inquire the behavior of the hue in regions where it has differences in the luminosity due to the topography of the land in two targets: forest and urban. In this aspect, the reached results had been satisfactory, since the implemented algorithm obtained solved these two cases in the most part of the times. Normally the color images are resulted of composition with three spectral bands. A method was implemented that is able to directly get the value of hue of any N spectral bands. However, nor always the upgrade of bands mean a better classification. It will depend on which bands are chosen, in order to generate the hue image. Results had been generated by classification of hue through color composit of three, four and five spectral bands. The behavior of the hue in these three cases, the distinction of the white forest in relief regions, with a strong presence of shade was also evaluated. The evaluation, as much for the white forest as for the urban one, was made through the matching of the results of classification with control points classified previously by photointerpreters. It was calculated of each classification, from the control points, a coefficient kappa. Diverse kappas estimated found had been compared through hypothesis test to verify itself if it had significant differences between the results of reached classificaton of hue from three, four and five bands. It was noticed that it has an upper performance using four bands to distinguish urban target, but had not been perceived significant differences in the forest. Same procedure was made to compare these classificatons of hue with the method of unsupervised classifier Isoseg, implemented at SPRING software. At the most part of the times, hue results overcame Isoseg however. However, for five bands, there are better results of classification by Isoseg method. It had been developed algorithms of automatized evaluation of the errors of classification, taking in account the statistical distribution (binomial) of these errors. Basically, this task has as purpose to know if the size of the sample of points chosen is correct. That is, if the producer does not has too much risk when collecting a small size of points to evaluate the classification. Or, besides, if it compensates the cost to collect sampling very great, in order to have a lesser risk to see its map rejected wrongly. All features of classification and evaluation can be accessed through a graphical user interface developed in this work.

SUMÁRIO

Pág.

LISTA DE FIGURAS.....	
LISTA DE TABELAS.....	
CAPÍTULO 1 - INTRODUÇÃO.....	23
1.1. - Justificativa.....	25
1.2. - Objetivos.....	26
1.2.1. - Objetivos Específicos.....	26
1.3. - Área de estudo.....	26
CAPÍTULO 2 - FUNDAMENTAÇÃO TEÓRICA.....	29
2.1. - Sensores Orbitais.....	29
2.2. - Formação de Imagens.....	29
2.3. - Teoria de cores.....	33
2.3.1. - Espaço de Cores.....	37
2.3.1.1. - Espaço RGB.....	37
2.3.1.2. - Espaço XYZ - valores triestímulos.....	39
2.3.1.3. - Espaço de cores uniforme.....	41
2.3.2. - Espaço dos atributos de cores: matiz, saturação e intensidade.....	43
2.3.2.1. - Problemas inerentes aos atributos de cores.....	47
2.3.2.2. - Método de Moik.....	50
2.3.2.3. - Transformar atributos de cores em RGB.....	53
2.3.2.4. - Cálculo de valores médios do componente matiz.....	54
CAPÍTULO 3 - CLASSIFICAÇÃO E AVALIAÇÃO ESTATÍSTICA.....	57
3.1. - Classificação de imagens.....	57
3.1.1. - Crescimento de regiões.....	58
3.2. - Avaliação estatística.....	59
3.2.1. - Teste de hipótese.....	60
3.2.2. - Avaliação através do coeficiente kappa ($\hat{\kappa}$).....	61
3.2.3. - Avaliação através do método de Amostragem por Nível de Aceitação.....	66
CAPÍTULO 4 - MATERIAIS E METODOLOGIA.....	77
4.1. - Material de trabalho.....	77
4.2. - Metodologia.....	78
4.3. - Realce de imagens.....	81
4.4. - Procedimento de segmentação de imagem.....	82
4.4.1. - Crescimento de regiões adaptado ao matiz.....	83
4.4.2. - Filtragem de pequenas regiões.....	85
4.4.3. - Agrupamento de regiões - identificação de regiões similares.....	85

4.4.4. - Tamanho mínimo de uma classe	86
4.4.5. - Particularidades do método de segmentação em matiz.....	88
4.5. - Procedimento para avaliação estatística.....	90
4.5.1. - Procedimento de avaliação de classificação em Caçapava.....	91
4.5.2. - Procedimento de avaliação de classificação em Tremembé.....	93
CAPÍTULO 5 - RESULTADOS E DISCUSSÕES	95
5.1. - Avaliação qualitativa	95
5.1.1. - Caçapava.....	96
5.1.1.1. - Base de dados analisada	97
5.1.1.2. - Influência da variação de luminosidade.....	98
5.1.1.3. - Área 1 - eucalipto.....	98
5.1.1.3.1. - Três bandas - TM345	99
5.1.1.3.2. - Quatro bandas - TM3457.....	100
5.1.1.3.3. - Cinco bandas - TM23457	101
5.1.1.4. - Área 2 - Água	101
5.1.1.4.1. - Três bandas - TM345.....	102
5.1.1.4.2. - Quatro bandas - TM3457.....	104
5.1.1.4.3. - Cinco bandas - TM23457	106
5.1.1.4.4. - Causas do baixo desempenho do matiz no alvo água.....	107
5.1.1.5. - Área 3 - Alvo urbano	109
5.1.1.5.1. - Três bandas - TM345.....	109
5.1.1.5.2. - Quatro bandas - TM3457.....	110
5.1.1.5.3. - Cinco bandas - TM23457	111
5.1.2. - Tremembé.....	113
5.1.2.1. - Três bandas - TM453.....	114
5.1.2.2. - Quatro bandas - TM3457.....	116
5.1.2.3. - Cinco bandas - TM23457	118
5.2. - Avaliação quantitativa.....	121
5.2.1. - Caçapava, 146 pontos.....	121
5.2.2. - Caçapava, 475 pontos.....	127
5.2.3. - Caçapava, 803 pontos.....	133
5.2.4. - Tremembé, 153 pontos	137
5.2.5. - Tremembé, 231 pontos.....	140
5.2.6. - Tremembé, 528 pontos.....	143
CAPÍTULO 6 - CONCLUSÕES E SUGESTÕES	147
6.1. - Conclusões	147
6.2. - Sugestões	148
REFERÊNCIAS BIBLIOGRÁFICAS	151
APÊNDICE A.....	155

APÊNDICE B	157
B.1. - Visualização e processamento.....	157
B.2. - Avaliação estatística	162
APÊNDICE C	167

LISTA DE FIGURAS

1.1 - Região onde estão localizadas as áreas de estudo nos Municípios de Cacapava e Tremembé. FONTE: Adaptada de Simi Jr. (1997) (a) e mapa gerado pelo programa Microsoft Expedia Maps (b).....	27
2.1 - Curvas espectrais de solo, vegetação e água e os intervalos espectrais de cada banda do sensor TM do LANDSAT. FONTE: Adaptada de de Harrison e Jupp (1989) a partir da figura original de Richards (1986, p. 38).	32
2.2 - Espectro dos comprimentos de onda da luz visível. FONTE: Bruton (2000)....	33
2.3 - Curvas das funções $r(\lambda)$, $g(\lambda)$ e $b(\lambda)$, que fornecem a quantidade necessária de luz das cores primárias para que o ser humano visualize a cor formada pela combinação destas cores. FONTE: Adaptada de Foley et al. (1990, p. 578).	34
2.4 - Curvas das funções $x(\lambda)$, $y(\lambda)$ e $z(\lambda)$, que fornecem a quantidade necessária dos valores triestímulos X, Y e Z, para que o ser humano visualize a cor formada pela combinação destes. FONTE: Adaptada de Foley et al. (1990), p. 579.	35
2.5 - Diagrama de cromaticidade xy do CIE. FONTE: Gerada no programa PCCOLOUR versão 2.1.....	36
2.6 - Círculos representando as cores primárias do sistema aditivo. Nas interseções estão representadas as cores subtrativas, resultantes da soma entre as cores dos círculos correspondentes. FONTE: Marshall (1996), www.yarc.com/colortut.htm	38
2.7 - Cubo representando o espaço de cores RGB. FONTE : Adaptada de Gonzalez e Woods (1992, p.226).....	39
2.8 - Elípses de MacAdam no diagrama de cromaticidade. FONTE: Pratt (1991, p. 86).	42
2.9 - Diagrama de cromaticidade uv (a) e as elipses de MacAdam (b) correspondentes ao espaço de cores $L^*u^*v^*$. FONTE: Gerada no programa PCCOLOUR versão 2.1.....	42
2.10 - Seção circular do cilindro esquemático do espaço de atributos de cores cilíndrico. FONTE: Adaptada de Pitas (1995, p.35).....	44
2.11 - Hexacôno do espaço de cores HSV. FONTE: Adaptada de Foley et al. (1990, p. 590).	45
2.12 - Estruturas piramidais duplo-hexacônica (a) e duplo-tetraédrica (b) do espaço de atributo de cores - HLS e HSI, respectivamente. FONTE: Adaptadas de Foley, et al. (1990, p. 594) e Gonzalez e Woods (1992, p. 230).	46
2.13 - Curvas de matiz (preto), saturação (azul) e brilho (laranja) iniciando a partir de uma situação com baixa saturação.....	48
2.14 - Curvas de matiz (preto), saturação (azul) e brilho (laranja) iniciando a partir de uma situação com baixo brilho.....	49

2.15 - Gráfico tridimensional (a) e bidimensional (b) de matiz para as coordenadas no espaço RGB, a um valor constante igual a 100 do componente referente a cor azul.	50
2.16 - Composição TM453 (a) e simulação TM4537 (b). Nota-se que na composição com quatro bandas o alvo urbano em azul, se destaca mais do restante da cena.	53
2.17 - Componente matiz do espaço de atributos: (a) matiz da composição TM453; (b) matiz da composição TM4537.	54
2.18 - (a) Resultado da média aritmética simples. (b) Valor médio real entre dois valores extremos de matiz. FONTE: Gerada a partir de algoritmo implementado na linguagem IDL.	55
3.1 - Curvas das funções de densidade de probabilidade binomial: - do ponto de vista do usuário, com área de risco pintada na cor azul correspondendo a $R_u=0,0481$; - do ponto de vista do produtor, com área de risco pintada na cor laranja correspondendo a $R_p=0,0221$	73
3.2 - Curvas das funções de densidade de probabilidade binomial: - do ponto de vista do usuário, com área de risco pintada na cor azul correspondendo a $R_u=0,0481$; - do ponto de vista do produtor, com área de risco pintada na cor laranja correspondendo a $R_p=0,5464$	75
4.1 - Fluxograma do procedimento de classificação do matiz.	80
4.2 - Histogramas da imagem original e realçada de Tremembé. FONTE: Obtida a partir do "software" ENVI.	81
4.3 - Imagem TM4 original (a) e imagem realçada 2% (b) de Tremembé.	82
4.4 - Pixel semente em cinza, e vizinhos na cor amarelo.	84
4.5 - Passos do crescimento de região.	84
4.6 - Exemplo de dois resultados de segmentação da mesma cena, usando limiar de segmentação 30.	88
4.7 - Pontos aleatórios sobre a composição TM4537 de Caçapava.	92
4.8 - Imagem de referência de Caçapava, com as classes urbano (branco) e não-urbano (cinza).	93
4.9 - Pontos aleatórios sobre detalhe da composição TM4537 de Tremembé.	94
5.1 - Composição TM453 de Caçapava. Em destaque, dentro de retângulos, quatro situações analisadas: preto: urbano; vermelho: água; branco: eucalipto; amarelo: região sombreada.	96
5.2 - Detalhe de uma região com sombra em três situações: (a) composição TM453, onde se nota variação grande de luminosidade devido ao relevo; (b) classificação matiz, limiar de segmentação 25, onde a variação da luminosidade pouco interfere na obtenção das classes; (c) classificação Iseseg, limiar de similaridade 40, limiar de aceitação 99,9%, onde a variação de luminosidade interfere bastante no resultado.	98
5.3 - Detalhe de uma região com eucalipto: (a) composição TM453, com pasto (em tons de verde) em volta da região de eucalipto (em tons de vermelho); (b) classificação do matiz, limiar de segmentação 20, com eucalipto e pasto sendo bem definidos; (c) classificação Iseseg, limiar de similaridade 40 e, limiar de aceitação 99,9%, com eucalipto bem classificado, e com a classificação de pasto sofrendo influência da variação de luminosidade.	99

5.4 - Detalhe de uma região com eucalipto: (a) composição TM4537; com pasto (em tons de bege) em volta da região de eucalipto (em tons de vermelho); (b) classificação matiz, limiar de segmentação 20, agora com grande parte de eucalipto sendo confundido com pasto, devido aos valores de matiz dos dois alvos serem mais próximos nesta composição; (c) classificação Isoseg, limiar de similaridade 20 e limiar de aceitação 99,9%, havendo boa discriminação do alvo eucalipto, mas com uma maior influência da variação de luminosidade no alvo pasto.....	100
5.5 - Detalhe da região com eucalipto em três situações: (a) composição TM45273; com pasto (em tons de marrom) em volta da região de eucalipto (em tons de vermelho); (b) classificação matiz, limiar 25 de segmentação; havendo muito boa identificação do alvo eucalipto e do alvo pasto, este não sofrendo qualquer influência de variação na luminosidade; (c) classificação Isoseg, limiar de similaridade 40, limiar de aceitação 95%. Boa identificação de eucalipto e muita influência da variação de luminosidade no alvo pasto.....	101
5.6 - Composição colorida TM453, onde cada número destaca um tipo de alvo água: 1- baixa quantidade de sedimentos em suspensão; 2- média quantidade de sedimentos em suspensão; 3- alta quantidade de sedimentos em suspensão;	102
5.7 - Composição TM453 (a) e sua respectiva imagem de matiz (b).	103
5.8 - Resultado de classificação de região com presença do alvo água: (a) método por matiz, limiar de segmentação 20. Há muita confusão entre os tipos de alvo água, de acordo com o nível de sedimentos em suspensão. (b) método Isoseg, limiar de similaridade 20, limiar de aceitação 99%. Consegue identificar e separar os três tipos de alvo água.....	104
5.9 - Composição TM4537 (a)- onde as setas brancas apontam para áreas irrigadas para plantação de arroz- e sua respectiva imagem de matiz (b).....	105
5.10 - Resultado de classificação região com presença de alvo água: (a) método por matiz, limiar de segmentação 20. Há muita confusão entre os tipos de alvo água, de acordo com o nível de sedimentos em suspensão. Há confusão também áreas irrigadas, identificadas por setas brancas na Figura 5.9. (b) método Isoseg, limiar de similaridade 20 e limiar de aceitação 99%. Consegue identificar e separar os três tipos de alvo água.....	105
5.11 - Composição TM45273 (a) e sua respectiva imagem de matiz (b).....	106
5.12 - Resultado de classificação região com presença de diversos tipos de alvo água: (a) método por matiz, limiar de segmentação 25. Ainda existe confusão entre os três tipos de alvo água, porém em menor grau. Já consegue discriminar dois tipos de alvo água; (b) método Isoseg, limiar de similaridade 40, limiar de aceitação 99,9%. Consegue identificar e separar os três tipos de alvo água.....	107
5.13 - Classificação de matiz da composição TM45273, de uma área com presença de água em Caçapava: Limiar de segmentação 25, tamanho mínimo de pixel 2, limiar de agrupamento 10 e sem restrição de tamanho de classe. Com estes parâmetros houve uma boa identificação dos três tipos de alvo água presentes na cena.	108

5.14 - Resultados de classificação sobre as bandas TM345: (a) método por matiz, limiar de segmentação 25. As setas em preto apontam para regiões onde houve erros de inclusão de um alvo não-urbano na classe urbano; (b) Isoseg, limiar de similaridade 30 e limiar de aceitação 95%. As setas em branco apontam para regiões onde houve erros de inclusão de um alvo não-urbano na classe urbano.....	110
5.15 - Resultados de classificação sobre as bandas TM3457: (a) método por matiz, limiar de segmentação 20. As setas em preto apontam para regiões onde houve erros de inclusão de um alvo não-urbano na classe urbano; (b) Isoseg, limiar de similaridade 40 e limiar de aceitação 75%. As setas em branco apontam para regiões onde houve erros de inclusão de um alvo não-urbano na classe urbano.....	111
5.16 - Resultados de classificação sobre as bandas TM23457: (a) método por matiz, limiar de segmentação 25; As setas em branco apontam para regiões onde houve erros de inclusão de um alvo não-urbano na classe urbano. (b) Isoseg, limiar de similaridade 20 e limiar de aceitação 90%. As setas em branco apontam para regiões onde houve erros de inclusão de um alvo não-urbano na classe urbano.....	112
5.17 - Composição TM453 de Tremembé. Em destaque está a região com forte presença de sombra, onde a classificação foi avaliada qualitativamente.....	114
5.18 - Detalhe de região com presença de floresta: (a) composição TM453, havendo forte presença de região com sombra; (b) matiz de TM453, onde a influência da sombra sobre os valores de matiz da região de floresta, é notada pelo matiz azul. Evidenciando uma instabilidade do matiz nestas áreas.	115
5.19 - Resultados de classificação sobre as bandas TM345: (a) método por matiz, limiar de segmentação 20; (b) Isoseg, limiar de similaridade 40 e limiar de aceitação 99,9%.....	116
5.20 - Detalhe de região com presença de floresta: (a) composição TM4537, havendo forte presença de região com sombra; (b) matiz de TM4537, onde a influência da sombra sobre os valores de matiz da região de floresta, é notada pelo matiz ciano. Evidenciando uma instabilidade do matiz nestas áreas.	117
5.21 - Resultados de classificação sobre as bandas TM4573: (a) método por matiz, limiar de segmentação 20; (b) Isoseg, limiar de similaridade 40 e limiar de aceitação 99,9%.....	118
5.22 - Detalhe de região com presença de floresta: (a) composição TM45273, havendo forte presença de região com sombra; (b) matiz de TM45273, onde a influência da sombra sobre os valores de matiz da região de floresta, é notada pelos matizes azul e ciano. Evidenciando assim, uma instabilidade do matiz nestas áreas.	119
5.23 - Resultado de classificação com regiões de valores instáveis de matiz, com intensidade menor que 0,10. Nem todas as regiões com sombra são corretamente mapeadas.....	120
5.24 - Resultados de classificação sobre as bandas TM23457: (a) método por matiz, limiar de segmentação 20; (b) Isoseg, limiar de similaridade 30 e limiar de aceitação 99,9%.....	120

5.25 - Valores estimados de kappa para matiz de três, quatro e cinco bandas.....	122
5.26 - Matriz de confusão de classificação com limiar de segmentação 30, sobre: (a) matiz de composição TM453; (b) matiz de composição TM4537.....	122
5.27 - Matriz de confusão de classificação com limiar de segmentação 30, sobre matiz de composição TM45273:.....	123
5.28 - Comparação entre o método Iseseg, com diferentes limiares de aceitação, e o método de matiz para três bandas.....	126
5.29 - Comparação entre o método Iseseg, com diferentes limiares de aceitação, e o método de matiz para quatro bandas.....	126
5.30 - Comparação entre o método Iseseg, com diferentes limiares de aceitação, e o método de matiz para cinco bandas.....	126
5.31 - Valores de kappa para matiz de três, quatro e cinco bandas.....	127
5.32 - Matriz de confusão de classificação com limiar de segmentação 30, sobre: (a) matiz de composição TM453; (b) matiz de composição TM4537; (c) matiz de composição TM45273.	128
5.33 - Regiões consideradas da classe urbano pela classificação por matiz, a limiar 30, que não coincidem com a referência.	129
5.34 - Comparação entre o método Iseseg, com diferentes limiares de aceitação, e o método de matiz para três bandas.	132
5.35 - Comparação entre o método Iseseg, com diferentes limiares de aceitação, e o método de matiz para quatro bandas.....	132
5.36 - Comparação entre o método Iseseg, com diferentes limiares de aceitação, e o método de matiz para cinco bandas.....	132
5.37 - Valores de kappa para matiz de três, quatro e cinco bandas.....	133
5.38 - Matriz de confusão de classificação com limiar de segmentação 30, sobre: (a) matiz de composição TM453; (b) matiz de composição TM4537; (c) matiz de composição TM45273.	134
5.39 - Comparação entre o método Iseseg, com diferentes limiares de aceitação, e o método de matiz para três bandas.....	136
5.40 - Comparação entre o método Iseseg, com diferentes limiares de aceitação, e o método de matiz para quatro bandas.....	136
5.41 - Comparação entre o método Iseseg, com diferentes limiares de aceitação, e o método de matiz para cinco bandas.....	136
5.42 - Valores de kappa para matiz de três, quatro e cinco bandas.....	137
5.43 - Comparação entre o método Iseseg, com limiares de aceitação 99,9% e 99%, e o método de matiz para três bandas.	139
5.44 - Comparação entre o método Iseseg, com limiares de aceitação 99,9% e 99%, e o método de matiz para quatro bandas.	139
5.45 - Comparação entre o método Iseseg, com limiares de aceitação 99,9% e 99%, e o método de matiz para cinco bandas.	139
5.46 - Valores de kappa para matiz de três, quatro e cinco bandas.....	141
5.47 - Comparação entre o método Iseseg, com limiares de aceitação 99,9% e 99%, e o método de matiz para três bandas.	142
5.48 - Comparação entre o método Iseseg, com limiares de aceitação 99,9% e 99%, e o método de matiz para quatro bandas.	142
5.49 - Comparação entre o método Iseseg, com limiares de aceitação 99,9% e 99%, e o método de matiz para cinco bandas.	142

5.50 - Valores de kappa para matiz de três, quatro e cinco bandas.....	143
5.51 - Comparação entre o método Iseseg, com limiares de aceitação 99,9% e 99%, e o método de matiz para três bandas.	145
5.52 - Comparação entre o método Iseseg, com limiares de aceitação 99,9% e 99%, e o método de matiz para quatro bandas.	145
5.53 - Comparação entre o método Iseseg, com limiares de aceitação 99,9% e 99%, e o método de matiz para cinco bandas.	145
B.1 - Menu principal do programa.....	157
B.2 - Opções de abertura de cenas no submenu Abrir	157
B.3 - Caixa de diálogo para definir parâmetros de entrada para abertura de composição colorida.	158
B.4 - Janelas de visualização de imagem: (a) Composição colorida TM45273; (b) Matiz da composição colorida.....	159
B.5 - Menu de chamada do programa de crescimento de regiões.....	159
B.6 - Menu para abertura dos resultados de processamentos.....	159
B.7 - Caixa de diálogo de definição dos parâmetros de segmentação e o respectivo resultado deste processamento.	160
B.8 - Caixa de diálogo de definição dos parâmetros de filtragem de pequenas regiões e o respectivo resultado deste processamento.	161
B.9 - Caixa de diálogo de definição dos parâmetros de agrupamento de regiões e o respectivo resultado deste processamento.	162
B.10 - Comandos de acesso a avaliação estatística dos pontos amostrados.	162
B.11 - Caixa de diálogo para carregar os pontos amostrados e de escolha da classe principal da classificação.	163
B.12 - Exemplo de relatório gerado da avaliação estatística realizada.	164
B.13 - Gráfico das fdp binomiais do consumidor (área azul) e do produtor (área laranja).....	165
C.1 - Gráfico das fdp binomial do consumidor (área azul) e do produtor (área laranja).....	167
C.2 - Relatório gerado após a avaliação estatística.	168
C.3 - Risco real do produtor com base na exatidão global $P_p=0,869$	169
C.4 - Riscos que usuário e produtor teriam, caso o usuário baixasse a exatidão requerida a um valor no qual a classificação é aprovada tendo 20 pontos mal classificados.....	169
C.5 - Riscos que usuário e produtor teriam, caso o usuário baixasse a exatidão requerida a um valor no qual a classificação é aprovada, tendo 27 pontos mal classificados e com um risco menor que 5% de ser rejeitada erroneamente.....	169
C.6 - Relatório gerado após a avaliação estatística.	170
C.7 - Risco real do produtor com base na exatidão global $P_p=0,945$	171
C.8 - Risco que usuário e produtor teriam, caso o usuário subisse a exatidão requerida até um valor onde ainda a classificação é aprovada com 8 pontos mal classificados.	171
C.9 - Risco que usuário e produtor teriam, caso o usuário subisse a exatidão requerida até um valor onde a classificação é aprovada sem que o produtor corra um risco maior que 5%.	171

LISTA DE TABELAS

2.1 - Bandas do sensor LANDSAT/TM.....	31
2.2 - Diferenças encontradas entre os valores de matiz obtidos pelo método de Moik e pela transformação RGB–HSV.....	52
3.1 - Exemplo de matriz de confusão.....	62
3.2 - Probabilidade de nenhum ponto ser mal classificado $p(x=0)$ dados o tamanho da amostragem (n) e a exatidão nominal do mapa temático (p).....	68
3.3 - Probabilidade de ocorrerem x erros de classificação dado o tamanho da amostragem (n) para uma exatidão nominal de $p = 0,85$	69
3.4 - Valores de x_c , R_u exato e R_p	71
3.5 - Tamanhos ótimos de amostragem (n) e seus respectivos valores de x_c e R_p , para $P_u=0,85$ e $R_u=0,05$	72
4.1 - Composição das classes na classificação de caçapava, limiar 30, tamanho mínimo de região 4 e limiar de agrupamento 10.....	87
4.2 - Composição das classes na classificação de caçapava, limiar 30, tamanho pixel 4, limiar de agrupamento 10 e tamanho mínimo 1%.....	87
4.3 - Classes identificadas na interpretação visual dos pontos de caçapava.....	91
5.1 - Kappa estimado, sua variância amostral e valores de estatística z de composições TM453, TM4537 e TM45273.....	122
5.2 - Valores estimados de kappa e suas variâncias, isoseg com vários limiares de aceitação e classificação de matiz.....	124
5.3 - Comparação entre desempenhos de classificação de isoseg e matiz.....	125
5.4 - Kappa estimado, sua variância amostral e valores de estatística z de composições TM453, TM4537 e TM45273.....	127
5.5 - Número de pixels que não coincidem com a referência, na classificação de matiz com limiar de segmentação 30.....	129
5.6 - Valores estimados de kappa e suas variâncias; isoseg com vários limiares de aceitação e classificação de matiz.....	130
5.7 - Comparativo entre desempenhos de classificação de isoseg e matiz.....	130
5.8 - Kappa estimado e suas variâncias amostrais.....	133
5.9 - Valores estimados de kappa e suas variâncias. Isoseg com vários limiares de aceitação e classificação de matiz.....	134
5.10 - Comparativo entre desempenhos de classificação de isoseg e matiz.....	135
5.11 - Kappa, variância de kappa e z para três, quatro e cinco bandas.....	137
5.12 - Comparativo entre desempenhos de classificação de isoseg e matiz.....	138
5.13 - Kappa, variância de kappa e z para três, quatro e cinco bandas.....	140
5.14 - Comparativo entre desempenhos de classificação de isoseg e matiz.....	141
5.15 - Kappa, variância de kappa e z para três, quatro e cinco bandas.....	143
5.16 - Comparação entre desempenhos de classificação de isoseg e matiz.....	144

CAPÍTULO 1

INTRODUÇÃO

O esforço de se desenvolver métodos computacionais para distinguir diferentes alvos presentes em imagens digitais resultou em diversos algoritmos de segmentação e classificação, muitos dos quais adotados pela comunidade científica de Sensoriamento Remoto. Esses métodos, em sua grande parte, baseiam-se na informação multispectral dos dados de sensoriamento remoto, obtidos por sensores em plataformas tanto orbitais, quanto aerotransportadas.

No entanto, são poucos os métodos computacionais que utilizam a informação da cor com o propósito de distinguir as regiões de uma cena presente na imagem, e são menos freqüentes ainda os métodos que lançam mão dos atributos matiz, saturação e intensidade de uma imagem colorida. Dentre esses, há o trabalho feito por Tseng e Chang (1992), onde a imagem é dividida em regiões cromáticas e acromáticas, seguindo o critério que considera conjuntamente os valores de saturação e de intensidade do pixel. Em seguida faz-se a segmentação separadamente pelos valores de matiz na região cromática e intensidade na acromática, obtendo-se bons resultados. No entanto, a delimitação da região acromática é imprecisa, não havendo uma regra universalmente aceita, podendo variar bastante dependendo dos critérios adotados.

Crevier (1993) comparou o resultado da segmentação por crescimento de regiões realizada sobre o matiz de duas maneiras. A primeira utiliza a média aritmética para calcular o valor médio de um conjunto de pixels, enquanto que a segunda este cálculo considera o caráter circular dos valores de matiz, dado que este é representado por ângulos entre 0 e 360 graus. Esta segmentação apresentou um resultado visualmente melhor em relação à primeira.

Tseng et al. (1995) mostrou uma comparação de resultados entre a limiarização de um histograma tradicional de uma imagem de matiz, a utilização de um histograma circular, que possui coordenadas polares (r e θ), onde θ representa o valor angular do componente matiz e r a freqüência com que ele ocorre. Observou-se que a limiarização utilizando histograma

circular, nos experimentos realizados, sempre obtive resultados melhores com relação à utilização de histograma tradicional. Este melhor desempenho se deve justamente ao histograma circular melhor expressar o comportamento dos valores de matiz presentes na imagem. Não foram definidas aqui regiões acromáticas.

Os atributos matiz e saturação, são os que melhor simulam a maneira de como o ser humano percebe as cores. Tendo como mote principalmente este argumento, Silva (1997) deu início ao desenvolvimento de um segmentador baseado no atributo matiz do espaço de atributos IHS (iniciais em inglês de intensidade, matiz e saturação: “Intensity”, “Hue” e “Saturation”). Além disso, diferentemente de métodos que utilizam a informação multiespectral, o segmentador proposto utiliza somente um canal (H), demandando um menor custo computacional.

Porém, há problemas inerentes a este espaço de cores que tornam o seu uso em segmentação por vezes inviável. Problemas esses relacionados principalmente à instabilidade que os valores do matiz (H) apresentam quando da ocorrência de baixos valores de saturação (S) e/ou intensidade (I).

Neste trabalho, métodos tradicionais de obtenção dos atributos de cor são abordados, assim como a utilização do método descrito por Moik (1980), que usa a informação de N imagens espectrais na obtenção dos atributos.

Um avaliação dos resultados, comparando-os com a verdade da imagem e com os resultados de outros segmentadores, na tarefa de separar principalmente regiões urbanas/não-urbanas e floresta/não-floresta também foi realizada.

1.1. - Justificativa

Este trabalho tem como motivação principal o uso do matiz na segmentação, tirando proveito de algumas características peculiares do mesmo. Dentre as características que incentivam o seu aproveitamento, destaca-se o seu valor homogêneo em áreas de um mesmo alvo com diferenças de luminosidade. Para terrenos com relevo acidentado este comportamento do valor de matiz é vantajoso. Por este motivo, escolheu-se uma imagem de floresta em área montanhosa para verificar até onde a variação de luminosidade não interfere no resultado de classificação por matiz.

O baixo custo computacional, tendo-se em vista a utilização de somente um componente, também é um fator que recomenda o emprego da técnica de segmentação no componente matiz. Contudo, existem algumas dificuldades inerentes ao espaço de atributos de cores, que tornaram o seu uso em segmentação de imagens digitais muito pouco explorado, dentre as quais, destaca-se o comportamento instável do atributo matiz sob valores pequenos de saturação e/ou intensidade. Essas dificuldades serão abordadas pormenorizadas no decorrer deste texto, bem como alternativas para contorná-las.

Outra área onde acredita-se que possa haver uma significativa contribuição do método proposto, é a identificação de manchas urbanas, haja visto a boa separabilidade de área urbanizada e não-urbanizada obtida pelo segmentador desenvolvido por Silva (1997). Além disso, o matiz do alvo urbano destaca-se bastante do matiz de vegetação. Isto é importante, pois há grande presença de vegetação (reflorestamento de eucalipto e pasto) em torno de manchas urbanas, na imagem escolhida para avaliar o desempenho do classificador por matiz.

1.2. - Objetivos

Este trabalho teve como principal objetivo, o desenvolvimento e implementação de algoritmos computacionais que utilizam a informação do matiz de uma composição colorida. A avaliação dos resultados obtidos também teve especial atenção, onde se concentraram esforços em duas situações: distinção entre áreas urbanas de não-urbanas e conseguir identificar (mapear) áreas de floresta uma imagem de região com relevo acidentado, havendo grande parcela de sombreamento na cena.

1.2.1. - Objetivos Específicos

Durante a elaboração deste trabalho, foi necessário implementar algoritmos que efetuassem algumas tarefas importantes para a o processamento e análise dos dados disponíveis. Dentre as ações realizadas com este intuito destacam-se:

- ✓ Utilizar o método descrito por Moik (1980), o qual baseia-se na informação de N bandas espectrais para gerar diretamente os atributos de cores ;
- ✓ Desenvolver algoritmo de crescimento de regiões que considere os valores médios dos dados circulares de matiz;
- ✓ Desenvolver algoritmos que automatizam o cálculos de risco de usuário e produtor;
- ✓ Implementação de interface gráfica.

1.3. - Área de Estudo

As imagens segmentadas correspondem às áreas situadas nos municípios de Caçapava e Tremembé, no vale do rio Paraíba do Sul, estado de São Paulo (Figura 1.1). A escolha de imagens dessa região se deveu ao fato de haver um desenvolvimento urbano local em Caçapava e áreas de floresta com grande presença de sombra devido ao relevo acidentado em Tremembé.



(a)



(b)

Fig. 1.1 - Região onde estão localizadas as áreas de estudo nos Municípios de Caçapava e Tremembé.

FONTE: Adaptada de Simi Jr. (1997) (a) e mapa gerado pelo programa Microsoft Expedia Maps (b).

CAPÍTULO 2

FUNDAMENTAÇÃO TEÓRICA

2.1. - Sensores Orbitais

Existem basicamente três níveis de obtenção de dados de uma cena em sensoriamento remoto, a saber: nível de campo, aéreo e orbital. Nos deteremos apenas em sensores presentes em plataformas orbitais, isto é, em satélites. Esses satélites de sensoriamento remoto ainda se subdividem por área de aplicação tais como meteorologia, oceanografia e agricultura, por exemplo.

O que define a aplicabilidade de um satélite, consiste basicamente de três características: a sua capacidade distinguir os detalhes de uma cena, a informação que o sensor consegue captar da cena e como é representada esta informação. À primeira dá-se o nome de **resolução espacial**, à segunda de **resolução espectral** e à última característica de **resolução radiométrica** do sensor. Na Seção 2.2 são apresentados mais detalhes a respeito das resoluções espacial, espectral e radiométrica, além das suas importâncias na formação de imagens de sensoriamento remoto.

2.2. - Formação de Imagens

A imagem de uma cena segue um modelo de uma função bidimensional $f(x,y)$ no qual se considera a iluminação e reflectância em cada coordenada espacial (x,y) da imagem, e o seu valor é finito (Gonzalez e Woods, 1992). Define-se reflectância como sendo a razão da quantidade de radiação refletida por objeto pela quantidade de radiação que incide nele, e é representada pelo componente $r(x,y)$. O componente da iluminação, proveniente de uma fonte, é dado por $i(x,y)$, que combinado com o componente $r(x,y)$ da reflectância, nos dá:

$$f(x,y) = i(x,y) r(x,y)$$

com $0 < i(x,y) < \infty$ (2.1)

e $0 < r(x,y) < 1$

A situação onde $r(x,y)$ é nulo indica que o objeto iluminado absorveu toda a luz incidente, ocorrendo justamente o contrário quando $r(x,y)$ vale um, isto é, o objeto reflete toda luz que nele incide. O valor de $i(x,y)$ é determinado principalmente pela fonte de luz, que na grande maioria dos casos trata-se do sol. Portanto, a iluminação da cena, sofre influência de fatores conjugados: o ângulo de inclinação solar e de aquisição (azimutal), com a própria topografia do terreno. Quanto maior o ângulo de incidência da luz do sol e/ou azimutal, mais regiões de sombra existirão na imagem, como consequência de baixos valores do componente de iluminação $i(x,y)$ da Equação (2.1).

As coordenadas da cena, são agrupadas na imagem digital em pixels (do inglês, *picture cells*, célula da imagem). O comprimento em largura e comprimento que cada pixel cobre na cena define a resolução espacial da imagem. Se, por exemplo, um sensor é capaz de distinguir objetos com pelo menos 5m de largura por 5m de comprimento, cada pixel da imagem formada terá resolução espacial de 5m.

Então, no processo de formação da imagem, cada pixel é sensibilizado pela energia (luz, luminosidade) proveniente da área contínua coberta por ele. A quantidade de energia captada pelo sensor, depende do intervalo de luz à qual o sensor é sensível, ou seja, entre quais comprimentos de onda iniciais e finais de radiação eletromagnética, o sensor reage. Este intervalo é resolução espectral do sensor, e o resultado visual deste processo na imagem resulta em tons de cinza escuros (pouca energia captada) a claros (mais energia captada).

Alguns sensores são capazes de captar a radiação proveniente da cena em mais de um intervalo espectral (também chamado de banda espectral). Por isso estes sensores são conhecidos com sensores multiespectrais. Um exemplo deste tipo de sensor é o

LANSAT/TM (Thematic Mapper), de onde as imagens utilizadas neste trabalho foram adquiridas.

O sensor TM possui 7 bandas espectrais, sendo seis que variam da faixa da luz visível até o infravermelho no espectro eletromagnético e uma no infravermelho termal. A resolução espacial do sensor TM nas bandas 1 a 5 e na banda 7 é de 30m, enquanto na banda 6 é de 120m. A Tabela 2.1 mostra a aplicabilidade de cada banda do TM, assim com seu intervalo de comprimento de onda (em μm) no espectro eletromagnético.

TABELA 2.1 - Bandas do Sensor Landsat/TM.

Banda	Intervalo de comp. de onda (μm)	Principais Aplicações
1	0,45 a 0,52	Mapeamento costeiro Diferenciação de solo e vegetação Diferenciação entre vegetação e coníferas e decíduas
2	0,52 a 0,60	Reflectância de vegetação verde sadia
3	0,63 a 0,69	Absorção da clorofila para Diferenciação de espécies vegetais
4	0,76 a 0,90	Pesquisas de biomassas Delineamento de corpos d'água
5	1,55 a 1,75	Diferenciação entre nuvens neve Medidas de umidade da vegetação
6	10,4 a 11,7*	Mapeamento de estresse térmico em plantas Outros mapeamentos térmicos
7	2,08 a 2,35	Mapeamento hidrotermal

FONTE: Adaptada de Novo (1989, p. 149).

* Calibração de pré-lançamento mostrou esse intervalo.

O intervalo do projeto era 10,4 a 12,5 μm (Harris, 1987).

Para cada banda há uma aplicação mais adequada, com um melhor aproveitamento da informação contida na imagem por ela gerada. Ao analisar-se a Figura 2.1, é facilitada a compreensão do porquê dessa escolha de bandas. Nesta figura, nota-se a diferença de comportamento do solo, da vegetação e da água diante a incidência de radiação eletromagnética no intervalo de 0,4 μm a 2,6 μm aproximadamente.

A região onde a água tem maior reflectância corresponde ao domínio das bandas 1 e 2 do TM. No caso da vegetação, nas bandas 3 e 4 ela possui alta resposta espectral. Já o solo apresenta mais alta resposta espectral nas bandas 5 e 7.

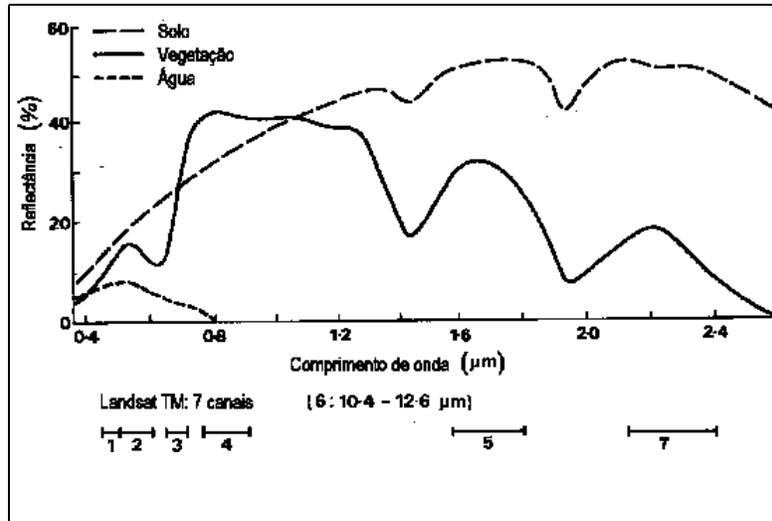


Fig. 2.1 - Curvas espectrais de solo, vegetação e água e os intervalos espectrais de cada banda do sensor TM do LANDSAT.

FONTE: Adaptada de de Harrison e Jupp (1989) a partir da figura original de Richards (1986, p. 38).

Os valores contínuos da função $f(x,y)$ passam por um processo de quantização, isto é, um intervalo de valores contínuos é integrado e representado por um número digital (ND), também tratado como nível de quantização. É definida como resolução radiométrica a quantidade de energia requerida para incrementar em uma unidade o nível de quantização de um pixel (Harrison e Jupp, 1989).

Também se refere à resolução radiométrica pelo número de bits que determina a quantidade de níveis de quantização da imagem. Por exemplo, dizer que uma imagem tem 8 bits de resolução radiométrica significa que a imagem possui 2^8 níveis de quantização, isto é, 256 níveis representados por números digitais (NDs) que variam de 0 (mais escuro) a 255 (mais claro).

2.3. - Teoria de Cores

Nada tem cor. Essa afirmativa *a priori* pode parecer estranha e até mesmo absurda. Mas o que na essência ela quer dizer é que, na realidade, tudo o que se vê, grosso modo, reflete uma cor e absorve todas as outras. E dependendo das condições de iluminação a que um objeto está submetido, são vistos matizes diferentes da cor refletida e até mesmo outras cores que antes haviam sido absorvidas.

O que as cores que conhecemos de fato, denominadas de luz visível, representam é uma parcela diminuta do espectro eletromagnético, se estendendo de 400 nm a 700 nm aproximadamente, tal como visto na Figura 2.2.. Aceita-se internacionalmente desde 1931 os valores 435,8 nm, 546,1 nm e 700 nm como os que representam espectralmente as três cores primárias aditivas, azul, verde e vermelho respectivamente, de acordo com a CIE (“Commission Internationale de l’Eclairage”).

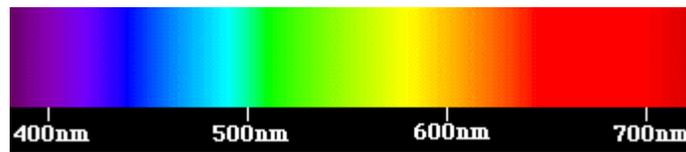


Fig. 2.2 - Espectro dos comprimentos de onda da luz visível.
FONTE: Bruton (2000).

As quantidades necessárias de luz nos comprimentos de onda do vermelho, do verde e do azul para que o olho humano visualize as cores formadas, são obtidas através das funções $r(\lambda)$, $g(\lambda)$ e $b(\lambda)$, respectivamente, onde λ (lambda) é o comprimento de onda em nanômetros. Para os comprimentos de onda na faixa da luz visível, a curva de cada função é mostrada no gráfico da Figura 2.3.

De acordo com Foley et al. (1990), os valores negativos na curva da Figura 2.3, significa que a cor vista pelo olho humano, pode de ser obtida pela adição da cor primária com valores negativos com a cor original, e combinar esta cor resultante com as outras duas cores primárias.

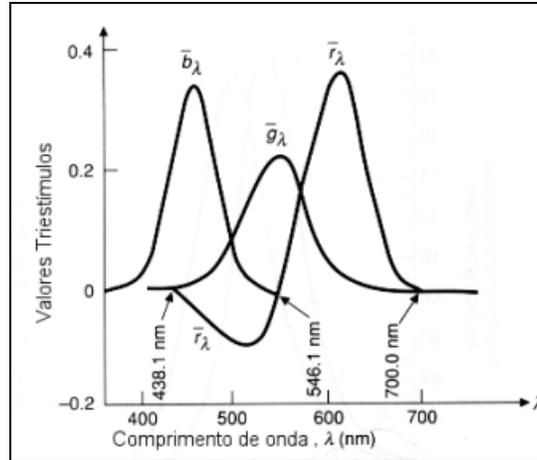


Fig. 2.3 - Curvas das funções $r(\lambda)$, $g(\lambda)$ e $b(\lambda)$, que fornecem a quantidade necessária de luz das cores primárias para que o ser humano visualize a cor formada pela combinação destas cores.

FONTE: Adaptada de Foley et al. (1990, p. 578).

O CIE definiu em 1931 três outras cores primárias, X, Y e Z, denominadas valores triestímulos. As funções que determinam as quantidades necessárias para se obter qualquer cor do espectro da luz visível são $x(\lambda)$, $y(\lambda)$ e $z(\lambda)$, cujas curvas são vistas na Figura 2.4. A vantagem destas com relação às funções das cores primárias vermelho, verde e azul, reside no fato de não haver valores (pesos) negativos.

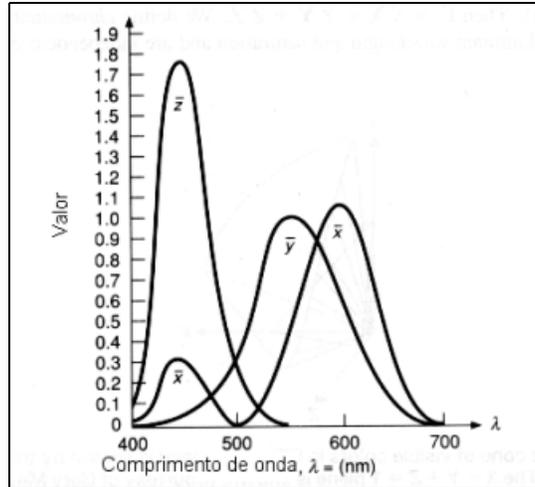


Fig. 2.4 - Curvas das funções $x(\lambda)$, $y(\lambda)$ e $z(\lambda)$, que fornecem a quantidade necessária dos valores triestímulos X, Y e Z, para que o ser humano visualize a cor formada pela combinação destes.

FONTE: Adaptada de Foley et al. (1990), p. 579.

Uma cor poderá também ser definida pelos coeficientes tricromáticos, dados por:

$$x = \frac{X}{X + Y + Z} \quad (2.2)$$

$$y = \frac{Y}{X + Y + Z} \quad (2.3)$$

$$z = \frac{Z}{X + Y + Z} \quad (2.4)$$

De onde se deduz que,

$$x + y + z = 1 \quad (2.5)$$

Uma representação gráfica dos coeficientes tricromáticos foi proposta pela *Commission Internationale de L'Eclairage* (CIE) em 1931 e recebe o nome de diagrama de cromaticidade (Figura 2.5), considerando como fonte de luz o iluminante padrão C (média da luz do dia). Todo ponto interior do diagrama de cromaticidade possui uma coordenada (x,y) dos coeficientes tricromáticos, com os quais pela a Equação (2.5), se obtém o valor do coeficiente tricromático z .

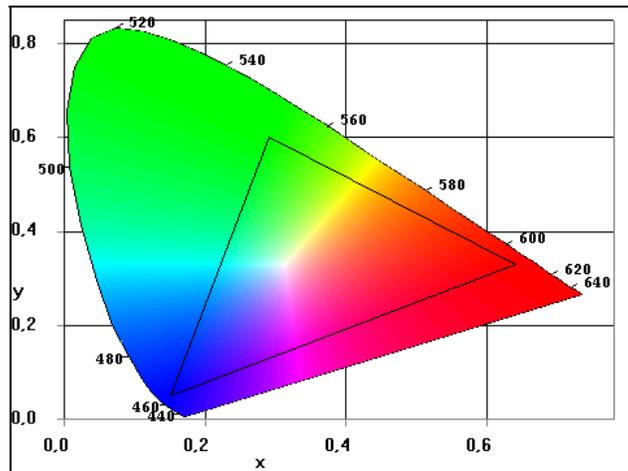


Fig. 2.5 - Diagrama de cromaticidade xy do CIE.

FONTE: Gerada no programa PCCOLOUR versão 2.1.

O triângulo localizado no interior do diagrama de cromaticidade, delimita a região onde estão todas as cores que as cores primárias aditivas vermelho, verde e azul são capazes de reproduzir. Este triângulo é denominado “gamut”, cujos vértices situam-se sobre cores primárias vermelho, verde e azul.

No contorno do diagrama localizam-se os comprimentos de onda das cores presentes no espectro da luz visível, onde as mesmas são totalmente puras. A pureza de uma cor diz respeito a quantidade de luz branca nela presente, isto é, quanto menor for a quantidade de luz branca, mais pura será a cor.

Verifica-se no diagrama (Figura 2.5), na transição entre as três cores primárias aditivas, a presença das cores secundárias ciano, magenta e amarelo. Segundo Gonzalez e Woods (1992), uma linha reta ligando dois pontos no diagrama engloba todas as combinações possíveis entre as duas cores correspondentes. Se ligar-se os vértices do "gamut" correspondentes as cores verde e vermelho através de uma reta, nela estarão todas as cores advindas da adição de verde e vermelho das mais diversas composições.

O ponto no diagrama onde há a mesma contribuição de cada cor primária é onde tem-se a cor branco. A linha que liga este ponto o contorno do diagrama contém todas as tonalidades de qualquer cor do espectro da luz visível.

2.3.1. - Espaço de Cores

De acordo com Foley et. al (1990), um espaço de cores é um sistema tridimensional de coordenadas, onde cada eixo refere-se a uma cor primária. A quantidade de cor primária necessária para reproduzir uma determinada cor, é atribuída a um valor sobre o eixo correspondente.

2.3.1.1. - Espaço RGB

Este espaço de cores é baseado nas três cores aditivas primárias, ou seja, no vermelho, no verde e no azul - red, green e blue, em inglês. A soma dessas três cores, duas a duas, resulta nas cores ciano (verde + azul), magenta (vermelho + azul) e amarelo (vermelho + verde), que vem a ser as cores subtrativas. São assim denominadas pelo fato de que as cores aditivas são obtidas através destas, pela subtração da cor branco por um par de cores subtrativas. Assim teremos:

$$\text{Vermelho} = \text{Branco} - \text{Amarelo} - \text{Magenta}$$

$$\text{Verde} = \text{Branco} - \text{Ciano} - \text{Amarelo}$$

$$\text{Azul} = \text{Branco} - \text{Magenta} - \text{Ciano}$$

Na Figura 2.6, são mostrados três círculos coloridos com cada uma das cores primárias aditivas, que se interceptam entre si. Nas interseções localizam-se justamente as correspondentes cores subtrativas, resultantes da soma duas a duas das cores primárias. Onde os três círculos interceptam-se, é formada a cor branco, resultado da soma das três cores primárias.

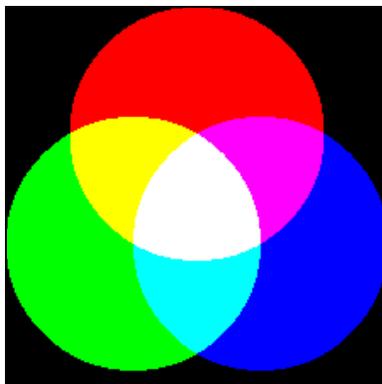


Fig. 2.6 - Círculos representando as cores primárias do sistema aditivo. Nas interseções estão representadas as cores subtrativas, resultantes da soma entre as cores dos círculos correspondentes.

FONTE: Marshall (1996), www.yarc.com/colortut.htm.

Deve-se ressaltar aqui, que o espaço de cores empregado pelas impressoras coloridas (o CMYK - do inglês "Cian", "Magenta", "Yellow" e "black"), baseia-se nas cores subtrativas. Portanto, as cores representadas no diagrama de cromaticidade da Figura 2.5, bem como em quaisquer imagens coloridas apresentadas neste trabalho, não reproduzem exatamente as cores vistas em um monitor colorido, baseado no espaço de cores RGB. Este problema poderia ser minimizado através da utilização de uma tradução da paleta de cores em RGB para a paleta em CMYK. No entanto, outros fatores, como a qualidade da tinta e do papel utilizado, também contribuem, embora em menor grau, para a não fidelidade de reprodução das cores vista no monitor RGB em um material impresso.

Um procedimento muito utilizado para tirar proveito das informações contidas nas diferentes bandas de uma mesma cena é o uso da composição colorida das imagens. Dada uma determinada cena, escolhe-se as três bandas que melhor contribuem na obtenção de informações dos elementos constituintes da mesma, e atribui-se a cada banda uma das cores aditivas primárias.

A composição da imagem colorida revela detalhes antes não percebidos ao se analisar a cena através de imagens monocromáticas banda a banda. Isto ocorre devido ao fato de o homem ter uma capacidade de discernimento muito maior entre feições coloridas do que entre feições em tons de cinza (Silva, 1997).

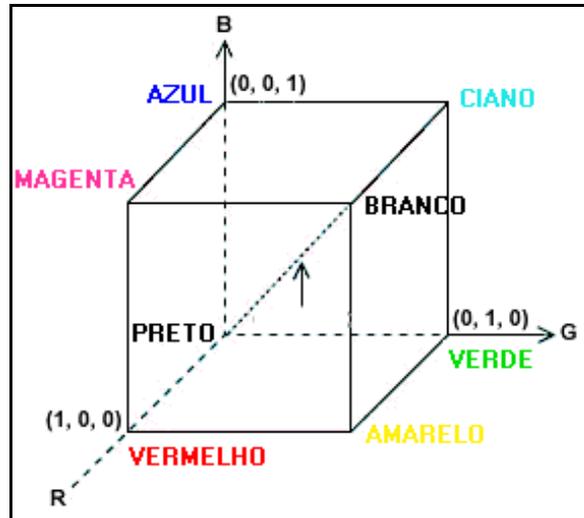


Fig. 2.7 - Cubo representando o espaço de cores RGB.
 FONTE : Adaptada de Gonzalez e Woods (1992, p.226).

O cubo mostrado na Figura 2.7 ilustra esquematicamente o espaço de cores RGB. Os valores sobre os eixos R, G e B, estão normalizados, ou seja, variam de 0 a 1. Note que os vértices do cubo representam as cores aditivas primárias e secundárias, a exceção dos vértices referentes ao preto e ao branco, em cuja a diagonal que os liga estão localizados os tons de cinza. Sobre as arestas do cubo, diz-se localizarem as cores saturadas neste espaço de cores.

Cor saturada não significa cor pura. A cor saturada está restrita ao espaço de cores a qual a mesma está inserida, e este espaço de cores por sua vez, está restrito às cores delimitadas pelo “gamut”. Enquanto que pura somente é aquela localizada no contorno do diagrama de cromaticidade mostrado na Figura 2.5. Portanto, cor totalmente pura o espaço RGB não é capaz de reproduzir.

2.3.1.2. - Espaço XYZ - Valores Triestímulos

A CIE define iluminantes padrões como aqueles que representam as distribuições de energia espectral de fontes luz. As fontes de luz consideradas são os iluminantes A (filamento de wolfrânio da lâmpada incandescente), C (média da luz do dia) e D65 (a

melhor representação da luz do dia). As fontes A, C e D65 geram as cores considerando que estão a temperaturas de 1856 K, 6740 K e 6500 K respectivamente (Gardner, 1997).

Quando se tem o iluminante padrão C (média da luz do dia) como fonte, a cor que contém uma quantidade R de vermelho, G de verde e B de azul, pode ser convertida nos valores triestímulos X,Y e Z, conforme Pratt (1991) pela seguinte transformação:

$$\begin{pmatrix} X \\ Y \\ Z \end{pmatrix} = \begin{pmatrix} 0,490 & 0,310 & 0,200 \\ 0,177 & 0,813 & 0,011 \\ 0,000 & 0,010 & 0,990 \end{pmatrix} \begin{pmatrix} R \\ G \\ B \end{pmatrix} \quad (2.6)$$

Assim como existem as fontes emissoras de radiação policromática (luz branca), há também emissores de luz monocromática, tais como os fósforos presentes nos tubos de raios catódicos dos aparelhos de televisão e monitores de microcomputadores. Esses tubos possuem três fósforos que emitem radiação na mesma faixa de comprimento de onda das cores vermelho, verde e azul.

Embora, segundo Pratt (1991), os fósforos difiram de fabricante para fabricante, há uma referência padrão de fósforos estabelecida pela NTSC (“National Television Systems Committee”). Para monitores de vídeo com padrão NTSC, tem-se a seguinte transformação para os valores triestímulos XYZ, a partir dos valores de R_N , G_N e B_N dos três fósforos de referência:

$$\begin{pmatrix} X \\ Y \\ Z \end{pmatrix} = \begin{pmatrix} 0,607 & 0,174 & 0,200 \\ 0,299 & 0,587 & 0,114 \\ 0,000 & 0,066 & 1,116 \end{pmatrix} \begin{pmatrix} R_N \\ G_N \\ B_N \end{pmatrix} \quad (2.7)$$

De posse das informações acima, é possível tecer alguns comentários acerca o espaço RGB. Ele apresenta deficiência em pelo menos dois aspectos:

- i. não representa fielmente a maneira como o ser humano percebe as cores;
- ii. não é capaz de reproduzir a totalidade das cores do espectro da luz visível.

No que tange ao item ii., isso não é exclusivo do espaço RGB. De fato, nenhum espaço possui essa qualidade.

Os valores normalizados do espaço RGB, não são os mais adequados para serem visualizadas as cores em um monitor colorido. Isto porque os monitores representam as cores numa escala que vai de 0 a 255. A combinação de valores nesta escala formam diversas outras cores. Por exemplo, a coordenada (1,1,0) no espaço de cores RGB tem valores máximos sobre os eixos vermelho e verde, representando a cor amarelo com alta intensidade. No entanto, estes mesmos valores para um monitor colorido são interpretados como a cor amarelo com baixa intensidade. O que é feito então, é mapear os valores normalizados de RGB no intervalo de 0 a 255.

2.3.1.3. - Espaço de Cores Uniforme

Conforme Tajima (1983), distâncias euclidianas nesse espaço de cores não correspondem as diferenças de cores percebidas pelo ser humano. Graficamente, isto pode ser visto através das elipses obtidas por MacAdam (1942) desenhadas no interior do diagrama de cromaticidade, representado na Figura 2.8.

Distância euclidiana é o comprimento de uma linha reta que liga dois pontos - P_1 e P_2 - no espaço. No espaço de triestímulos XYZ, por exemplo, ela será dada pela equação

$$D(P_1, P_2)^2 = (\Delta X)^2 + (\Delta Y)^2 + (\Delta Z)^2 \quad (2.8)$$

com ΔX , ΔY e ΔZ representando a variação em cada eixo deste espaço de cores.

O que as elipses representam, é a percepção pelo ser humano de diferença de cores. Note que o tamanho das elipses varia ao longo do diagrama, apontando a não existência de uniformidade nas distâncias entre um ponto e outro no diagrama. Isto significa que duas distâncias iguais, em regiões diferentes do diagrama, não indicam variações equivalentes das cores. Em suma, as variações de cores no diagrama-xy não podem ser representadas por distâncias euclidianas.

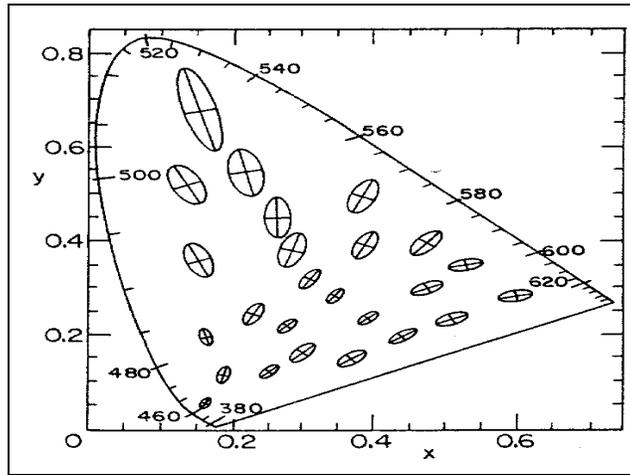


Fig. 2.8 - Elipses de MacAdam no diagrama de cromaticidade.
 FONTE: Pratt (1991, p. 86).

Espaços de cores nos quais a diferença de cores percebidas pelo ser humano podem ser aproximadamente representados por uma distância euclidiana são ditos de escala de cromaticidade uniforme - “uniform chromaticity scale” (UCS). Como exemplo há os espaços recomendados pela CIE, denominados $L^*a^*b^*$ e $L^*u^*v^*$. A Figura 2.9b mostra o diagrama de cromaticidade uv , onde as elipses de MacAdam apresentam-se com tamanhos mais uniformes em relação aos observados na Figura 2.8.

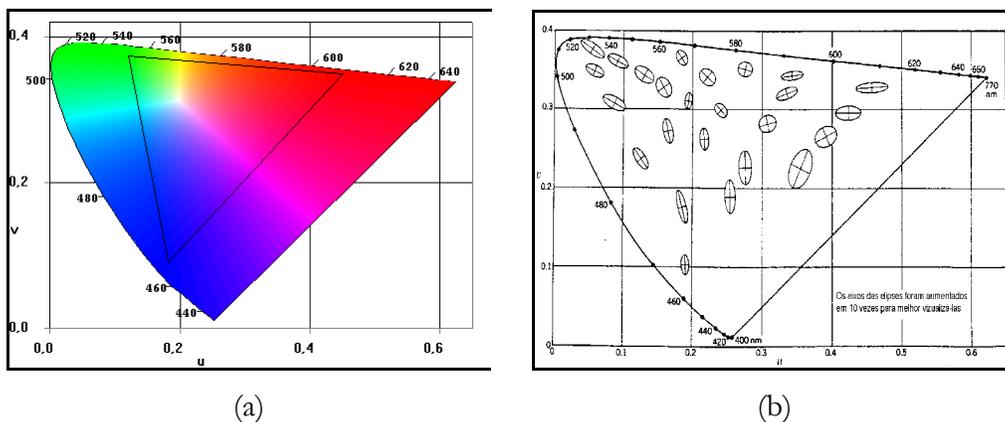


Fig. 2.9 - Diagrama de cromaticidade uv (a) e as elipses de MacAdam (b) correspondentes ao espaço de cores $L^*u^*v^*$.
 FONTE: Gerada no programa PCCOLOUR versão 2.1.

Apesar de todas as aparentes vantagens do espaço $L^*u^*v^*$, resolveu-se não adotá-lo neste trabalho, por entender que o teste e a comparação de diferentes espaços de cores na tarefa de obtenção dos atributos de cores, não era uma das finalidades do trabalho. Contudo, trabalhos futuros poderão abordar este assunto com mais atenção. Este trabalho restringiu-se aos métodos convencionais de obtenção dos atributos de cores, além do método proposto por Moik (1980), que passam a ser tratados a seguir.

2.3.2. - Espaço dos Atributos de Cores: Matiz, Saturação e Intensidade

Nos espaços de cores vistos anteriormente, os seus componentes (eixos) representam uma quantização da energia, referente aos comprimentos de onda respectivos às cores primárias vermelho, verde e azul do espectro da luz visível. Qualquer ponto interior ao espaço de cores representa uma cor, que é resultado da combinação das três cores primárias.

Esta cor por sua vez, dependendo dos valores dos componentes escolhidos, terá uma intensidade (brilho) associada, uma quantidade de luz branca que determina a sua saturação e uma cor predominante a qual chama-se matiz. A partir destes três atributos, é possível igualmente construir uma representação espacial que para a mesma cor obtida pelo espaço de cores. Esta representação espacial é o espaço de atributos de cores.

No entanto, é importante esclarecer uma certa confusão que se faz entre as “diversas representações” espaciais existentes dos atributos de cores. Pode-se definir o espaço de atributos como um sistema de coordenadas cilíndricas (r, ϕ, z) , onde em seu eixo vertical situam-se os valores de intensidade (componente intensidade = eixo z). Já o valor de saturação corresponde ao raio (componente saturação = eixo r) e o ângulo ϕ corresponde ao valor de matiz da cor (componente matiz = eixo ϕ).

Os valores de intensidade e de saturação variam desde 0 até 1, enquanto os valores de matiz estão compreendidos entre os ângulos 0 e 360 graus. Para ϕ igual a 0, 120 e 240 graus, o matiz será vermelho, verde e azul respectivamente, isto é, as três cores primárias.

Na Figura 2.10 está representada um seção circular do cilindro referente ao espaço de atributos, com seus respectivos eixos.

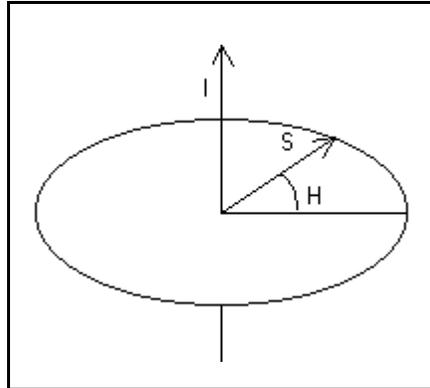


Fig. 2.10 - Seção circular do cilindro esquemático do espaço de atributos de cores cilíndrico.

FONTE: Adaptada de Pitas (1995, p.35).

No eixo I (do inglês “Intensity”) localizam-se os valores de intensidade, tendo como origem a base do cilindro, no o eixo S (“Saturation”) estão os valores de saturação, que sobre o eixo I possui valor 0 e sobre a circunferência da seção circular tem máximo valor, e o matiz é dado pelo arco no eixo H (da palavra em inglês para matiz “Hue”). Devido a isso, este sistema de coordenadas dos atributos de cores recebe o nome de espaço IHS.

Existem outras representações espaciais do espaço de atributos, tais como o **HSV** ("Hue", "Saturation", "Value") mostrado na Figura 2.11, que não tem representação cilíndrica, mas sim **hexacônica**. Isto porque este espaço resulta de transformações geométricas do espaço de cores RGB. Portanto, existem relações matemáticas, deduzidas a partir destas transformações geométricas, que permitem a representação de uma coordenada (cor) no espaço de cores RGB em uma coordenada no espaços de atributos HSV, e vice-versa. Convém ressaltar que o V do **HSV**, e o I do **IHS** representam a mesma grandeza, isto é, o brilho.

Com um pouco de exercício de abstração espacial, é possível imaginar o que ocorreu com o cubo do espaço RGB da Figura 2.7, até ele tomar a forma do hexacone. Note que as três faces retangulares que contém o vértice branco, estão na base do hexacone, e todos os

vértices estão no mesmo plano horizontal da base, exceto o vértice preto. Essa transformação fez com que as faces retangulares formadas pelos vértices das cores secundárias com os vértices das suas respectivas cores primárias tivessem como que sido divididas em duas faces triangulares, pois os vértices correspondentes deixaram de ser pertencer ao mesmo plano.

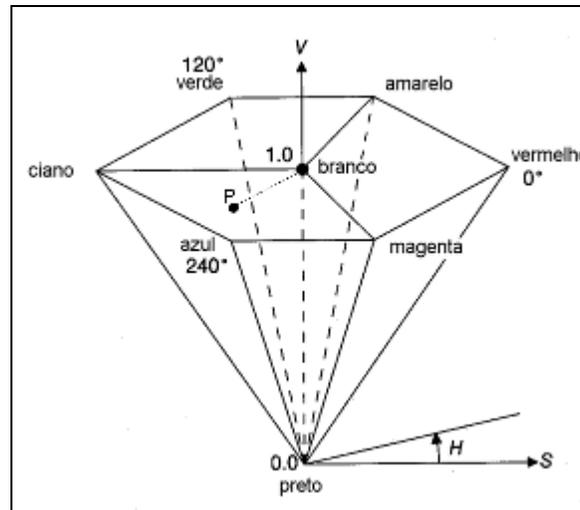


Fig. 2.11 - Hexacone do espaço de cores HSV.
 FONTE: Adaptada de Foley et al. (1990, p. 590).

Em outras palavras, é como se o cubo tivesse sido equilibrado pelo vértice preto e as faces que formam o vértice branco fossem “empurradas” para um mesmo plano, provocando uma deformação tal, que os vértices adjacentes deixaram de ser coplanares, criando as arestas ligando as cores secundárias ao vértice preto, moldando assim a figura do hexacone. A partir desta representação espacial, pôde-se chegar a relações geométricas entre o RGB e o HSV, como era desejado.

O eixo de V coincide com o eixo do hexacone, tendo sua origem no seu vértice. Portanto, na base do hexacone $V=1$, que é o valor máximo de V, e no vértice $V=0$. A saturação é medida pela distância do ponto **P** ao eixo do hexacone, variando de $S=0$ (sobre o eixo) a $S=1$ sobre as arestas do hexágono. Por fim, o matiz é dado pelo ângulo correspondente ao ponto **P** no plano hexagonal.

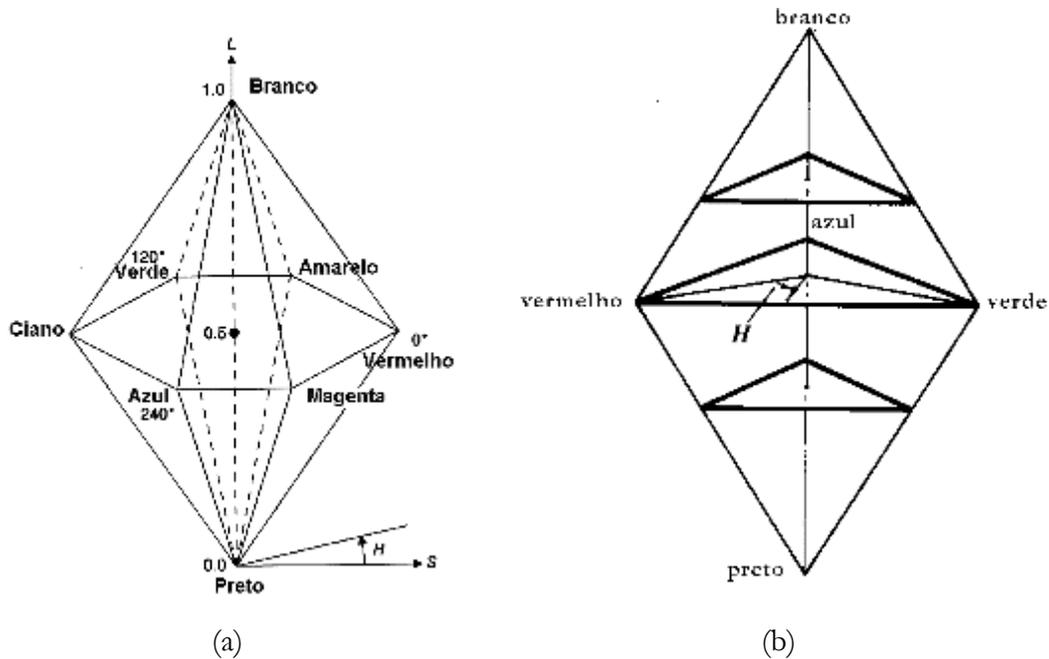


Fig. 2.12 - Estruturas piramidais duplo-hexacônica (a) e duplo-tetraédrica (b) do espaço de atributo de cores - HLS e HSI, respectivamente.

FONTE: Adaptadas de Foley, et al. (1990, p. 594) e Gonzalez e Woods (1992, p. 230).

Existem ainda as representações piramidais **duplo-hexacônica** e **duplo-tetraédrica**, ilustradas na Figura 2.12, referentes aos espaços de atributos **HLS** ("Hue", "Lightness", "Value") e **HSI** ("Hue", "Saturation", "Intensity"). Assim como o HSV, essas duas representações derivam do cubo referente ao espaço de cores RGB a partir de algumas transformações aplicadas em suas faces e arestas.

Apesar das diferenças geométricas dessas três representações do espaço de atributos, não há significativa diferença entre os atributos matiz e saturação obtidos através dos métodos citados. A diferença mais notada se dá com relação aos valores de intensidade no HLS, pois nesta representação o valor que corresponde a máxima intensidade é $L = 0,5$, e não $L = 1,0$ como nas outras representações. Neste trabalho, optou-se por se utilizar o espaço HSV, por já haver algoritmos implementados na linguagem IDL de conversão do espaço de cores RGB em HSV e vice-versa, e cujos os algoritmos são descritos no Apêndice A, adaptado de Foley et. al (1990).

2.3.2.1. - Problemas Inerentes aos Atributos de Cores

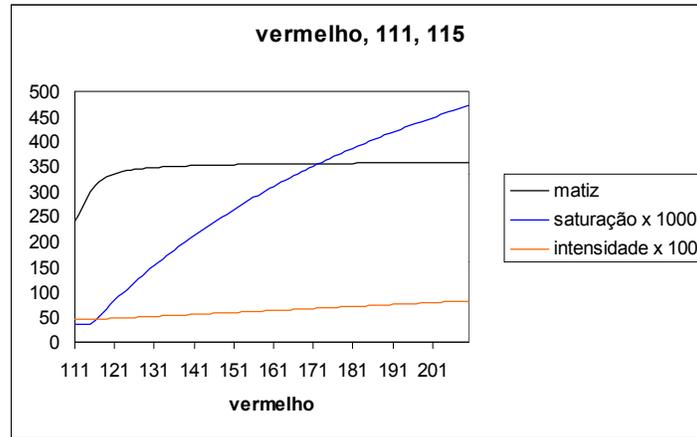
O atributo matiz apresenta características vantajosas, como a baixa influência da variação de iluminação na cena. Contudo, em algumas situações, sob condições de saturação e/ou intensidade com reduzido valor, o valor de matiz se torna instável.

Para ilustrar esta instabilidade, primeiro foi simulada uma situação onde a saturação fosse baixa e o brilho alto. Partindo de uma coordenada (111, 111, 115) no espaço de cores RGB, variou-se, de um em um, apenas o valor do componente vermelho (R) até o valor 211. Cada coordenada foi convertida para uma coordenada no espaço de atributos HSV, cujos valores iniciais foram (240, 0,0348, 0,451).

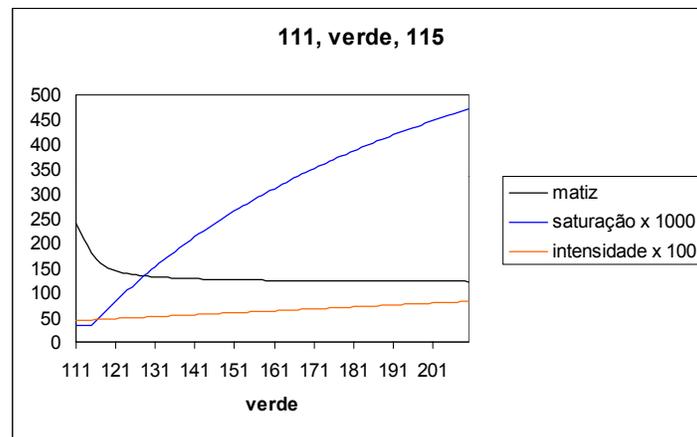
Mesmo procedimento foi realizado partindo-se da mesma coordenada, variando o valor do componente verde. Nos gráficos das Figuras 2.13a e 2.13b, são mostradas as curvas de matiz, saturação e intensidade para os dois procedimentos realizados. Nos dois casos, o que se percebe é uma acentuada inclinação da curva de matiz a baixos valores de saturação. E, na medida em que o valor de saturação aumenta, a inclinação da curva de matiz decresce até chegar a uma situação de estabilidade.

Simulação semelhante foi feita para mostrar a instabilidade do valor de matiz, para coordenadas com baixo valor de intensidade. A Figura 2.14 ilustra isso para uma coordenada no espaço RGB, com valores iniciais (11, 11, 1), que convertidos ao espaço HSV tornam-se (60, 0,909, 0,043), revelando uma alta saturação e baixa intensidade.

Conforme aumenta-se o valor do componente vermelho (Figura 2.14a) e verde (Figura 2.14b), conseqüentemente o brilho aumenta, e com isso a o valor absoluto da inclinação da curva de matiz decai gradualmente. Com o que pode-se inferir que, para valores baixos de brilho, o componente matiz é mais sensível (ou instável) as variações de valores das componentes no espaço RGB.



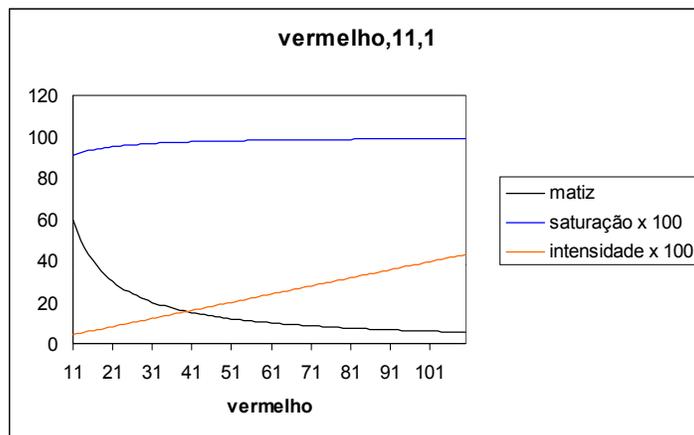
(a)



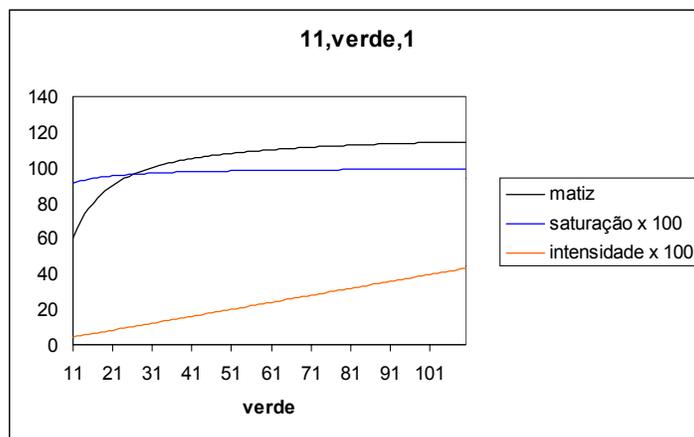
(b)

Fig. 2.13 - Curvas de matiz (preto), saturação (azul) e brilho (laranja) iniciando a partir de uma situação com baixa saturação.

A Figura 2.15, mostra os gráficos de valor de matiz em três (Figura 2.15a) e duas dimensões (Figura 2.15b) para as coordenadas em RGB, mantendo-se o valor da coordenada em azul com $B=100$, e as coordenadas de vermelho (R) e verde (G) variando de 0 a 255. Valores próximos a $RGB=(100,100,100)$, com valores de saturação próximos de zero, verifica-se grande tendência de variação dos valores de matiz. À medida em que afasta-se radialmente da coordenada $(100,100,100)$, a superfície de matiz apresenta variações (inclinações) menos acentuadas.

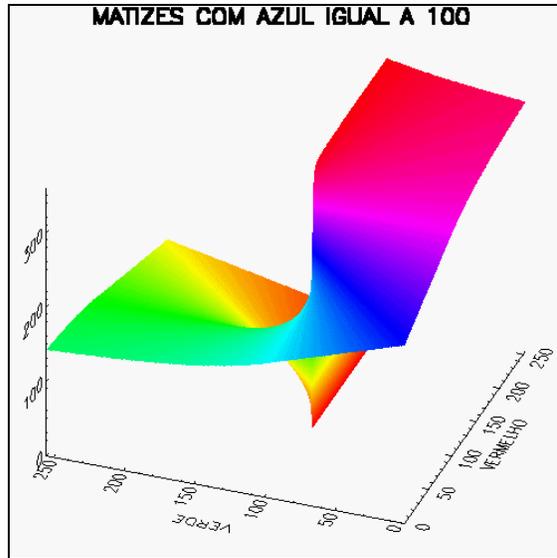


(a)

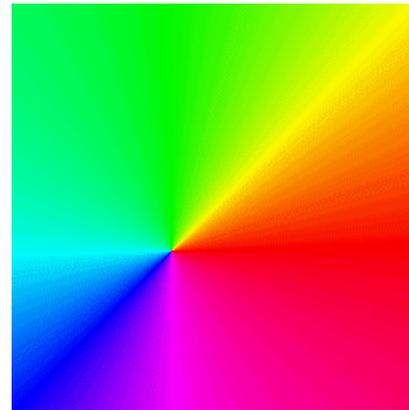


(b)

Fig. 2.14 - Curvas de matiz (preto), saturação (azul) e brilho (laranja) iniciando a partir de uma situação com baixo brilho.



(a)



(b)

Fig. 2.15 - Gráfico tridimensional (a) e bidimensional (b) de matiz para as coordenadas no espaço RGB, a um valor constante igual a 100 do componente referente a cor azul.

2.3.2.2. - Método de Moik

Normalmente para obter-se os atributos de cores, se requer a imagem de uma composição colorida para, a partir desta, converter as coordenadas em RGB dos pixels da imagem em coordenadas em HSV, por exemplo. Moik (1980) propôs um método onde estes atributos são obtidos independentemente de haver uma composição colorida previamente disponibilizada.

Moik denomina os atributos de cores de “Hue”, “Saturation” e “Brightness” - Matiz, Saturação e Brilho, respectivamente. Não há, no entanto, qualquer diferença de ordem prática entre o componente Brilho e Valor da representação HSV. Seja então f_k o valor do nível de cinza do pixel (i, j) da k -ésima banda da imagem, os componente matiz (H), saturação (S) e Brilho (B) serão dados por:

$$H(i, j) = \tan^{-1} \frac{\sum_{k=1}^N f_k(i, j) \sin \phi_k}{\sum_{k=1}^N f_k(i, j) \cos \phi_k} \quad (2.9)$$

$$S(i, j) = 1 - \frac{\min f_k(i, j)}{\max f_k(i, j)} \quad (2.10)$$

$$B(i, j) = \frac{\max f_k(i, j)}{\max f} \quad (2.11)$$

com

$i = 1, 2, \dots$, número de colunas da imagem;

$j = 1, 2, \dots$, número linhas da imagem.

onde:

- N é o número de bandas;
- $\max f$ é o máximo valor de brilho encontrado nas N bandas;
- ϕ_k é o ângulo atribuído a cada banda da imagem.

Para N bandas, os ângulos serão dados por $\phi_i = \phi_{i-1} + 360^\circ/N$, com $i = 3, 4, \dots, N$ e $\phi_1 = 0^\circ$.

Cada banda espectral esta espaçada igualmente em fase uma da outra no espaço de cores, representado uma fase entre 0 e 360 graus, ou a um vértice no "gamut" do diagrama de cromaticidade, o qual será agora um polígono de N lados. O "gamut" será um triângulo na situação específica de $N=3$.

Foram comparadas uma imagem de matiz, obtida com três bandas ($N=3$) pelo método de Moik (denominada de H_{moik}), com a imagem de matiz obtida pelo método implementado no "software" IDL (denominada de H_{hsv}), o qual baseia-se no espaço HSV. A imagem utilizada foi a de Caçapava, com composição colorida RGB/TM345.

Foi realizada uma operação de subtração entre H_{moik} e H_{hsv} , a fim de se obter uma imagem de diferença absoluta, para avaliar a semelhança entre as imagens de matiz obtidas

através dos dois métodos. A imagem de diferença é dada então por, $Abs_Dif = \mathbf{abs}(H_moik \text{ e } H_hsv)$, onde $\mathbf{abs}()$ é uma função que retorna o valor absoluto de um resultado.

TABELA 2.2 - Diferenças Encontradas entre os Valores de Matiz Obtidos Pelo Método de Moik pela Transformação RGB–HSV.

Diferença	Pixels	Percentual
0	86772	31,8254%
1	179453	65,8181%
2	6341	2,3257%
296	32	0,0117%
315	4	0,0015%
359	16	0,0059%
360	32	0,0117%
	272650	100,00%

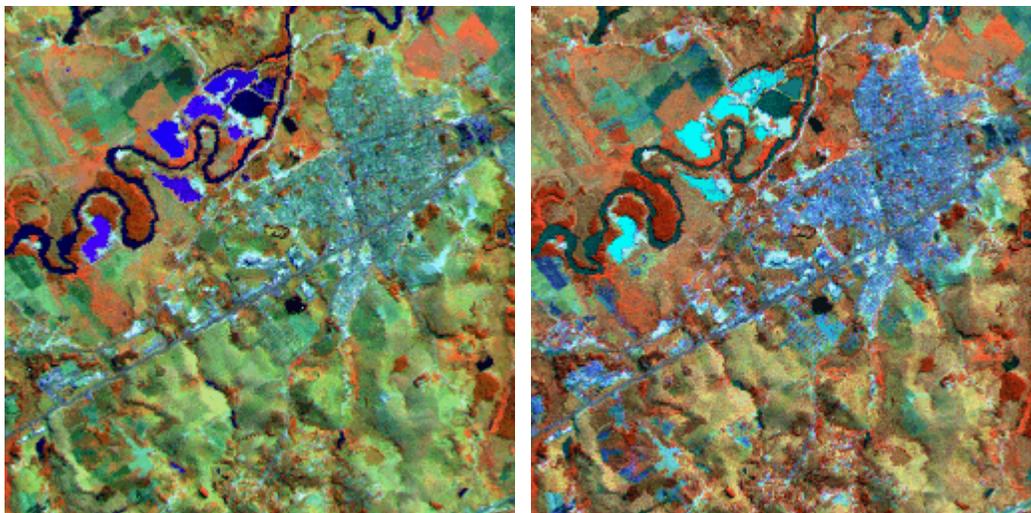
A Tabela 2.2, mostra na primeira coluna as diferenças absolutas encontradas quando fez-se a subtração. Não houve diferença em 86.772 pixels, ou em 31,83% dos pixels da imagem de matiz. Houve diferença em uma ou duas unidades de valor de matiz, em cerca de 68% dos pixels, o que pode-se atribuir a diferenças de arredondamento em etapas dos algoritmos. No entanto esta diferença de uma ou duas unidades de matiz, em diversos pixels espalhados sobre a imagem, é muito pequena para que se perceba visualmente, ou para que comprometa o resultado de uma classificação posterior.

Diferenças iguais a 359 e 360 foram encontradas em 48 pixels. A explicação destes altos valores se deve ao fato do matiz ser um dado angular, ou seja, um pixel que valha 359 em H_moik , pode valer 0 em H_hsv , e vice-versa. As diferenças realmente grandes se verificaram em 32 pixels onde os valores de matiz distam de 296 unidades, e em outros 4 pixels onde a diferença foi de 315 unidades. Entretanto, estes pixels são uma parcela muito pequena (0,0074%) da imagem. Logo, o método de Moik e o de transformação RGB-HSV, são compatíveis para três bandas espectrais.

2.3.2.3. - Transformar Atributos de Cores em RGB

O caminho de volta justifica-se ao querer simular uma composição três canais do RGB, a partir de atributos de cores obtidos por meio de mais de três bandas espectrais. Para isso utilizou-se o algoritmo de conversão implementado na linguagem IDL, que realiza a transformação HSV-RGB.

Duas imagens coloridas de Caçapava-SP, foram geradas para ilustrar as diferenças entre uma composição RGB normal (TM4, TM5 e TM3) e outra, resultado de uma simulação de três bandas a partir de quatro ou mais bandas (TM4, TM5, TM3 e TM7), via método descrito por Moik. Espera-se, a princípio, que por esta ser uma composição formada a partir de mais bandas, haverá uma melhor separabilidade entre os alvos presentes num cena.



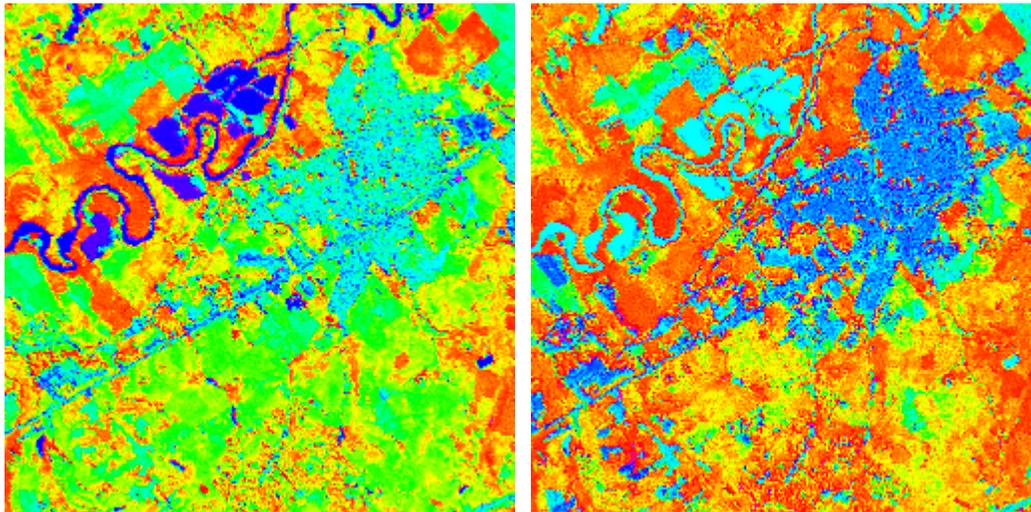
(a)

(b)

Fig. 2.16 - Composição TM453 (a) e simulação TM4537 (b). Nota-se que na composição com quatro bandas o alvo urbano em azul, se destaca mais do restante da cena.

Observa-se que na composição obtida com quatro bandas mostrada à Figura 2.16b, houve uma melhor distinção de áreas urbanizadas, quando comparada com a composição vista na Figura 2.16a. Isto fica ainda mais perceptível visualmente na imagem de matiz das duas composições (Figura 2.17).

Apesar de haver ganho na separabilidade do alvo urbano, na composição TM4537 há perda de informação espectral inerente do alvo nas bandas. Isto porque as imagens dos canais RGB da composição TM4537, não correspondem a quaisquer bandas do sensor TM, mas sim a uma simulação das quatro bandas espectrais originais em três.



(a)

(b)

Fig. 2.17 - Componente matiz do espaço de atributos:
(a) matiz da composição TM453;
(b) matiz da composição TM4537.

2.3.2.4. - Cálculo de Valores Médios do Componente Matiz

Uma das peculiaridades dos valores de matiz é a sua natureza circular, devido a se tratarem de valores angulares. Portanto, a aplicação de média aritmética simples nem sempre retrataria com fidelidade o valor médio correspondente a um conjunto de matizes de distintos valores. É apresentada nesta Seção, a maneira como foi calculado o valor médio de matiz de conjuntos de pixels na imagem.

Na Figura 2.18a, em branco está a representação dos raios para os ângulos de 40° e 340° e em preto o ângulo correspondente a média aritmética entre eles, ou seja, 190° . Logicamente que esse valor não tem significado, pois o ângulo requerido é aquele que se situa na **metade do arco menor** formado pelos dois ângulos em questão, que na realidade é o ângulo de 10° , como mostrado na Figura 2.18b.

Portanto uma maneira diferente de cálculo de média se faz necessária. Supõe-se os valores angulares de matiz como sendo os argumentos de vetores unitários, cuja a soma vetorial entre eles dá um vetor resultante. Logo, o seu argumento será o valor médio dos argumentos dos vetores unitários.

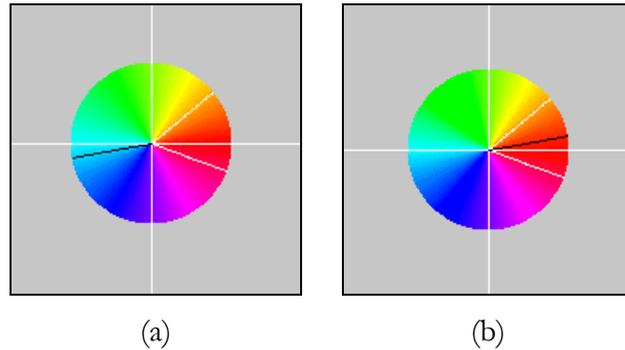


Fig. 2.18 - (a) Resultado da média aritmética simples.
 (b) Valor médio real entre dois valores extremos de matiz.
 FONTE: Gerada a partir de algoritmo implementado na linguagem IDL.

Seja $v_k = \cos(h_k) \mathbf{i} + \text{sen}(h_k) \mathbf{j}$ o vetor unitário onde h_k é o ângulo que representa o k -ésimo componente matiz, \mathbf{i} e \mathbf{j} são os vetores unitários direcionais, respectivamente dos eixos x e y do sistema de coordenadas cartesianas no plano.

A soma vetorial de n vetores é dada por:

$$v = a \mathbf{i} + b \mathbf{j} \quad (2.12)$$

onde,

$$a = \sum_{k=1}^n \cos(h_k) \quad (2.13)$$

e

$$b = \sum_{k=1}^n \text{sen}(h_k) \quad (2.14)$$

Logo, o valor médio dos n componentes matiz será:

$$\bar{H} = \arg(v) = \arctan\left(\frac{b}{a}\right) \quad (2.15)$$

A Equação 2.9, utilizada para obter o matiz de um pixel através de N bandas espectrais, é semelhante à Equação 2.15. A diferença reside no fato de que na primeira, cada elemento tem um peso dado pelo valor digital na sua banda respectiva, no cálculo do matiz de um pixel. No caso da segunda, todos os componentes contribuem igualmente no cálculo do matiz médio de um conjunto de n valores de matiz.

CAPÍTULO 3

CLASSIFICAÇÃO E AVALIAÇÃO ESTATÍSTICA

Tão importante quanto realizar uma classificação de qualidade é conhecer-se o quão boa realmente a mesma é. Com este propósito, foram realizadas avaliações estatísticas dos resultados de classificação obtidos neste trabalho. Uma breve visão geral sobre classificação, seguida por uma explicação detalhada dos métodos estatísticos empregados compõem o conteúdo deste capítulo.

3.1. - Classificação de Imagens

Os métodos de classificação de imagens podem ser divididos entre aqueles que se utilizam de informações das classes que devem encontrar na imagem, e aqueles que procuram as classes sem nenhuma informação prévia. A estes cunhou-se o termo de não-supervisionados, enquanto que os primeiros são denominados métodos supervisionados.

Os métodos supervisionados baseiam-se na informação de amostras de pixels de cada classe que se queira identificar na cena. Estas amostras contêm atributos, que podem ser por exemplo o valor médio dos pixels e a sua variância. A partir da informação destes atributos é que se é possível atribuir um pixel da cena a uma classe predeterminada.

Nos métodos não-supervisionados não se tem qualquer informação prévia sobre os alvos presentes na cena. Uma das técnicas utilizadas, baseia-se na resposta espectral dos pixels da imagem em uma banda espectral - através do seu histograma - ou mais, através do método de “clustering”. Este método tem este nome por levar em conta os agrupamentos (“clusters”) de pixels, formados a partir da resposta espectral dos mesmos em duas ou mais bandas. Cada “cluster” representa o comportamento característico de um determinado alvo, a partir de uma amostragem, em um conjunto de bandas espectrais

Outras técnicas, baseiam-se na distribuição espacial dos valores dos pixels. A segmentação é uma destas técnicas. Dentre os algoritmos de segmentação de imagem, existem aqueles

que se baseiam na descontinuidade e os que se baseiam na similaridade dos atributos da imagem. Como exemplos do primeiro tipo, destacam-se os filtros detetores de bordas e bacias e os filtros direcionais. Utilizou-se neste trabalho um algoritmo do segundo tipo, denominado crescimento de regiões.

3.1.1. - Crescimento de Regiões

A idéia desta técnica é de se obter as regiões homogêneas da imagem a partir da informação de apenas alguns pixels, chamados de sementes. Os pixels vizinhos aos sementes que se enquadrarem ao predicado lógico preestabelecido (que pode ser a média, textura, cor dos pixels), serão agregados em uma região. Esse procedimento se repete até que todos os pixels similares estejam agregados a uma região.

Por exemplo, um critério de agregação que é possível adotar para selecionar os pixels que serão agregados a região é o valor absoluto da diferença entre o ND do pixel candidato e o valor médio dos pixels da região. Se esta diferença for menor que um limite, determinado pelo usuário, o pixel candidato é agregado à região.

A escolha tanto dos pixels sementes, quanto o critério de agregação é feita pelo usuário e conforme a sua necessidade e conveniência. Geralmente, essa escolha é norteadada pelo tipo de aplicação a que essa imagem destina-se. Se for, por exemplo, para discriminar na imagem o que pertence à classe solo, água e vegetação, convém escolher um pixel de cada classe como semente.

Segundo Gonzalez e Woods (1992), a técnica de crescimento de regiões se adequa aos critérios de segmentação dados por:

$$(i) \quad \bigcup_{i=1}^n R_i = R$$

$$(ii) \quad R_i \text{ é uma região conectada, } i = 1, 2, \dots, n$$

$$(iii) \quad R_i \cap R_j = \emptyset \text{ para todo } i \text{ e } j, \text{ com } i \neq j$$

$$(iv) \quad P(R_i) = \text{VERDADEIRO para } i = 1, 2, \dots, n$$

$$(v) \quad P(R_i \cup R_j) = \text{FALSO para } i \neq j$$

O primeiro critério estabelece que todos os pixels terão de pertencer a uma das subregiões resultantes da segmentação da região R . O critério (ii) refere-se a conectividade dos pontos de cada subregião. Dois pixels são ditos conectados se o ND a eles atribuídos pertencerem a um mesmo conjunto de NDs e, além disso, satisfizerem uma condição de vizinhança entre ambos. Em (iii), assegura-se que nenhum pixel pertença a mais de uma subregião. O quarto critério verifica se os pixels da subregião obedecem a um critério de seleção, isto é, um predicado lógico P . Finalmente, o último critério garante que duas regiões sejam diferentes, de acordo com o critério de seleção estabelecido.

3.2. - Avaliação Estatística

Uma das principais justificativas apresentadas para utilizar os atributos de cores na tarefa de distinção de alvos numa cena, é a de que esses atributos melhor representam o modo como o ser humano percebe as cores presentes nesta cena. Espera-se que o resultado visual de uma classificação no componente matiz do espaço de atributos de cores corresponda a essa tendência.

Embora esta avaliação qualitativa possa se aparentar satisfatória visualmente, ela não pode ser considerada exaustiva quando se pretende avaliar corretamente o resultado da segmentação. É por este motivo que foram adotados alguns parâmetros estatísticos com o propósito de aprovar ou rejeitar o resultado de uma segmentação, ou seja, utilizou-se uma avaliação quantitativa para reforçar - ou não - o que a análise visual dos resultados nos informa.

Dois métodos foram utilizados: cálculo do coeficiente kappa (κ) e teste de exatidão de mapas temáticos a partir da função de densidade de probabilidade (**fdp**) binomial dos erros de classificação que ocorrem na amostragem de dados da cena.

Faz-se, portanto, necessário apresentar uma abordagem sobre os fundamentos estatísticos do comportamento dos dados os quais foram trabalhados, bem como dos testes que foram utilizados para avaliar o resultados das classificações.

3.2.1. - Teste de Hipótese

Na impossibilidade de se analisar a totalidade de uma população, foram analisadas amostras da mesma e, com base nas informações obtidas a partir da amostragem, é possível formular algumas suposições - hipóteses - sobre o todo, que podem ser válidas ou não. O método de comprovação ou reprovação destas suposições é denominado **teste estatístico**. Os conceitos apresentados a seguir tiveram como fonte de consulta Trivedi (1982).

Parte-se de uma **hipótese nula** H_0 com relação a um parâmetro estatístico da distribuição da amostra, onde se deseja refutá-la em favorecimento a **hipótese alternativa** H_1 , que contradiz a H_0 . Testou-se se a hipótese (H_0), a qual pode ser refutada ou não.

Por exemplo, é desejado testar a hipótese da exatidão global (ξ_g) de uma classificação ser igual a um limiar estabelecido como aceitável (ξ_0). Então esta é considerada como sendo a hipótese nula $\xi_g = \xi_0$. E a hipótese alternativa é aquela onde considera a exatidão global menor do que o limiar, $\xi_g < \xi_0$.

Chama-se de **erro (ou risco) do tipo I**, a probabilidade da hipótese nula H_0 ser rejeitada quando ela é de fato verdadeira. Analogamente, quando a hipótese alternativa H_1 é aceita quando falsa, ocorre aí o **erro (ou risco) do tipo II**. A probabilidade de o primeiro tipo de erro ocorrer dá-se o nome de **nível de significância** do teste, ou simplesmente α . Já a probabilidade do segundo tipo de erro acontecer, é notada por β .

O que se deseja é que estes erros sejam os menores possíveis. No entanto, para um número fixo n de amostras, um decréscimo em um tipo de erro, acarreta em um acréscimo no outro. A única maneira de diminuir a probabilidade do dois erro é ao aumentar o número de amostras, na dependência de isto ser viável, tanto do ponto de vista logístico como econômico, de acordo com a situação prática.

3.2.2. - Avaliação Através do Coeficiente Kappa ($\hat{\kappa}$)

Este método encontra-se entre os mais difundidos na tarefa de avaliação do resultado de uma classificação ou interpretação visual de imagens orbitais ou aéreas. A boa aceitação do método se deve em parte por ele ser um bom estimador da qualidade da fotointerpretação/classificação com relação a verdade do terreno.

A vantagem do coeficiente kappa sobre a exatidão global de uma classificação, reside no fato de que, diferentemente desta, o cálculo do kappa estimado leva em conta o erros de classificação em cada alvo de interesse. Ou seja, a exatidão global é um valor superestimado da qualidade da classificação, enquanto o kappa estimado é um valor mais ponderado e aproximado da realidade.

O seu uso se tornou mais difundido entre a comunidade usuária de Sensoriamento Remoto, a partir da divulgação dos resultados do artigo de Congalton e Mead (1983), que utilizaram o coeficiente kappa e a sua variância para, além de estimar a similaridade entre a fotointerpretação e a verdade de terreno, fazer comparações entre as diferentes fotointerpretações, através de teste de hipótese.

O valor de kappa é obtido a partir da **matriz de confusão** da classificação, que tabula a quantidade de acertos e erros na classificação de cada alvo. Os valores de referência, que são em tese a verdade do terreno, são dispostos nas colunas, enquanto que os valores da classificação posicionam-se nas linhas. Exemplo de matriz de confusão é mostrado na Tabela 3.1.

Por definição, denomina-se erro o fato de atribuir-se um ponto uma classe diferente da qual ele realmente pertence. Erro de omissão é este erro do ponto de vista da referência, isto é, da verdade de campo, para o conjunto de pontos que pertencem a cada alvo de interesse. E do ponto de vista da classificação, para o seu próprio conjunto de pontos em cada alvo, este erro é dito de erro de inclusão.

TABELA 3.1 - Exemplo de Matriz de Confusão.

		Referência			Total	Inclusão
		A	B	C		
A		30	4	5	39	23,08%
B		1	52	2	55	5,45%
C		4	3	41	48	14,58%
Total		35	59	48	142	
Omissão		14,29%	11,86%	14,58%		

A partir da construção da matriz de confusão, o estimador de kappa é calculado segundo a seguinte expressão matemática, originalmente obtida por Cohen (1960), segundo :

$$\hat{k} = \frac{n \sum_{i=1}^r x_{ii} - \sum_{i=1}^r x_{i+} x_{+i}}{n^2 - \sum_{i=1}^r x_{i+} x_{+i}} \quad (3.1)$$

onde n é o tamanho da amostra, isto é, o número de pontos amostrados; e r é número de alvos. Para o exemplo dado, $n = 142$ e $r = 3$. O sinal de mais, representa a soma dos elementos na linha/coluna correspondente. Para o exemplo dado na Tabela 3.1, teremos:

$$\sum_{i=1}^3 x_{ii} = x_{11} + x_{22} + x_{33} = 30 + 52 + 41 = 123$$

$$\sum_{i=1}^3 x_{i+} x_{+i} = 39 * 35 + 55 * 59 + 48 * 48 = 1365 + 3245 + 2304 = 6914$$

Então o valor do coeficiente kappa fica:

$$\hat{k} = \frac{142 * 123 - 6914}{142^2 - 6914} = \frac{17466 - 6914}{20164 - 6914} = \frac{10552}{13250} = 0,7964$$

O coeficiente kappa assume seu maior valor quando a classificação for perfeita. Neste caso, a matriz de confusão só terá elementos na diagonal principal. Pixels, então

teremos, $\sum_{i=1}^r x_{ii} = n$, que se substitui-se na Eq. 3.1.

$$\hat{k} = \frac{n^2 - \sum_{i=1}^r x_{i+} x_{+i}}{n^2 - \sum_{i=1}^r x_{i+} x_{+i}} = 1$$

Então, o maior valor possível do coeficiente kappa é $\hat{k} = 1$. Quando nenhum dos pontos for corretamente classificado, temos o caso oposto, isto é, de menor valor de kappa.

$$\hat{k} = \frac{-\sum_{i=1}^r x_{i+} x_{+i}}{n^2 - \sum_{i=1}^r x_{i+} x_{+i}}$$

Dividindo o numerador e denominador por $\sum_{i=1}^r x_{i+} x_{+i}$, têm-se

$$\hat{k} = \frac{-1}{\left(\frac{n^2}{\sum_{i=1}^r x_{i+} x_{+i}} - 1 \right)} \quad (3.2)$$

O valor do estimador de kappa terá seu menor valor negativo quando o denominador alcançar seu mínimo valor. Isto ocorrerá quando a razão $n^2 / \sum_{i=1}^r x_{i+} x_{+i}$ for mínima.

Reescrevendo esta razão como

$$g(x, y) = \frac{\left(\sum_{i=1}^r x \right)^2}{\sum_{i=1}^r xy} \quad (3.3)$$

onde

$$x = x_{i+} \text{ e } y = x_{+i} \text{ com } \sum_{i=1}^r x = n$$

Do cálculo diferencial, vem que a função $g(x, y)$ tem valor extremo (mínimo ou máximo) quando suas derivadas parciais em relação a x e y são iguais a zero. Ou seja, quando

$$\frac{\partial g(x, y)}{\partial x} = 0 \quad \text{e} \quad \frac{\partial g(x, y)}{\partial y} = 0$$

Para este caso basta efetuar uma derivada parcial, pois $\sum_{i=1}^r x = \sum_{i=1}^r y$

A derivada parcial de $g(x, y)$ é dada por

$$\frac{\partial g(x, y)}{\partial x} = \frac{\sum x [2 \sum xy - (\sum x)(\sum y)]}{(\sum xy)^2} = 0$$

Então, a função $g(x, y)$ terá valor mínimo, quando acontecer

$$2 \sum xy - (\sum x)(\sum y) = 0$$

$$2 \sum xy = (\sum x)(\sum y)$$

$$2 \sum xy = nn$$

$$2 \sum xy = n^2 \tag{3.4}$$

Substituindo a Equação 3.4 na fórmula de kappa dada pela Equação 3.2, teremos:

$$\hat{k} = \frac{-1}{\left(\frac{2 \sum xy}{\sum xy} - 1 \right)} = \frac{-1}{(2-1)} = -1$$

Então, o menor valor possível do coeficiente kappa é $\hat{k} = -1$.

Podemos também escrever o estimador kappa numa forma simplificada.

$$\hat{k} = \frac{\theta_1 - \theta_2}{1 - \theta_2} \tag{3.5}$$

onde

$$\theta_1 = \sum_{i=1}^r x_{ii} / n \quad \text{e} \tag{3.6}$$

$$\theta_2 = \sum_{i=1}^r x_{i+} x_{+i} / n^2 \tag{3.7}$$

O estimador da variância de kappa para amostras de grande tamanho n , segundo Hudson e Ramm (1987) foi corretamente formulado por Fleiss et al. (1969) e apresentado assim por Bishop et al. (1975).

$$\hat{\sigma}(\hat{\kappa}) = \frac{1}{n} \left[\frac{\theta_1(1-\theta_1)}{(1-\theta_2)^2} + \frac{2(1-\theta_1)(2\theta_1\theta_2 - \theta_3)}{(1-\theta_2)^2} + \frac{(1-\theta_1)^2(\theta_4 - 4\theta_2)^2}{(1-\theta_2)^4} \right] \quad (3.8)$$

onde

$$\theta_3 = \sum_{i=1}^r x_{ii}(x_{i+} + x_{+i})/n^2 \quad \text{e} \quad (3.9)$$

$$\theta_4 = \sum_{\substack{i=1 \\ j=1}}^r x_{ij}(x_{j+} + x_{+i})^2/n^3 \quad (3.10)$$

Para o exemplo dado na Tabela 3.1, o valor de kappa é $\hat{\kappa} = 0,796$, enquanto que a variância é $\hat{\sigma}(\hat{\kappa}) = 0,00186$. Para ser possível afirmar que duas matrizes de confusão são significativamente diferentes ou não, adota-se um teste de hipótese sobre a diferença de kappas. De acordo com Congalton e Mead (1983), este teste é possível porque, embora a os dados sejam discretos, para uma amostra de tamanho suficientemente grande, a distribuição de kappa é gaussiana.

Seja a hipótese nula:

$$H_o : \hat{\kappa}_1 - \hat{\kappa}_2 = 0$$

e a estatística Z

$$\frac{\hat{\kappa}_1 - \hat{\kappa}_2}{\sqrt{\hat{\sigma}_1^2 + \hat{\sigma}_2^2}} = Z \quad (3.11)$$

onde

- $\hat{\kappa}_1$ e $\hat{\kappa}_2$ são os estimadores de κ_1 e κ_2 computados segundo a Equação (3.1);

- $\hat{\sigma}_1^2$ e $\hat{\sigma}_2^2$ são os estimadores das variâncias σ_1^2 e σ_2^2 , obtidas segundo a Equação (3.8).

Então, para uma nível de significância α , as regiões críticas para o teste estatístico são especificadas por:

Para os testes unilaterais:

$$\begin{aligned} Z < -z_\alpha, & \quad \text{se } H_1 : \hat{\kappa}_1 - \hat{\kappa}_2 < 0 \\ Z > z_\alpha, & \quad \text{se } H_1 : \hat{\kappa}_1 - \hat{\kappa}_2 > 0 \end{aligned}$$

Para o teste bilateral:

$$|Z| > z_{\alpha/2}, \quad \text{se } H_1 : \hat{\kappa}_1 - \hat{\kappa}_2 \neq 0$$

onde $z_{\alpha/2}$ é um valor crítico, a um nível de significância α , para o qual se o módulo de Z for maior, a hipótese alternativa é aceita no teste bilateral.

3.2.3. - Avaliação Através do Método de Amostragem por Nível de Aceitação

Um aspecto importante que é levado em conta quando se vai estabelecer a quantidade de pontos numa avaliação estatística, é o da viabilidade tanto econômica quanto temporal para colher os dados da amostragem contendo um número n de pontos aleatórios. Este número não pode ser grande a ponto de demandar um tempo demasiado para coletar os dados, ou de gerar um alto custo operacional. É necessário, no entanto, que exista um número de pontos suficiente a fim de que a amostragem seja uma boa representação da cena inteira, isto é, que represente bem as diferentes classes presentes na cena.

Foi pensando justamente numa maneira de determinar um tamanho de amostra mínimo, tendo por trás uma forte justificativa estatística, que Van Genderen et al. (1978) propuseram um método baseado na probabilidade de haver x erros de classificação em uma amostragem contendo n pontos. Esta probabilidade é dada pelo valor da função de densidade de probabilidade binomial em x , a qual é escrita como:

$$f(x, n, P) = \frac{n!}{(n-x)!x!} Q^x P^{n-x} \quad (3.12)$$

onde

x é número de erros de classificação

P é a exatidão especificada (ou nominal) do mapa temático

$Q = 1 - P$, a probabilidade de um ponto do mapa ser mal classificado.

A expressão que descreve qual a probabilidade de existir **no máximo** x erros é dada pela expansão binomial:

$$(P + Q)^x = \sum_{i=0}^x C_i^x Q^i P^{x-i} \quad (3.13)$$

onde C_i^x é a combinação de x elementos num conjunto de i elementos.

Por exemplo, a probabilidade de haver 50 ou menos pontos mal classificados é dado pelo somatório:

$$\begin{aligned} (P + Q)^{50} &= \sum_{i=0}^{50} C_i^{50} Q^i P^{50-i} & (3.14) \\ &= C_0^{50} Q^0 P^{50} + C_1^{50} Q^1 P^{49} + C_2^{50} Q^2 P^{48} + \dots + C_{49}^{50} Q^{49} P^1 + C_{50}^{50} Q^{50} P^0 \\ &= P^{50} + 50QP^{49} + 1225Q^2P^{48} + \dots + 50Q^{49}P^1 + Q^{50} \\ &= \text{Pr}[0 \text{ erros}] + \text{Pr}[1 \text{ erro}] + \text{Pr}[2 \text{ erros}] + \dots + \text{Pr}[49 \text{ erros}] + \text{Pr}[50 \text{ erros}] \\ &= \text{Pr}[50 \text{ erros ou menos}] \end{aligned}$$

Segundo Van Genderen et al. (1978), até então, as propostas apresentadas para determinar o tamanho de amostra (n), ora não apresentavam uma fundamentação matemática consistente, ora eram de difícil execução, pois os parâmetros envolvidos eram de difícil determinação.

A Tabela 3.2 informa a probabilidade de não haver erros de classificação para vários tamanhos de amostra (n) em mapas com diferentes valores de exatidão nominal (P). Abaixo da linha cheia, para um tamanho n de amostra, a probabilidade de aceitar que o mapa não contém erros de classificação é maior que 0,05.

Com esses valores de probabilidade pode-se então encontrar o tamanho de amostra mínimo no qual, supondo uma exatidão nominal para o mapa temático, a probabilidade de aceitar que o mapa não contém erros de classificação seja inferior a um valor α por ele determinado. No exemplo dado, o valor α escolhido é 0,05.

TABELA 3.2 - PROBABILIDADE DE NENHUM PONTO SER MAL CLASSIFICADO $P(x = 0)$ DADOS O TAMANHO DA AMOSTRAGEM (n) E A EXATIDÃO NOMINAL DO MAPA TEMÁTICO (P)

$x = 0$	N										
P	5	10	15	20	25	30	35	40	45	50	60
0,99	0,9510	0,9044	0,8601	0,8179	0,7778	0,7397	0,7034	0,6690	0,6362	0,6050	0,5472
0,95	0,7738	0,5987	0,4633	0,3585	0,2774	0,2146	0,1661	0,1285	0,0994	0,0769	0,0461
0,9	0,5905	0,3487	0,2059	0,1216	0,0718	0,0424	0,0250	0,0148	0,0087	0,0052	0,0018
0,85	0,4437	0,1969	0,0874	0,0388	0,0172	0,0076	0,0034	0,0015	0,0007	0,0003	0,0001
0,8	0,3277	0,1074	0,0352	0,0115	0,0038	0,0012	0,0004	0,0001	0,0000	0,0000	0,0000
0,7	0,1681	0,0282	0,0047	0,0008	0,0001	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
0,6	0,0778	0,0060	0,0005	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
0,5	0,0313	0,0010	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000

FONTE: Adaptada de Van Genderen et al. (1978).

Já a Tabela 3.3, mostra o risco de, não somente de aceitar que um mapa não contenha erros, mas de também aceitar que o mapa tenha x erros de classificação, dada a sua exatidão nominal. Em cada coluna há uma linha que marca a posição onde a probabilidade acumulada de x é a mais aproximada de 0,05. Exemplificando, na coluna de $x = 3$, a linha onde a probabilidade acumulada mais se aproxima do valor 0,05 é a linha correspondente a $n = 50$.

De fato, pois quando $n = 50$

$$\Pr(x = 0) + \Pr(x = 1) + \Pr(x = 2) + \Pr(x = 3) = 0,0003 + 0,0026 + 0,0113 + 0,0319 = 0,0461$$

Embora este método tenha o mérito de determinar um tamanho de amostra ótimo, de modo a minimizar o risco de o usuário aceitar um mapa temático que esteja fora das especificações por ele requeridas, ao mesmo tempo não prevê qual a probabilidade de que um mapa dentro destas especificações seja rejeitado.

TABELA 3.3 - PROBABILIDADE DE OCORREREM \times ERROS DE CLASSIFICAÇÃO DADO O TAMANHO DA AMOSTRAGEM (n) PARA UMA EXATIDÃO NOMINAL DE $P = 0,85$

n	x					
	0	1	2	3	4	5
15	0,0874	0,2312	0,2856	0,2184	0,1156	0,0449
20	0,0388	0,1368	0,2293	0,2428	0,1821	0,1028
25	0,0172	0,0759	0,1607	0,2174	0,2110	0,1564
30	0,0076	0,0404	0,1034	0,1703	0,2028	0,1861
35	0,0034	0,0209	0,0627	0,1218	0,1719	0,1881
40	0,0015	0,0106	0,0365	0,0816	0,1332	0,1692
45	0,0007	0,0053	0,0206	0,0520	0,0963	0,1394
50	0,0003	0,0026	0,0113	0,0319	0,0661	0,1072
55	0,0001	0,0013	0,0061	0,0189	0,0434	0,0781
60	0,0001	0,0006	0,0032	0,0110	0,0275	0,0544
65	0,0000	0,0003	0,0017	0,0062	0,0170	0,0365

FONTE: Adaptada de Van Genderen (1978).

De acordo com Ginevan (1979), um método de amostragem dos pontos de uma cena deve basicamente considerar três critérios:

- 1) Deve haver baixa probabilidade de o consumidor aceitar um mapa temático com uma exatidão inferior ao pedido;
- 2) Deve haver alta probabilidade de o consumidor aceitar um mapa temático com uma exatidão superior ao pedido;
- 3) Deve requerer um número mínimo de pontos, a fim de que não onere a sua posterior verificação em campo

Foi calcado nestas premissas que ele aprimorou a idéia de encontrar um tamanho mínimo necessário, já que, diferentemente do desenvolvimento anterior, leva em consideração a chance de um mapa de boa qualidade ser rejeitado. Isso torna a escolha do tamanho da amostragem mais apurada, principalmente do ponto de vista do produtor do mapa temático.

Esta chance de o mapa ser recusado indevidamente, é chamada de **Risco do produtor** (R_p). Já a chance de um mapa ser de qualidade inferior ao especificado pelo cliente ser

aceito, recebe o nome de **Risco do usuário** (Ru). E as exatidões especificada pelo produtor e requerida pelo usuário são identificadas como **Probabilidade do produtor** (Pp) e **Probabilidade do usuário** (Pu), respectivamente.

Como visto anteriormente, o somatório das fdp binomiais para uma amostra de tamanho n , com uma exatidão nominal P, não deveria ultrapassar um limite α . Portanto, para o x que correspondesse ao maior número de erros o qual este somatório não ultrapasse α , é denominado x_c (x crítico). Esta idéia é expressa pela inequação abaixo:

$$\sum_{x=0}^{x_c} f(x, n, Pu) \leq \alpha \quad (3.15)$$

Note que é entrado com o valor de Pu ao invés de Pp, pois a exatidão nominal em questão é a requerida pelo usuário e não a especificada pelo produtor. E o valor de α corresponde ao Ru, enquanto que o somatório é o **Risco exato do usuário** (Ru exato).

De posse do valor de x_c , o produtor pode estimar que risco ele correrá de o seu mapa ser rejeitado, mediante o cálculo da probabilidade de haver um número x maior do que x_c de erros, considerando ele ter um mapa com exatidão nominal Pp, sendo normalmente $Pp > Pu$. Esse risco (Rp), é dado pelo somatório:

$$\beta = \sum_{x=x_c+1}^n f(x, n, Pp) \quad (3.16)$$

Este é o somatório das fdp binomiais restantes, variando o número de erros na amostra de $x_c + 1$ até uma situação onde todos os pontos da amostragem são mal classificados, ou seja, $x = n$. A Tabela 3.4 mostra valores de x crítico, Ru exato e Rp às exatidões nominais Pp=0,90, Pp=0,95 e Pp=0,99, com n variando de 30 a 50.

Devido ao fato de a distribuição dos dados ser discreta, observa-se que o valor de x_c permanece inalterado até que n tenha um valor que “permita” aumentar em uma unidade o

valor de x_c , isto é, que se aceite mais um ponto mal classificado sem que isso acarrete em um risco exato do usuário (Ru exato) maior do que o estipulado (Ru).

TABELA 3.4 - VALORES DE x_c , Ru exato E Rp

n	x_c	Ru exato ($P_u = 0,85$)	Rp		
			$P_p = 0,90$	0,95	0,99
30	1	0,0480	0,8163	0,4465	0,0361
31	1	0,0420	0,8304	0,4634	0,0384
32	1	0,0366	0,8436	0,4800	0,0407
33	1	0,0320	0,8558	0,4964	0,0430
34	1	0,0279	0,8671	0,5123	0,0454
35	1	0,0243	0,8776	0,5280	0,0479
36	1	0,0212	0,8874	0,5433	0,0503
37	1	0,0184	0,8964	0,5582	0,0529
38	1	0,0160	0,9047	0,5728	0,0555
39	1	0,0139	0,9124	0,5871	0,0581
40	2	0,0486	0,7772	0,3233	0,0075
41	2	0,0431	0,7914	0,3371	0,0080
42	2	0,0382	0,8049	0,3510	0,0086
43	2	0,0339	0,8176	0,3648	0,0092
44	2	0,0300	0,8296	0,3786	0,0098
45	2	0,0265	0,8410	0,3923	0,0104
46	2	0,0234	0,8516	0,4060	0,0110
47	2	0,0207	0,8617	0,4195	0,0117
48	2	0,0183	0,8711	0,4330	0,0124
49	2	0,0161	0,8800	0,4463	0,0131
50	3	0,0460	0,7497	0,2396	0,0016

FONTE: Adaptada de Ginevan (1979).

A Tabela 3.5 mostra, a partir de um valor fixo de $Ru = 0,05$, a quantidade máxima de erros permitida para uma amostragem de tamanho n , onde o risco do produtor é menor do que Ru , bem como o risco Rp que o produtor está correndo de o seu mapa com exatidão nominal Pp ser rejeitado.

TABELA 3.5 - TAMANHOS ÓTIMOS DE AMOSTRAGEM (n) E SEUS RESPECTIVOS VALORES DE X_C E R_p , PARA $P_U=0,85$ E $R_U=0,05$

n	xc	Ru exato ($P_u = 0.85$)	Rp		
			Pp = 0.90	0,95	0,99
19	0	0,0456	0,8649	0,6226	0,1738
30	1	0,0480	0,8163	0,4465	0,0361
40	2	0,0486	0,7772	0,3233	0,0075
50	3	0,0460	0,7497	0,2396	0,0016
59	4	0,0469	0,7152	0,1719	0,0003
68	5	0,0465	0,6859	0,1242	0,0001
76	6	0,0497	0,6467	0,0856	0,0000
85	7	0,0478	0,6247	0,0624	0,0000
93	8	0,0496	0,5919	0,0432	0,0000
102	9	0,0471	0,5746	0,0318	0,0000
110	10	0,0481	0,5464	0,0221	0,0000
118	11	0,0488	0,5203	0,0153	0,0000
126	12	0,0492	0,4959	0,0107	0,0000
134	13	0,0494	0,4731	0,0074	0,0000
142	14	0,0494	0,4518	0,0052	0,0000
150	15	0,0493	0,4318	0,0036	0,0000
158	16	0,0491	0,4130	0,0025	0,0000
166	17	0,0488	0,3954	0,0018	0,0000
174	18	0,0483	0,3787	0,0012	0,0000
182	19	0,0478	0,3630	0,0009	0,0000
190	20	0,0473	0,3481	0,0006	0,0000
197	21	0,0495	0,3252	0,0004	0,0000
205	22	0,0488	0,3122	0,0003	0,0000
213	23	0,0480	0,2998	0,0002	0,0000
220	24	0,0499	0,2802	0,0001	0,0000
228	25	0,0490	0,2693	0,0001	0,0000
236	26	0,0482	0,2589	0,0001	0,0000
243	27	0,0498	0,2421	0,0000	0,0000
251	28	0,0488	0,2329	0,0000	0,0000
259	29	0,0479	0,2242	0,0000	0,0000
266	30	0,0493	0,2097	0,0000	0,0000
274	31	0,0483	0,2020	0,0000	0,0000
281	32	0,0497	0,1890	0,0000	0,0000
289	33	0,0486	0,1821	0,0000	0,0000
296	34	0,0499	0,1704	0,0000	0,0000
304	35	0,0487	0,1643	0,0000	0,0000
311	36	0,0499	0,1537	0,0000	0,0000
319	37	0,0488	0,1483	0,0000	0,0000
326	38	0,0499	0,1388	0,0000	0,0000
334	39	0,0487	0,1339	0,0000	0,0000
341	40	0,0497	0,1253	0,0000	0,0000
349	41	0,0485	0,1210	0,0000	0,0000
356	42	0,0495	0,1133	0,0000	0,0000
364	43	0,0483	0,1094	0,0000	0,0000
371	44	0,0492	0,1024	0,0000	0,0000
379	45	0,0480	0,0989	0,0000	0,0000
386	46	0,0489	0,0926	0,0000	0,0000
393	47	0,0497	0,0867	0,0000	0,0000

FONTE: Adaptada de Ginevan (1979).

Se hipoteticamente, existe um caso em que o cliente deseje um mapa com exatidão de 85% ($P_u = 0,85$), com um risco de, no máximo, 5% de aceitar um mapa fora dessa especificação ($R_u = 0,05$). Do outro lado está então o produtor, que confia que seu mapa temático tem uma exatidão nominal de 95% ($P_p = 0,95$), mas não queira correr um risco maior do que 3% de o seu produtor ser rejeitado ($R_p \leq 0,03$).

Consultando a Tabela 3.5, constata-se que o tamanho n mínimo de amostragem que atenderia as exigências tanto do cliente, quanto a do produtor seria $n = 110$. De fato, para esse valor de n , tem-se R_u exato = 0,0481 e $R_p = 0,0221$, com um valor crítico $x_c=10$ de número máximo de erros aceitável.

Foram desenvolvidos e implementados algoritmos que automatizam o cálculo de x_c , R_u e R_p , bem como os algoritmos de visualização das curvas das funções de densidade de probabilidade binomial referentes ao usuário e produtor. Como resultado, tem-se um gráfico como o mostrado na Figura 3.1, onde o exemplo descrito no parágrafo anterior é ilustrado.

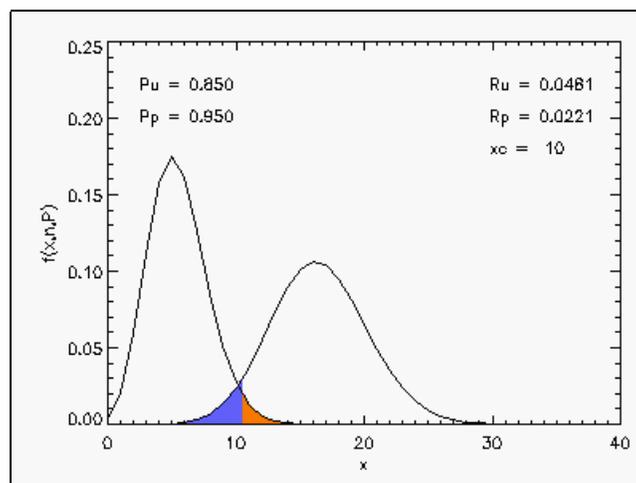


Fig. 3.1 - Curvas das funções de densidade de probabilidade binomial:
 - do ponto de vista do usuário, com área de risco pintada na cor azul correspondendo a $R_u=0,0481$;
 - do ponto de vista do produtor, com área de risco pintada na cor laranja correspondendo a $R_p=0,0221$.

A leitura do que ocorre neste gráfico é relativamente simples. A função de densidade de probabilidade binomial $f(\mathbf{x};n;\mathbf{P})$, nos fornece a probabilidade de \mathbf{x} pontos serem mal classificados num conjunto de n pontos, tendo a classificação uma exatidão \mathbf{P} . Se houver uma exatidão \mathbf{P}_1 e uma outra exatidão \mathbf{P}_2 maior, no primeiro caso mais pontos serão mal classificados, o que justifica o fato de a curva $f(\mathbf{x};n;\mathbf{P}_u=0,85)$ estar deslocada para valores maiores de \mathbf{x} , a direita de $f(\mathbf{x};n;\mathbf{P}_p=0,95)$, neste caso descrito.

Definido o risco máximo que o usuário quer correr de aceitar uma classificação fora das especificações, haverá um valor de \mathbf{x}_c , onde à sua esquerda está localizado este risco, ou **erro do tipo I**. Isto porque se $\mathbf{x} > \mathbf{x}_c$, a classificação já é reprovada de imediato, enquanto que se $\mathbf{x} \leq \mathbf{x}_c$ a classificação é aprovada, havendo a possibilidade de estar fora das especificações.

A partir daí, o risco de o produtor ver a classificação ser rejeitada mesmo dentro das especificações, segue o raciocínio análogo. À direita de \mathbf{x}_c , sob a curva de $f(\mathbf{x};n;\mathbf{P}_p=0,95)$ localiza-se este risco, ou **erro do tipo II**. A área pintada de azul refere-se ao risco do usuário, enquanto a área pintada de laranja diz respeito ao risco do produtor.

Se a exatidão do produtor for diminuída para $\mathbf{P}_p=0,90$, a curva de $f(\mathbf{x};n;\mathbf{P}_p=0,90)$ desloca-se para direita, conforme se verifica na Figura 3.2. Mas a curva do consumidor permanece inalterada, logo a área correspondente ao risco do produtor aumentará, resultando em um valor igual de $\mathbf{R}_p=0,54$.

Embora este tipo de avaliação seja importante, ela não consta do conjunto de resultados que são apresentados neste trabalho. Ela serve aqui como mais uma ferramenta de auxílio a decisão, implementada na interface gráfica do classificador.

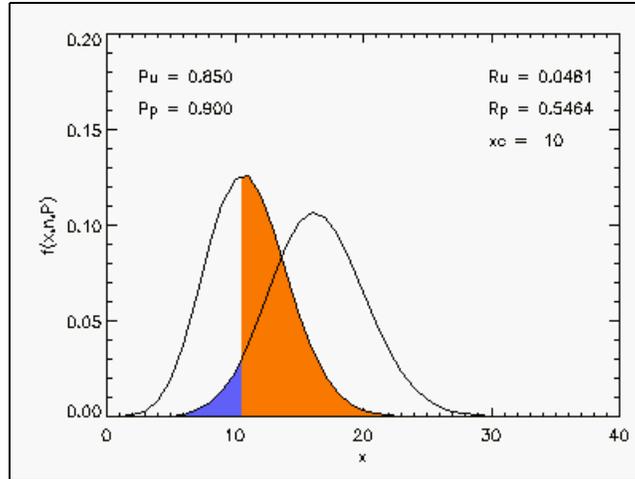


Fig. 3.2 - Curvas das funções de densidade de probabilidade binomial:

- do ponto de vista do usuário, com área de risco pintada na cor azul correspondendo a $R_u=0,0481$;
- do ponto de vista do produtor, com área de risco pintada na cor laranja correspondendo a $R_p=0,5464$.

Valeriano (1985), utilizou esta técnica para avaliar a qualidade do mapeamento realizado e determinar o tamanho da amostra, ao estabelecer primeiro os parâmetros de risco e exatidão de usuário e produtor. Os parâmetros adotados foram:

Risco do usuário $R_u = 0,05$;

Exatidão mínima requerida pelo usuário $P_u = 0,85$;

Risco do produtor $R_p = 0,15$;

Exatidão estabelecida pelo produtor $P_p=0,90$.

Ao se consultar a Tabela 3.5, constata-se que o tamanho de amostra n que atende aos parâmetros definidos é de 319 pontos, com um valor crítico x_c de 37 pontos.

CAPÍTULO 4

MATERIAIS E METODOLOGIA

Neste capítulo encontra-se explicação dos passos realizados para obter a segmentação através do matiz de uma composição colorida. Desde o tratamento inicial da imagens até a avaliação estatística do resultado final de classificação.

4.1. - Material de Trabalho

As imagens utilizadas neste trabalho, tanto de Caçapava (órbita/ponto: 219/76, quadrante: B) quanto de Tremembé (órbita/ponto: 218/76, quadrante: A), foram obtidas pelo sensor Landsat/TM. A cena de Caçapava tem 475 colunas e 574 linhas. Em Tremembé, as imagens tem 854 colunas e 924 pixels linhas.

Os algoritmos de segmentação/classificação, assim como a interface gráfica, foram implementados na linguagem de programação IDL ("Interactive Data Language"), versão 5.2. Os resultados foram comparados com os obtidos pelo métodos de segmentação e de classificação de imagens implementados no "software" **SPRING** (Sistema para Processamento de Informações Georreferenciadas).

O **SPRING** é um banco de dados geográfico de 2ª geração, desenvolvido pelo INPE, onde é permitido realizar-se diversos processamentos de imagens, incluindo segmentação e classificação. Dentre os métodos de segmentação disponíveis no **SPRING**, utilizou-se neste trabalho de crescimento de regiões, o qual divide a imagem em regiões baseando-se nos níveis de cinza dos pixels pertencentes a uma região nas bandas espectrais escolhidas. O método de classificação empregado foi o Iseseg, que classifica imagens previamente segmentadas, que por este motivo ele é considerado como sendo um classificador de regiões.

Os parâmetros de entrada do segmentador são o limiar de similaridade e o tamanho mínimo de área. Cada região possui um atributo numérico que a caracteriza (podendo se média dos níveis de cinza, por exemplo). Todo pixel vizinho a esta região é um candidato em potencial a pertencer a mesma, desde que a diferença do valor do atributo deste pixel e da região seja inferior ao limiar de similaridade estipulado. O atributo área limita o tamanho mínimo, em número de pixels, que uma região deve ter na imagem segmentada.

No classificador Ioseg, o parâmetro empregado é o limiar de aceitação, um valor percentual que definirá uma distância (denominada distância de Mahalanobis). Todas as regiões que estiverem a uma distância da classe, inferior à definida pelo limiar de aceitação, pertencem a esta classe.

4.2. - Metodologia

As imagens passaram primeiro por um processo de realce, visando aumentar o contraste entre os níveis de cinza das bandas e, conseqüentemente, das composições coloridas. Com isso obtém-se uma melhor separabilidade entre os valores de matiz.

Foram geradas partir das bandas realçadas disponíveis, três composições coloridas: uma utilizando três bandas espectrais, uma com quatro bandas e uma com cinco bandas espectrais. Para cada uma, foi escolhida a composição de bandas onde o matriz apresentasse a melhor separabilidade visual entre o alvo de interesse, e o restante da cena. Para três, quatro e cinco bandas, as composições escolhidas foram TM453, TM4537 e TM45273, respectivamente.

A transformação a ser utilizada para obtenção dos atributos de cores, dependerá de quantas bandas TM forem carregadas. Se forem três, utiliza-se a transformação HSV, caso contrário o método de Moik é empregado para N bandas espectrais, encontrando os atributos de cores diretamente, sem ser necessário uma composição colorida.

A seguir, a segmentação por crescimento de regiões é efetuada sobre a imagem de matiz. Se assim for requerido, o segmentador pode ignorar os pixels de matiz, cujo os valores de saturação ou intensidade forem muito baixo. Quando esta situação ocorre, os valores de matiz são instáveis e não podem ser levados em conta na segmentação, conforme já comentado na Seção 2.3.2.1. - Os pixels que se enquadram nesta situação são atribuídos à uma classe em separado, identificada na imagem classificada na cor preto.

Também de acordo com os parâmetros de entrada das etapas posteriores, o resultado da segmentação pode sofrer um processo de filtragem de pequenas regiões. Neste caso regiões pequenas (com 2 ou 3 pixels, por exemplo) podem ser eliminadas da imagem segmentada, sendo substituídas por aquela região vizinha mais freqüente.

Na etapa seguinte, as regiões agora são agrupadas, de acordo com um limiar de agrupamento fornecido ao programa. Ao final, podem restar classes, que no contexto da cena inteira são demasiadamente pequenas, podendo ou não serem filtradas, de acordo com a sua importância. Estes procedimentos na Figura 4.1 estão mostrados na forma de fluxograma.

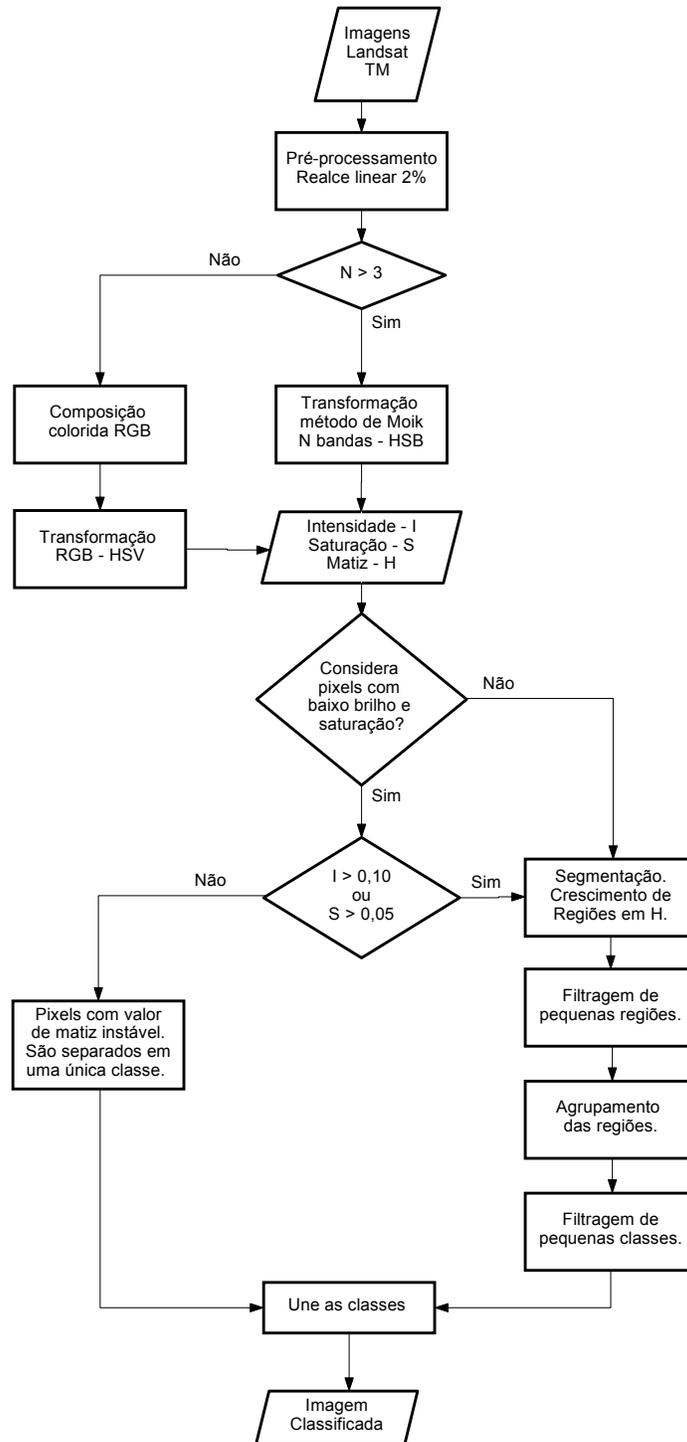


Fig. 4.1 - Fluxograma do procedimento de classificação do matiz.

4.3. - Realce de Imagens

O realce realizado sobre as imagens TM foi o realce linear 2%, que consiste em aplicar uma transformação linear sobre 96% dos pixels da imagem. Do total de pixels da imagem, os 2% de mais baixos e altos valores, são deslocados para os valores 0 e 255 respectivamente. Os demais variarão entre 1 e 254. Na Figura 4.2, aparecem os histogramas da imagem TM4 de Tremembé original e realçada, onde nesta nota-se claramente uma maior distribuição dos valores dos pixels, caracterizando um contraste maior entre os mesmos.

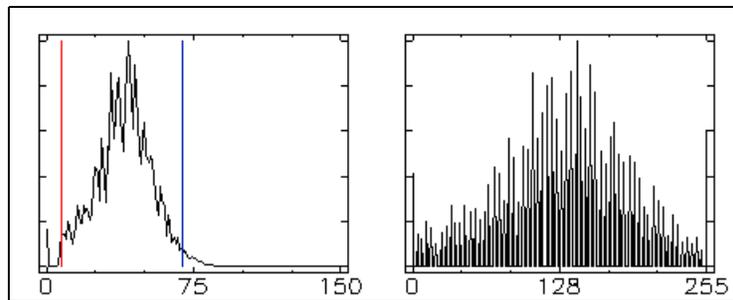


Fig. 4.2 - Histogramas da imagem original e realçada de Tremembé.
FONTE: Obtida a partir do "software" ENVI.

O efeito visual sobre as imagens é bem nítido, havendo uma clareza de detalhes muito mais presente na imagem que sofreu realce 2% (Figura 4.3). A partir destas imagens é feito então todo o processamento de obtenção do atributos de cor, para posterior segmentação da imagem de matiz da cena.

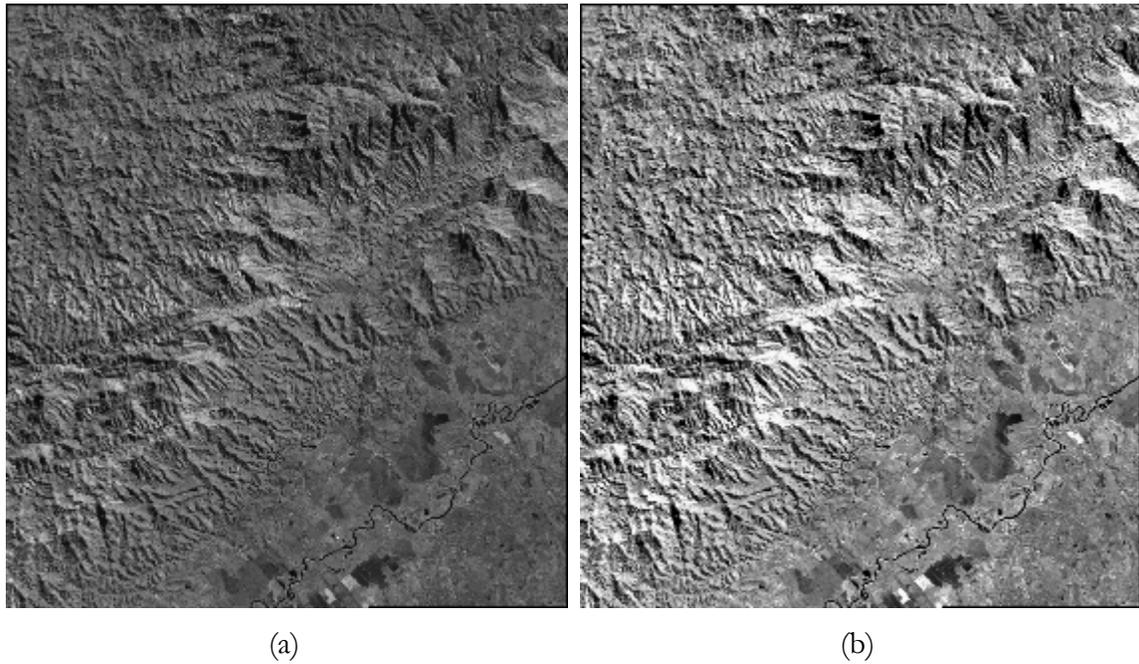


Fig. 4.3 - Imagem TM4 original (a) e imagem realçada 2% (b) de Tremembé.

4.4. - Procedimento de Segmentação de Imagem

Desenvolveu-se um algoritmo de segmentação de imagem de matiz, adaptado a sua característica peculiar de serem dados circulares. Para o algoritmo foram escolhidos quatro parâmetros que determinam o resultado final da segmentação, a saber: o limiar de segmentação, o tamanho mínimo de uma região, o limiar de reclassificação e o tamanho mínimo da classe.

O **limiar de segmentação** define a diferença máxima entre o valor de um pixel da vizinhança de uma região, e o valor médio dos pixels desta região. Se esta diferença for menor ou igual a este limiar, o pixel é agregado a região. Terminada a segmentação, todas as regiões que não obedecerem ao critério de **tamanho mínimo de região** (dado em número de pixels), são agrupadas à região mais freqüente ao seu redor.

A **reclassificação (ou agrupamento)** irá agrupar as regiões em classes, de acordo com dois critérios: i) diferença entre os valores médios deve ser menor que o **limiar de**

reclassificação e ii) concorrência entre as regiões, isto é, serão agrupadas aquelas cujo os valores médios são mais próximos. O processo de reclassificação se dá até que todas as regiões estejam atribuídas a uma classe, que não são conhecidas *a priori*, e são rotuladas por números.

Ao final desta etapa, resta ainda verificar se alguma classe é pequena demais em relação ao conjunto de pixels da imagem. Por exemplo, se o tamanho da classe for menor que 2% do tamanho da imagem, ela será reagrupada a outra classe de valor médio mais próximo. E é este percentual que define o **tamanho mínimo de uma classe** na imagem.

4.4.1. - Crescimento de Regiões Adaptado ao Matiz

Todo o procedimento de segmentação começa a partir de uma escolha aleatória do pixel semente, ou seja, do pixel donde será feito o primeiro crescimento de regiões na imagem. A escolha se deu desta maneira para preservar a natureza não-supervisionada em todas as etapas da classificação da imagem. Na Figura 4.4 está um conjunto de pixels com valores de matiz, agrupados em 7 colunas e 7 linhas, e em destaque na cor cinza está o pixel central desta grade, que é o pixel semente da segmentação.

Em amarelo estão destacados os pixels vizinhos ao semente, através do critério de vizinhança 4. Por este critério, são vizinhos a um pixel, aqueles que localizam-se a norte, sul, leste e oeste. O segmentador verifica quais são os pixels vizinhos que obedecem a condição de similaridade e agrupa-os a região.

Para um limiar de similaridade é 30, ter-se-ia uma nova região com valor médio de matiz 349, como mostrado na Figura 4.5. Note que se fosse calculada a média simples destes 4 pixels, o resultado seria igual a 260; bem diferente do real. Esta diferença ocorre, como já explicado anteriormente, devido ao caráter circular dos dados de matiz, onde a diferença entre 350 e 20 vale 30, e não 330. Portanto a forma utilizada para calcular o valor médio, leva em consideração esta característica dos dados circulares.

	0	1	2	3	4	5	6
0	110	70	50	120	290	270	220
1	90	50	30	110	100	250	240
2	70	40	10	20	270	230	220
3	100	90	100	350	340	220	210
4	60	70	80	330	260	250	180
5	50	40	60	250	170	100	190
6	20	30	30	10	190	110	130

Fig. 4.4 - Pixel semente em cinza, e vizinhos na cor amarelo.

Passo 1: Verifica quais pixels vizinhos são similares ao pixel semente.	Passo 2: Agrupa estes pixels similares e o pixel semente em uma única região.

Fig. 4.5 - Passos do crescimento de região.

Como já mencionado, pelo fato de os dados de matiz serem circulares, o que se faz é considerar cada valor de pixel como o argumento de um vetor - cada vetor no primeiro passo, é considerado unitário. Efetua-se a soma vetorial entre eles para encontrar o vetor resultante, a partir do qual obtêm-se o seu argumento, ou seja, o valor médio dos pixels.

Do exemplo anterior e de acordo com as equações:

$$\mathbf{v} = [\cos 350^\circ, \text{sen } 350^\circ] + [\cos 20^\circ, \text{sen } 20^\circ] + [\cos 340^\circ, \text{sen } 340^\circ] + [\cos 330^\circ, \text{sen } 330^\circ]$$

$$\mathbf{v} = [3.73, -0.674]$$

$$m = \text{arc tg} (-0.180), \quad m = 349^\circ$$

Os próximos passos seguem o mesmo princípio, só que agora se buscam os pixels vizinhos à esta região recém encontrada. Novamente é feita a soma vetorial do vetor \mathbf{V} resultante com os vetores referentes aos pixels vizinhos, que atendem a condição de similaridade, e é

obtido um novo vetor resultante da região. E assim sucessivamente, até que não haja mais nenhum pixel vizinho que possa ser agregado à região.

No próximo passo o algoritmo escolhe aleatoriamente o novo pixel semente os restantes na imagem, repetindo-se o mesmo procedimento até finalizar o crescimento desta nova região. A segmentação termina quando todos os pixels da imagem já estiverem atribuídos a alguma região.

Antes de começar a segmentação, é criada uma tabela na qual são armazenadas as informações pertinentes a cada região obtida na imagem. A estrutura desta tabela é composta de quatro elementos que são usados durante todo o procedimento de segmentação: o número identificador da região, denominado rótulo; o valor médio dos pixels da região; a quantidade de pixels presentes na região; e por fim um elemento que contém a informação do vetor resultante da região, na forma complexa.

4.4.2. - Filtragem de Pequenas Regiões

Após finalizar a etapa de crescimento de regiões, existirá na imagem uma grande quantidade de pequenas regiões, as quais conferem um aspecto ruidoso ao resultado da segmentação. Realiza-se então uma filtragem destas pequenas regiões, através de um procedimento que agrega as regiões menores ou iguais a p pixels à região vizinha a sua borda que for mais freqüente.

4.4.3. - Agrupamento de Regiões - Identificação de Regiões Similares

O resultado alcançado até então são regiões contíguas em toda a extensão da imagem. Esta última etapa visa agregar estas regiões de acordo com os seus valores médios, com a finalidade de obter as classes sobre a imagem. Para tanto, deve-se estipular um limiar de agrupamento, que servirá de parâmetro na decisão de agrupar ou não duas regiões.

O procedimento consiste em agrupar as regiões da imagem, a partir da de maior tamanho em pixels até a de menor tamanho, seguindo as seguintes etapas:

- 1) A tabela de regiões **tab** é ordenada em ordem decrescente de tamanho de regiões;
- 2) Uma nova tabela auxiliar **ntab** é criada, contendo apenas a região de maior tamanho;
- 3) A partir do segundo elemento da tabela **tab** - correspondendo a segunda maior região da segmentação - o valor médio deste é comparado com o valor médio do único elemento da tabela **ntab**. Caso a diferença entre ambos for menor que o limiar **r** de agrupamento, este segundo elemento é incorporado ao único elemento da tabela **ntab**. Caso contrário, um segundo elemento é adicionado à tabela **ntab**.
- 4) Este processo repete-se até que todas as regiões da tabela **tab** sejam testadas. A diferença é que a partir do momento em que for criado o segundo elemento de **ntab**, o valor médio dos próximos elementos da tabela **tab** é comparado com os valores médios de todos os elementos de **ntab**. Àquele que for mais próximo e atender ao critério de similaridade, o elemento de **tab** será agregado.
- 5) Ao final do processo, o conteúdo da tabela **tab** é substituído pelo conteúdo da tabela auxiliar **ntab**.

4.4.4. - Tamanho Mínimo de uma Classe

Há ainda a opção de estipular o tamanho mínimo em pixels de uma classe, tendo como parâmetro o total de pixels na imagem. Por exemplo, ao estipular-se um tamanho mínimo igual a 1%, nenhuma classe deverá ter menos do que 1% do total de pixels da imagem. Caso isto ocorra, a classe será agregada à classe de mais próximo valor médio, que tenha tamanho superior ao mínimo estipulado.

A seguir são mostradas como exemplo, as Tabelas 4.1 e 4.2, que apresentam as classes e seus respectivos valores médios de matiz, total de pixels e o percentual com relação ao total de pixels da imagem. A primeira tabela refere-se ao agrupamento sem restrição de tamanho mínimo de classe, enquanto que a segunda limita o tamanho mínimo de uma classe a 1%

do total de pixels da imagem. Deste modo, treze classes que anteriormente estavam sendo consideradas, foram agrupadas as outras dez que atendiam ao critério de tamanho mínimo.

TABELA 4.1 - COMPOSIÇÃO DAS CLASSES NA CLASSIFICAÇÃO DE CAÇAPAVA, LIMIAR 30, TAMANHO MÍNIMO DE REGIÃO 4 E LIMIAR DE AGRUPAMENTO 10

Estatística das classes			
Classe	Média	Pixels	Perc. (%)
1	40	21179	32,32
2	28	20794	31,73
3	207	7882	12,03
4	177	5400	8,24
5	195	2540	3,88
6	87	1506	2,30
7	145	1282	1,96
8	14	1221	1,86
9	66	1058	1,61
10	164	679	1,04
11	1	489	0,75
12	100	347	0,53
13	111	342	0,52
14	124	335	0,51
15	226	158	0,24
16	242	105	0,16
17	337	75	0,11
18	313	33	0,05
19	256	33	0,05
20	300	32	0,05
21	349	30	0,05
22	289	9	0,01
23	276	7	0,01
		65536	100,00

TABELA 4.2 - COMPOSIÇÃO DAS CLASSES NA CLASSIFICAÇÃO DE CAÇAPAVA, LIMIAR 30, TAMANHO PIXEL 4, LIMIAR DE AGRUPAMENTO 10 E TAMANHO MÍNIMO 1%

Estatística das classes			
Classe	Média	Pixels	Perc. (%)
1	40	21179	32,32
2	28	20794	31,73
3	208	8194	12,5
4	177	5400	8,24
5	195	2540	3,88
6	93	2195	3,35
7	8	1880	2,87
8	141	1617	2,47
9	66	1058	1,61
10	164	679	1,04
		65536	100,00

4.4.5. - Particularidades do Método de Segmentação em Matiz

Apesar de conceitualmente correta, a escolha aleatória do pixel semente de cada nova região, acarreta resultados de segmentação não idênticos da mesma cena. Um exemplo com dois resultados de segmentação utilizando o mesmo limiar, é mostrado na Figura 4.6.

Devido a escolha aleatória dos pixels semente, os resultados embora próximos, não serão idênticos mas preservam o valor médio geral. Na Figura 4.6a, o valor médio geral de matiz é 50,1893, enquanto que em Figura 4.6b é 50,1907.

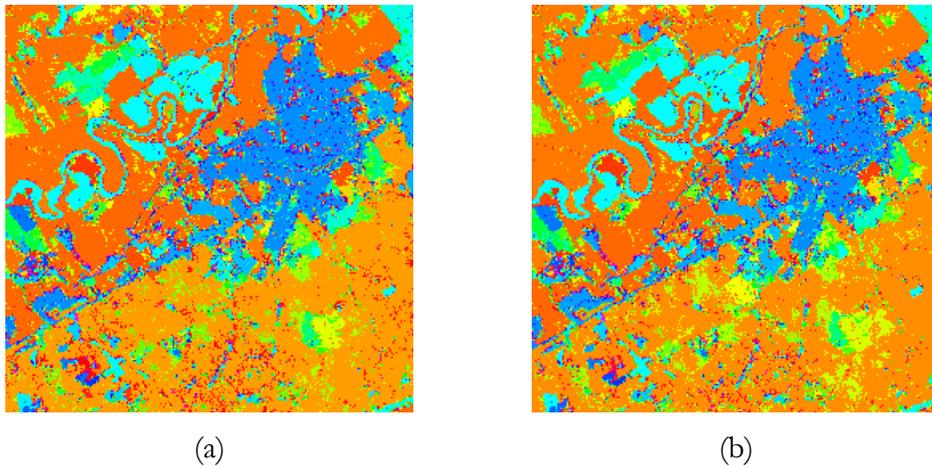


Fig. 4.6 - Exemplo de dois resultados de segmentação da mesma cena, usando limiar de segmentação 30.

Uma outra particularidade na segmentação de matiz de composição colorida, percebida durante a elaboração deste trabalho. Constatou-se, que é indiferente realizar-se segmentação sobre uma composição TM453 ou TM543. Para exemplificar isso, tomou-se como exemplo os valores das coordenadas em RGB de dois pixels e seus respectivos valores de matiz.

Sejam então dois pixels **a** e **b**, com as seguintes coordenadas no espaço de cores RGB, para as composições TM543 (índice 1) e TM453 (índice 2):

- **a1**: coordenada (100,200,50) e **b1**: coordenada (180,30,90);
- **a2**: coordenada (200,100,50) e **b2**: coordenada (30,180,90);

Os seus respectivos valores de matiz e diferença entre eles serão:

- **a1**: $h=100$ e **b1**: $h=336$; diferença 124
- **a2**: $h=20$ e **b2**: $h=144$; diferença 124

A diferença entre os valores de matiz dos dois pixels foi igual para as duas composições coloridas. Como o método de segmentação por crescimento de regiões baseia-se justamente na diferença entre os valores de matiz dos pixels, os resultados da segmentação em uma composição colorida TM543, TM453 e TM345 devem ser iguais, embora não isto não é provado neste trabalho.

Entretanto, para quatro e mais bandas, esta propriedade não se verifica, ou seja, o resultado da segmentação dependerá da composição colorida feita. Esta característica recomenda mais ainda a utilização de composições com mais de três bandas espectrais, a partir do método de Moik. Exemplificando, sejam agora então dois pixels **a** e **b**, com as seguintes coordenadas, para as composições TM4537 (índice 1) e TM3457 (índice 2):

- **a1**: coordenada (100,200,50,150) e **b1**: coordenada (180,30,90,230);
- **a2**: coordenada (50,100,200,150) e **b2**: coordenada (90,180,30,230);

Os seus respectivos valores de matiz e diferença entre eles são:

- **a1**: $h=45$ e **b1**: $h=294$; diferença 111
- **a2**: $h=198$ e **b2**: $h=320$; diferença 122

Com relação a baixos valores de saturação e/ou intensidade, o valor de matiz torna-se instável e, conseqüentemente, sem utilidade no procedimento de segmentação de uma imagem. Infelizmente, não há um critério consensualmente aceito com relação aos intervalos de valores de saturação e/ou intensidade, os quais determinem os valores instáveis de matiz.

Entretanto, especificamente para as imagens utilizadas nesta dissertação, foi possível estimar os valores mínimos de saturação e intensidade para os quais o valor de matiz fosse considerado válido. Para pixels com valor de saturação igual ou inferior a 0,05, ou com valor de intensidade igual ou inferior a 0,10, o algoritmo de segmentação não os levaram

em conta, atribuindo-os a uma única região isolada das demais. A escolha desses valores mínimos se deu a partir de observações visuais das imagens de matiz, onde em regiões com valores instáveis de matiz, correspondiam na grande maioria das vezes a pixels onde valores intensidade e saturação eram menores ou iguais a 0,05 e 0,10 respectivamente.

4.5. - Procedimento para Avaliação Estatística

Para realizar uma avaliação estatística utilizando o coeficiente kappa, é preciso de antemão da verdade de campo. No entanto, em ambas as imagens utilizadas neste trabalho, não havia um mapeamento de uso de solo para toda a cena. Para estimar uma verdade, gerou-se um conjunto de pontos aleatórios sobre a imagem de composição colorida TM4537, obtida pelo método de Moik.

Cada ponto foi então interpretado, e com base nesta interpretação visual, montou-se uma matriz binária (0 ou 1) de dimensão $\mathbf{P} \times \mathbf{C}$, onde \mathbf{P} é o número de pontos amostrados, e \mathbf{C} o número de classes. Dentre as \mathbf{C} colunas, identifica-se a que representa os pontos da classe principal, a qual se quer separar das classes restantes. Estas por sua vez, na etapa seguinte são agrupadas todas em uma única classe (Não-floresta para Tremembé, Não-urbano para Caçapava). A matriz binária agora tem dimensões $\mathbf{P} \times \mathbf{2}$, isto é, \mathbf{P} linhas por duas colunas, sendo a primeira coluna a que contém os pontos de referência da classe principal e a segunda coluna a que armazena os pontos das outras classes.

Para cada resultado de classificação, é gerada uma matriz binária semelhante a esta, que é comparada linha a linha (ponto a ponto) com a matriz binária de referência. Com isso sabe-se quantos pontos da imagem classificada coincidem ou não com os pontos de cada uma das duas classes de referência. Pode-se agora então, a partir dessas informações, gerar uma matriz de confusão.

Tanto a imagem de Caçapava quanto a de Tremembé tiveram de ter suas escalas ampliadas a fim de se realizar uma interpretação visual mais precisa. Caçapava teve a escala de sua

imagem ampliada de uma escala nominal de 1:100.000 para escala de 1:50.000, enquanto Tremembé foi ampliada a escala de 1:70.000.

4.5.1. - Procedimento de Avaliação de Classificação em Caçapava

Sobre a imagem de composição TM4537, foram gerados 173 pontos de maneira aleatória, tal como pode ser visto na Figura 4.7. Este pontos foram analisados por somente um intérprete, que no entanto possui amplo conhecimento da região. Em virtude disto, doze classes, listadas na Tabela 4.3 foram identificadas. No entanto, para efeito de avaliação estatística somente duas classes - urbano e não-urbano - nortearam a análise do resultado de classificação.

TABELA 4.3 - CLASSES IDENTIFICADAS NA INTERPRETAÇÃO VISUAL DOS PONTOS DE CAÇAPAVA

Classe	
1	Solo exposto / Início de ocupação urbana
2	Solo exposto / Várzea
3	Areia
4	Vegetação de áreas úmidas / Capoeira
5	Pasto / Vegetação rasteira
6	Agricultura
7	Mata Ciliar
8	Mata Atlântica
9	Silvicultura
10	Lago / Água
11	Lago / Cava
12	Área urbana / Ocupação urbana

Do total, 16 pontos receberam classificação urbano, 130 não-urbano, 5 foram interpretados como sombra e houve 22 pontos de borda, onde não se foi possível decidir a qual classe pertencia. Na avaliação estatística, somente os pontos que foram interpretado como alvo urbano ou não-urbano (146 pontos), é que servirão de referência para as avaliações estatísticas das classificações obtidas neste trabalho.

Dois outros conjuntos de pontos gerados aleatoriamente, foram utilizados para avaliar os resultados de classificação, contendo 475 e 803 pontos respectivamente. Isto foi feito

porque, para 146 pontos amostrados, as diferenças entre kappas estimados de resultados de classificação no matiz, não foram significativamente diferentes a um nível de significância $\alpha=10\%$. Desejou-se, com amostragens maiores, verificar se as diferenças encontradas persistem e se são significativas ou não.

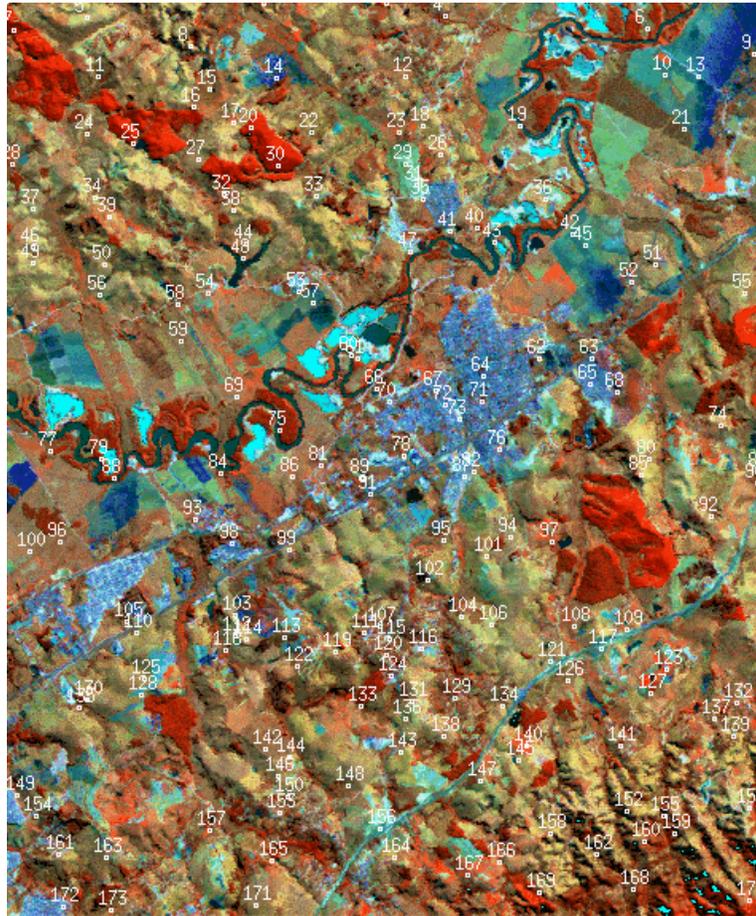


Fig. 4.7 - Pontos aleatórios sobre a composição TM4537 de Caçapava.

Estes novos conjuntos aleatórios de pontos, foram classificados a partir de uma imagem de referência contendo somente duas classes: urbano e não-urbano. As classes urbano (branco) e não-urbano (cinza) que aparecem na imagem de referência da Figura 4.8, foram obtidas através da ferramenta de criação de vetores disponível no "software" ENVI. Sobre a composição colorida TM4537 de Caçapava, traçaram-se os contornos das áreas urbanas, que possuem boa identificação visual nesta composição (em tonalidade azul), mesmo para quem não é familiarizado com a região.



Fig. 4.8 - Imagem de referência de Caçapava, com as classes urbano (branco) e não-urbano (cinza).

4.5.2. - Procedimento de Avaliação de Classificação em Tremembé.

Enquanto que em Caçapava os pontos foram interpretados por um especialista, para Tremembé convidou-se três pessoas a interpretar os pontos aleatórios gerados. Cada um dos três intérpretes preencheu uma planilha onde constavam quatro colunas, representando as classes floresta, não floresta e não identificado (ou sombra), além de um item para discriminar os pontos de borda, isto é, onde não foi possível determinar com certeza qual é a classe predominante. Por este motivo a classe borda não é considerada na avaliação, mas tem a função de descartar alguns pontos de difícil interpretação visual.

Apesar de todos os pontos amostrados terem sido inseridos na planilha, somente aqueles onde houve coincidência em todas as interpretações foram considerados no algoritmo de avaliação estatística. Assim foi feito pois cada intérprete, por mais cuidadosa e criteriosa que seja feita sua avaliação, tem por vezes opinião própria sobre um determinado alvo visto na imagem.

Do total de 343 pontos gerados, houve 153 pontos atribuídos às classes floresta e não-floresta pelos três intérpretes, os quais passaram a ser considerados como a referência disponível para a avaliação, já não foi realizado trabalho de campo para verificar os pontos. Na Figura 4.9, é mostrada parte da cena de Tremembé, com uma parcela dos 343 pontos amostrados aleatoriamente

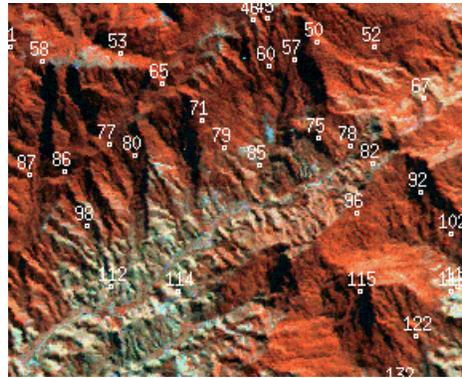


Fig. 4.9 - Pontos aleatórios sobre detalhe da composição TM4537 de Tremembé.

Por igual motivo ao exposto para Caçapava na Seção 4.5.1, utilizaram-se dois outros conjuntos maiores de pontos aleatórios. Deseja-se verificar se nestas amostragens, as diferenças entre os kappas estimados de resultados diferentes de matiz são significativamente diferentes.

Um conjunto, baseia-se nos mesmos 343 pontos obtidos anteriormente. No entanto, ao invés de serem resultado da coincidência de interpretação de três especialistas, este conjunto de pontos é fruto da coincidência de dois, que mais pontos interpretaram. Nesta situação encontram-se 231 pontos classificados como floresta ou não-floresta.

Gerou-se aleatoriamente também outros 635 pontos, donde 185 foram classificados como floresta e 343 pontos como não-floresta, totalizando 528 pontos de referência. Os demais 107 pontos localizaram-se sobre regiões de sombra ou de borda.

CAPÍTULO 5

RESULTADOS E DISCUSSÕES

Foi gerada uma quantidade de resultados de classificação de cenas das cidades de Caçapava e Tremembé, tanto a partir de segmentação da imagem de matiz, como através do método Isoseg implementado no programa SPRING. Comparou-se os resultados dos dois métodos entre si e entre os diferentes parâmetros utilizados dentro de um mesmo método. Esta comparação se deu de forma qualitativa e quantitativa.

No primeiro caso buscou-se avaliar visualmente o resultado de classificação, comparando-o com a imagem de origem, analisando a homogeneidade com relação a cor, e ainda o tamanho das regiões. Já a comparação quantitativa baseou-se na avaliação estatística realizada, onde foi feito o cálculo de coeficiente kappa para cada resultado de classificação.

5.1. - Avaliação Qualitativa

É apresentada nesta Seção o resultado de classificação sobre imagens de Caçapava e Tremembé, tanto pelo método de matiz de composição colorida, quanto pelo método Isoseg. Todas as segmentações por crescimento de regiões feitas antes de se aplicar o método de classificação Isoseg, tiveram com parâmetro de tamanho mínimo de região cinco pixels. Ou seja, nenhuma região segmentada tem menos do que cinco pixels. Já imagens segmentadas de matiz tiveram todas posteriormente os seguintes parâmetros de classificação:

- regiões pequenas a serem filtradas: até 4 pixels;
- limiar de reclassificação (agrupamento): valor 10;
- limiar de tamanho mínimo de classe: maiores que 1%.

5.1.1. - Caçapava

Antes, é verificada a própria composição colorida e as regiões da mesma as quais julgam -se ter menor ou maior grau de dificuldade de distinção, principalmente com relação a regiões com diferenças de iluminação, devido à topografia acidentada.

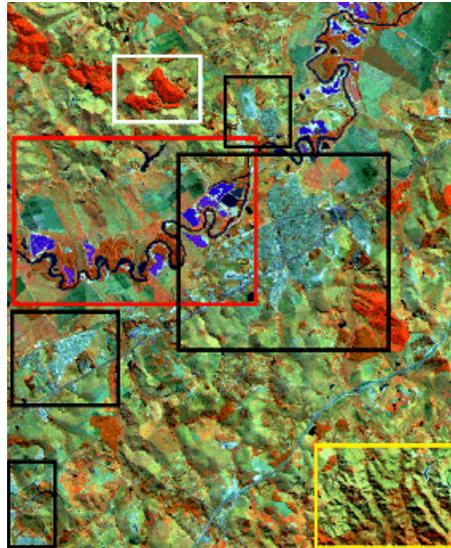


Fig. 5.1 - Composição TM453 de Caçapava. Em destaque, dentro de retângulos, quatro situações analisadas: **preto**: urbano; **vermelho**: água; **branco**: eucalipto; **amarelo**: região sombreada.

Os retângulos presentes na composição colorida destacam áreas de análise para três alvos: eucalipto, água e urbano; retângulos branco, vermelho e preto, respectivamente. Em amarelo aparece o retângulo que destaca região onde a variação de luminosidade, devido à topografia, é mais acentuada.

O retângulo branco mostra uma região de eucalipto onde se supõe que tenha menor grau de complexidade, haja visto que esta destaca-se em relação as regiões vizinhas pela coloração avermelhada. No retângulo vermelho encontram-se alvos de valores mais próximos: curso d'água de rio e lagos com extração de areia com alta, média e baixa suspensão de sedimentos, existindo aqui uma dificuldade maior de separabilidade. Já os retângulos pretos, mostram zona urbana com uma textura característica um pouco rugosa,

que nesta composição possui coloração próxima ao ciano. Devido ao tipo de textura da área urbana, este alvo é de uma complexidade um pouco maior.

Outro item analisado é a influência da variação de luminosidade sobre os alvos, que ocorre principalmente em virtude da existência de terrenos acidentados, como os presentes na cena. Quanto menor for esta influência, mais homogêneo será o resultado da classificação do alvo.

5.1.1.1. - Base de Dados Analisada

Foram gerados resultados de classificação com os dois métodos em três situações diferentes: usando três, quatro e cinco bandas espectrais: TM345, TM3457 e TM23457 respectivamente. Na segmentação por crescimento de regiões do SPRING, as similaridades escolhidas foram 20, 30 e 40, com tamanho mínimo de região 5 pixels. Na classificação por Isoseg, para cada similaridade, variou-se o limiar de aceitação em 75%, 90%, 95%, 99% até 99,9%. Portanto, no total foram gerados quarenta e cinco resultados diferentes de classificação, quinze por grupo de bandas TM.

A partir do método de matiz, foram obtidos mais 15 resultados de classificação, cinco para cada grupo de bandas, com as composições coloridas TM453, TM4537 e TM45273. Para cada uma, os limiares de segmentação utilizados foram 20, 25, 30, 35 e 40, com tamanho mínimo de região 5 pixels, limiar de agrupamento 10 e tamanho mínimo de classe 1%. Os melhores resultados para cada grupo de bandas - segundo uma avaliação visual e individual, sujeita a todo tipo de subjetividade - foram escolhidos entre os dois métodos de classificação e comparados entre si.

5.1.1.2. - Influência da Variação de Luminosidade

Uma das principais características da imagem de matiz consiste exatamente, na baixa influência da variação de luminosidade no terreno, na determinação do valor digital do pixel. Mesmo em regiões com terreno acidentado, o que prevalece, na maior parte das vezes, é a expressão do matiz da composição colorida na cena.

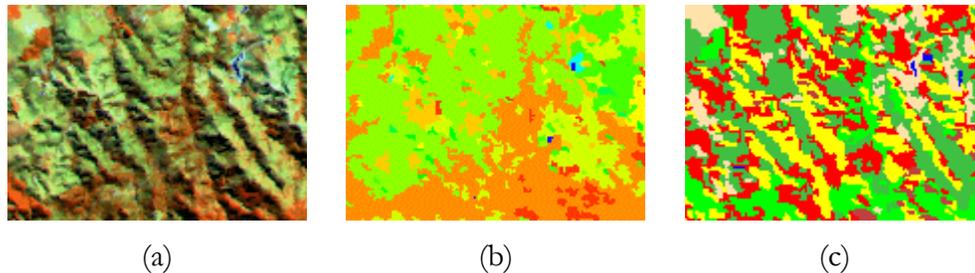


Fig. 5.2 - Detalhe de uma região com sombra em três situações:
(a) composição TM453, onde se nota variação grande de luminosidade devido ao relevo;
(b) classificação matiz, limiar de segmentação 25, onde a variação da luminosidade pouco interfere na obtenção das classes;
(c) classificação Isoseg, limiar de similaridade 40, limiar de aceitação 99,9%, onde a variação de luminosidade interfere bastante no resultado

A Figura 5.2 traz um exemplo em que tem-se uma composição colorida (Figura 5.2a) de uma região com terreno acidentado e, em conseqüência, com variação na luminosidade. É apresentado também, o resultado de classificação no matiz (Figura 5.2b), onde foi capaz de se identificar corretamente os alvos sob o terreno, mesmo sob condições não favoráveis de iluminação. Diferentemente do método Isoseg (Figura 5.2c), que mostra bem como esta variação dificulta a correta identificação dos alvos presentes na cena.

5.1.1.3. - Área 1 - Eucalipto

Esta área foi analisada, devido a sua boa identificação visual do alvo eucalipto. Espera-se portanto, um bom desempenho tanto no matiz, quanto no Isoseg. Entretanto, este fato não se confirmou sempre para o matiz.

5.1.1.3.1. - Três Bandas - TM345

A composição colorida RGB escolhida para se trabalhar com seu matiz foi a TM453, na qual o eucalipto destaca-se bastante com relação aos alvos vizinhos. Na Figura 5.3 vêem-se dois resultados de classificação de uma região com eucalipto na cena, onde a Figura 5.3c ilustra o desempenho do método Iseseg com limiar de similaridade 40 e limiar de aceitação de 99,9%.

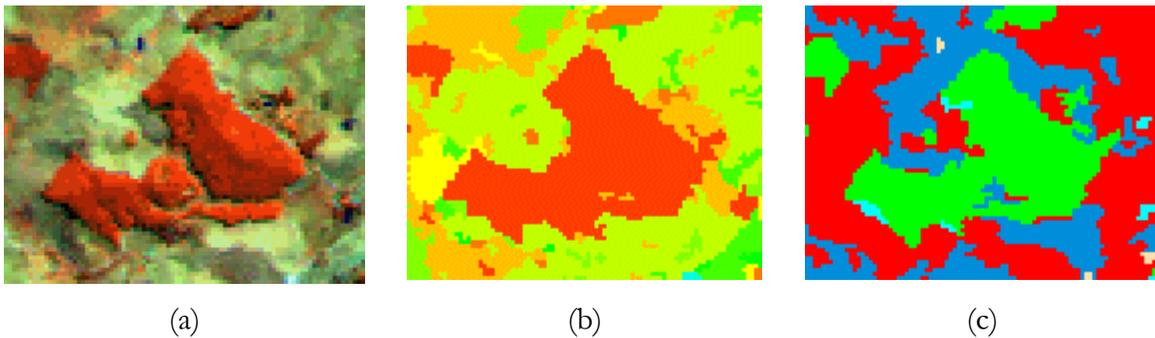


Fig. 5.3 - Detalhe de uma região com eucalipto:

- (a) composição TM453, com pasto (em tons de verde) em volta da região de eucalipto (em tons de vermelho);
- (b) classificação do matiz, limiar de segmentação 20, com eucalipto e pasto sendo bem definidos;
- (c) classificação Iseseg, limiar de similaridade 40 e, limiar de aceitação 99,9%, com eucalipto bem classificado, e com a classificação de pasto sofrendo influência da variação de luminosidade.

Ao redor da região de eucalipto, há predominantemente presença de pasto, alvo que na composição colorida mostrada na Figura 5.3a, apresenta coloração tendendo ao verde. Sobre o alvo pasto, a variação da iluminação fez com que o método Iseseg, interpretasse pasto (em vermelho) com presença de sombra como sendo uma outra classe (em azul).

Por outro lado, no resultado de matiz (Figura 5.3b), não há alteração de atribuição de classe no alvo pasto, em virtude da presença ou não de sombra. O fator que realmente determina a mudança de classe de uma região para outra é o matiz.

5.1.1.3.2. - Quatro Bandas - TM3457

O desempenho do classificador por matiz decaiu consideravelmente ao se trabalhar com quatro bandas, conforme pode ser visto na Figura 5.4b. Isso ocorreu, devido ao fato de os valores de matiz de eucalipto e do pasto ao redor, na composição colorida utilizada (Figura 5.4a) serem mais próximos que na composição anterior, havendo portanto confusão entre estes alvos.

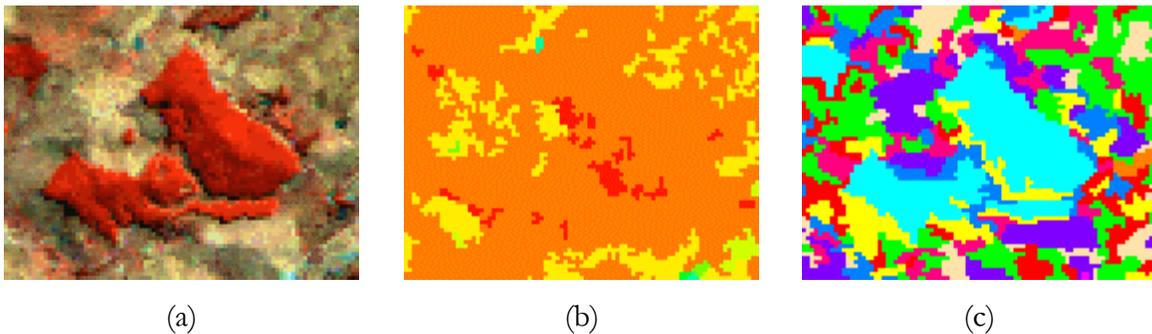


Fig. 5.4 - Detalhe de uma região com eucalipto:

- (a) composição TM4537; com pasto (em tons de bege) em volta da região de eucalipto (em tons de vermelho);
- (b) classificação matiz, limiar de segmentação 20, agora com grande parte de eucalipto sendo confundido com pasto, devido aos valores de matiz dos dois alvos serem mais próximos nesta composição;
- (c) classificação Iseg, limiar de similaridade 20 e limiar de aceitação 99,9%, havendo boa discriminação do alvo eucalipto, mas com uma maior influência da variação de luminosidade no alvo pasto.

Para o método Iseg, embora também tenha havido uma queda no desempenho, esta foi bem menos acentuada que a ocorrida no matiz. Na imagem de classificação vista na Figura 5.4c, o alvo eucalipto encontra-se dividido em duas classes, nas cores ciano e amarelo. Na vizinhança do alvo eucalipto também foi um número maior de classes que no caso anterior.

5.1.1.3.3. - Cinco Bandas - TM23457

Com estas cinco bandas, houve uma sensível melhora no resultado de ambos os métodos, principalmente quando comparados com os resultados com quatro bandas. A composição colorida usada foi TM45273 (Figura 5.5a), obtendo-se uma boa separabilidade entre o matiz de eucalipto e o da vizinhança, conforme pode ser visto na Figura 5.5b.

Para o Isoseg, o resultado alcançado não difere tanto do obtido com três bandas. No entanto, o melhor resultado geral (Figura 5.5c), permite a identificação do alvo eucalipto como pertencendo a uma classe somente. A classificação da vizinhança do eucalipto, como das outras vezes, continua sofrendo forte influência da variação de luminosidade, acarretando em número superestimado de classes.

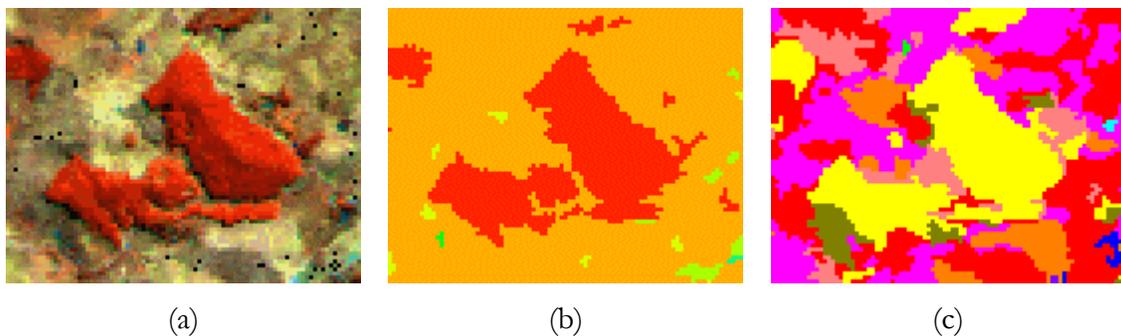


Fig. 5.5 - Detalhe da região com eucalipto em três situações:

- (a) composição TM45273; com pasto (em tons de marrom) em volta da região de eucalipto (em tons de vermelho);
- (b) classificação matiz, limiar 25 de segmentação; havendo muito boa identificação do alvo eucalipto e do alvo pasto, este não sofrendo qualquer influência de variação na luminosidade;
- (c) classificação Isoseg, limiar de similaridade 40, limiar de aceitação 95%. Boa identificação de eucalipto e muita influência da variação de luminosidade no alvo pasto.

5.1.1.4. - Área 2 - Água

Neste alvo o método Isoseg obteve resultados muito superiores aos alcançados pelo matiz. Esta diferença de resultado favorável ao método Isoseg, se deveu ao fato do matiz não conseguir resolver os diferentes tipos de alvo água existentes na cena. Existem corpos

d'água com alto, médio e baixo nível de sedimentos em suspensão que, dependendo da composição colorida utilizada, aparecerão com coloração distinta.

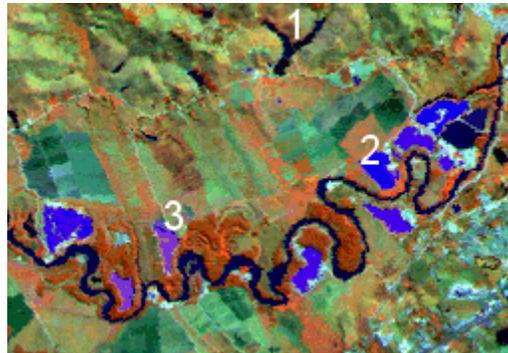


Fig. 5.6 - Composição colorida TM453, onde cada número destaca um tipo de alvo água:
1 - baixa quantidade de sedimentos em suspensão;
2 - média quantidade de sedimentos em suspensão;
3 - alta quantidade de sedimentos em suspensão;

Exemplos de cada tipo de alvo água podem ser visualizados na composição colorida TM453, mostrada na Figura 5.6. Cada tipo de alvo foi destacado com números, que estão em ordem crescente de quantidade de sedimentos em suspensão. Logo acima de uma represa, onde há pouca presença de sedimentos, aparece o número um. O número dois está destacando uma lagoa com um nível médio de quantidade de sedimento. O terceiro nível destacado, o mais alto, está sobre uma lagoa que aparece com uma coloração que tende ao violeta.

5.1.1.4.1. - Três Bandas - TM345

Na composição colorida TM453 (Figura 5.7a), dependendo da quantidade de sedimentos em suspensão presente na água, este alvo aparece com uma cor diferente. Para água com maior presença de sedimentos, ela aparece na cor violeta. Um azul forte caracteriza um nível médio sedimentos na superfície, enquanto que azul escuro, tendendo ao preto, indica baixa sedimentação.

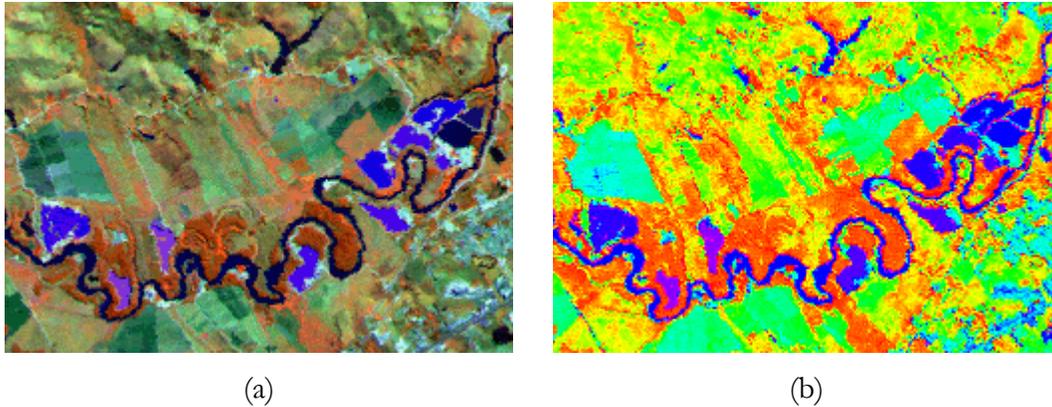


Fig. 5.7 - Composição TM453 (a) e sua respectiva imagem de matiz (b).

Enquanto que no método utilizando matiz (Figura 5.8a), não se foi capaz distinguir estas particularidades de cada tipo de alvo água, no Isoseg (Figura 5.8b) as mesmas são percebidas pelas diferentes classes a que são atribuídas. A represa, localizada na parte superior da figura, aparece em vermelho, mesma cor do curso d'água do rio Paraíba e das lagoas mais escuras, com baixa quantidade de sedimentos em suspensão.

Algumas lagoas que possuem um pouco mais de sedimentos, pertencem a classe da cor magenta. Por fim, em um tom de cinza, estão os dois lagos com maior quantidade de sedimentos. Já pelo método de matiz, todo alvo água aparece, indiscriminadamente, na cor azul.

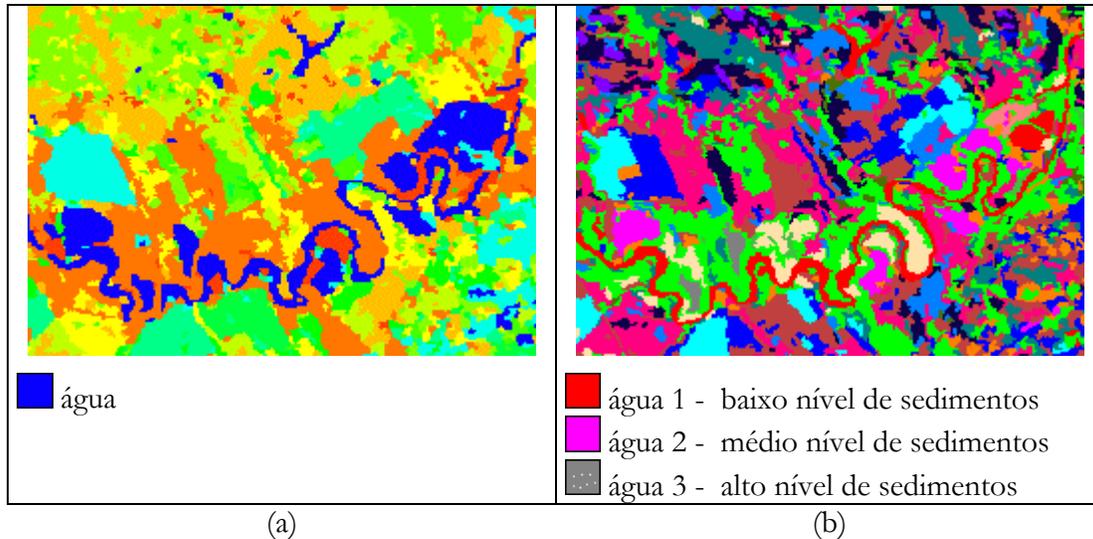


Fig. 5.8 - Resultado de classificação de região com presença do alvo água:
 (a) método por matiz, limiar de segmentação 20. Há muita confusão entre os tipos de alvo água, de acordo com o nível de sedimentos em suspensão.
 (b) método Isoseg, limiar de similaridade 20, limiar de aceitação 99%. Consegue identificar e separar os três tipos de alvo água.

5.1.1.4.2. - Quatro Bandas - TM3457

Ao acrescentar-se a banda TM7 à composição, não se verificou mudanças significativas no alvo água, para o método Isoseg. Entretanto, no método de matiz, se o resultado anterior já não era bom, agora ele ficou ainda mais comprometido com a confusão existente entre água e áreas irrigadas para plantação, destacadas por setas brancas na Figura 5.9a. Esta confusão pode ser entendida ao observar-se a própria imagem de matiz (Figura 5.9b), onde água e área irrigada aparecem com cores próximas.

Além disso, dentro do alvo água, perdeu-se na composição colorida TM4537, a separabilidade visual entre o nível alto de sedimentos em suspensão e os demais. Por tudo isso, o desempenho de classificação para o alvo água ficou muito aquém do resultado obtido com o método Isoseg.

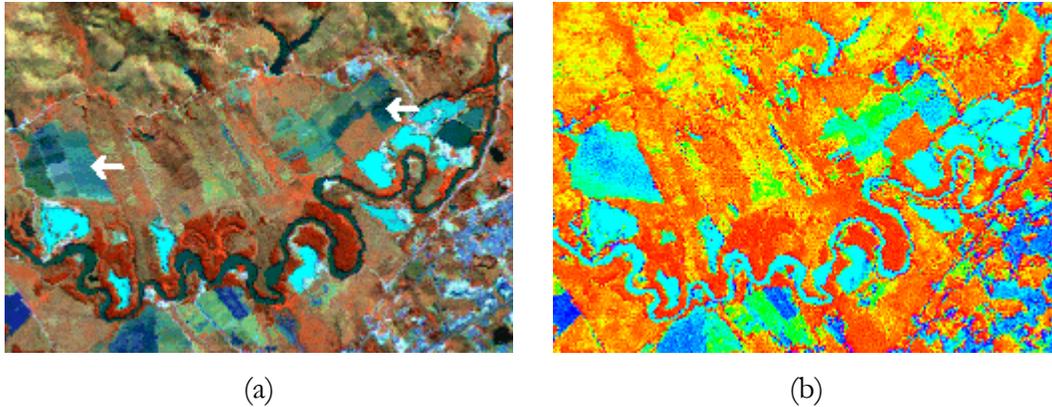


Fig. 5.9 - Composição TM4537 (a) - onde as setas brancas apontam para áreas irrigadas para plantação de arroz - e sua respectiva imagem de matiz (b).

Um dos resultados de Isoseg que melhor conseguiu separar o alvo água, foi o que utilizou similaridade 20 e limiar de aceitação 99% (Figura 5.10b). O curso d'água do rio, assim como todos os outros alvos com baixo nível de sedimentos, foram muito bem classificados e aparecem na cor amarelo. Os alvos com médio e alto nível de sedimentos, classificados nas cores caqui e laranja respectivamente, igualmente foram bem classificados.

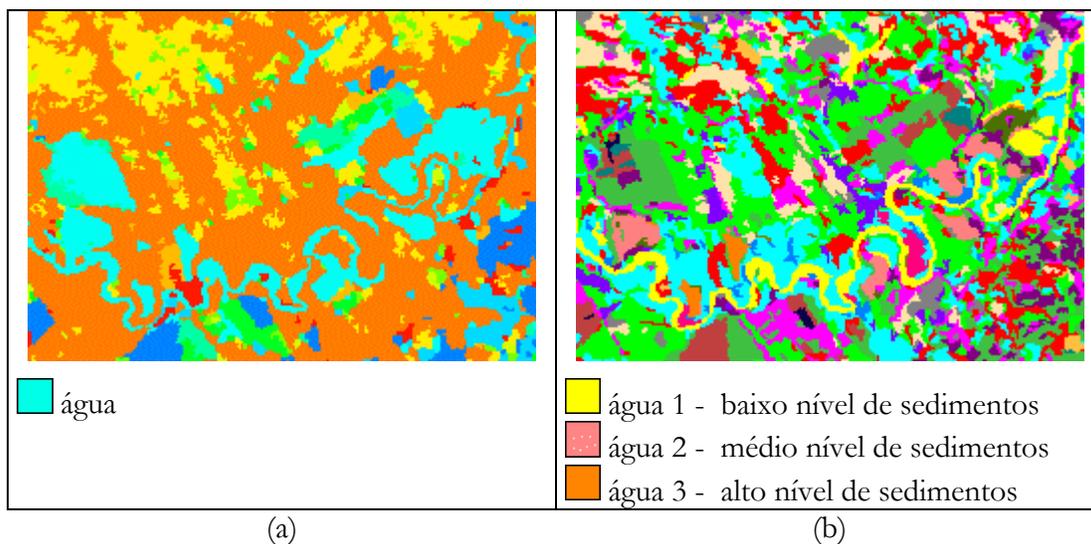


Fig. 5.10 - Resultado de classificação região com presença de alvo água:
 (a) método por matiz, limiar de segmentação 20. Há muita confusão entre os tipos de alvo água, de acordo com o nível de sedimentos em suspensão. Há confusão também áreas irrigadas, identificadas por setas brancas na Figura 5.9.
 (b) método Isoseg, limiar de similaridade 20 e limiar de aceitação 99%. Consegue identificar e separar os três tipos de alvo água.

5.1.1.4.3. - Cinco Bandas - TM23457

A composição utilizada (Figura 5.11a), com o acréscimo da banda TM2, permitiu a obtenção de uma imagem de matiz, na qual se foi capaz perceber as diferenças existentes no alvo água. No entanto, embora a imagem matiz (Figura 5.11b) tenha tido uma boa melhora na separabilidade, a sua classificação ainda fica inferior ao método Iseseg.

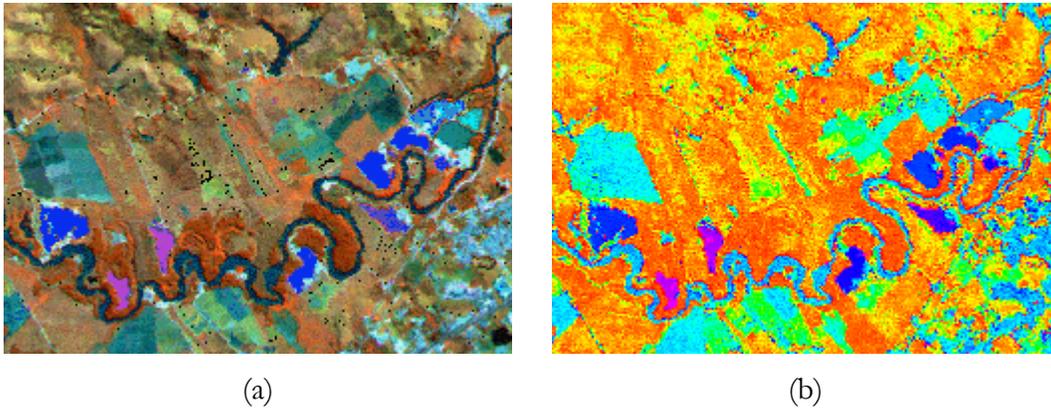


Fig. 5.11 - Composição TM45273 (a) e sua respectiva imagem de matiz (b).

Na Figura 5.12a, vê-se um resultado de classificação de matiz onde o rio ora aparece numa tonalidade clara de azul, ora numa tonalidade mais escura. Por vezes o curso do rio desaparece, tomado pela classe predominante na imagem, de cor laranja. A represa aparece representada por três classes (cores) diferentes. Lagoas com baixa quantidade de sedimentos, estão numa classe diferente do rio e da represa, num tom ciano.

Enfim, diversos problemas foram detectados nesta classificação, que teve como origem aquela imagem de matiz que justamente apresenta, visualmente, a melhor separabilidade dentre as mostradas até então. Enquanto isso, o método Iseseg novamente correspondeu bem às expectativas, e obteve bom desempenho para o alvo água.

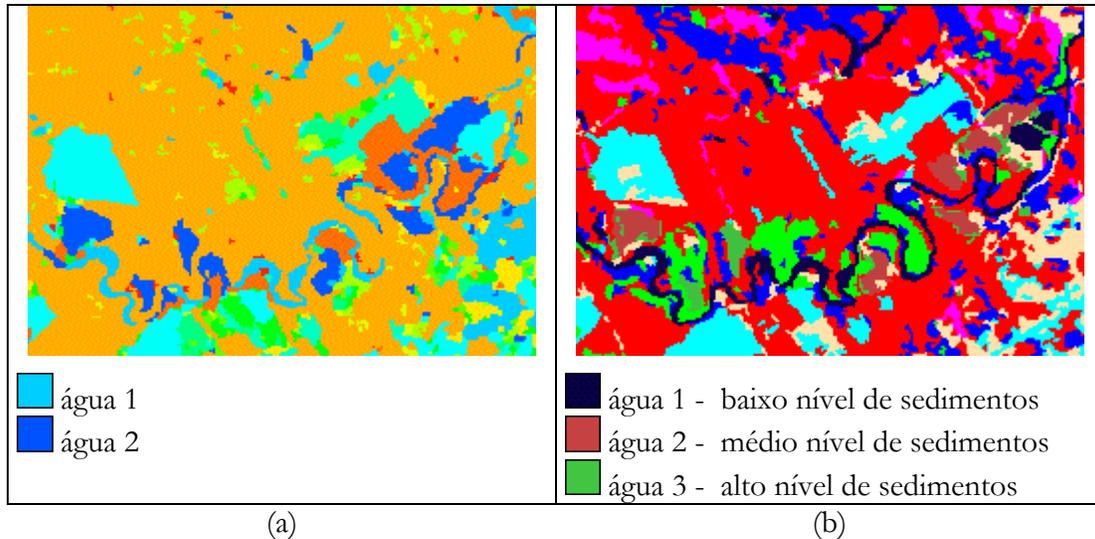


Fig. 5.12 - Resultado de classificação região com presença de diversos tipos de alvo água:
 (a) método por matiz, limiar de segmentação 25. Ainda existe confusão entre os três tipos de alvo água, porém em menor grau. Já consegue discriminar dois tipos de alvo água;
 (b) método Iseseg, limiar de similaridade 40, limiar de aceitação 99,9%. Consegue identificar e separar os três tipos de alvo água.

5.1.1.4.4. - Causas do Baixo Desempenho do Matiz no Alvo Água

Para a última composição vista (Figura 5.11a), uma explicação a ser dada pode ser, apesar de contraditório, a boa separabilidade visual da mesma. Os diferentes matizes dos alvos de água vistos na Figura 5.11b, possuem valores numéricos mais próximos do que os limiares de segmentação e/ou reclassificação - exceto o alvo com alto nível de sedimentos em suspensão. Por isso ocorrem tantas confusões entre eles.

Outra questão, resulta do fato de um dos parâmetros de agrupamento ser o tamanho mínimo da classe, relativo a cena inteira. Ao se estipular este parâmetro em 1%, significa que nenhuma classe poderá ter menos do que 1% do total de pixels na cena. E é isso que ocorre com as lagoas com alto nível de sedimentação. Por serem uma classe com poucos pixels, tem de ser agrupada à classe com valor de matiz mais próximo a ela, que no caso é justamente o rio.

No caso específico do rio, o processo de filtragem de pequenas regiões resulta na possibilidade de, em alguns trechos mais estreitos, haver uma substituição de classe água nestes pixels, pela classe mais freqüente em sua volta. Como consequência, o curso do rio fica subdividido em vários trechos desconectados, que na reclassificação podem ser atribuídos ou a uma única classe, ou a mais de uma, como acontece aqui.

O tamanho mínimo de região adotado foi de cinco pixels, ou seja, regiões com quatro ou menos pixels foram eliminadas da segmentação. Logo, trechos do rio com espessura menor ou igual a este tamanho estipulado, caso não estejam conectados a um trecho maior, tendem a desaparecer.

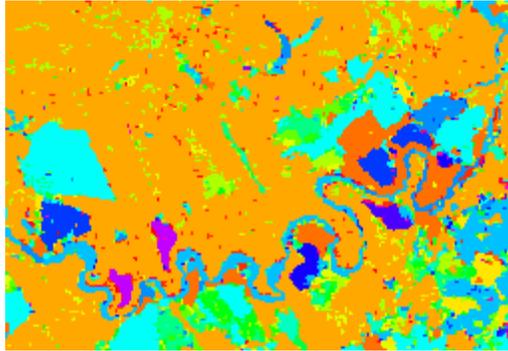


Fig. 5.13 - Classificação de matiz da composição TM45273, de uma área com presença de água em Caçapava: Limiar de segmentação 25, tamanho mínimo de pixel 2, limiar de agrupamento 10 e sem restrição de tamanho de classe. Com estes parâmetros houve uma boa identificação dos três tipos de alvo água presentes na cena.

Uma tentativa para se contornar todos esses problemas, é o uso de um tamanho mínimo de região menor, associado com um tamanho de classe igualmente menor ou sem este tipo de restrição, Para a imagem de classificação mostrada na Figura 5.13, o limiar de segmentação adotado foi 25, o tamanho máximo de região a filtrar foi 1, o limiar de agrupamento 10 e não houve restrição ao tamanho mínimo da classe.

Pode observar, através da Figura 5.13, que melhorou a separabilidade entre os alvos água com diferentes níveis de sedimentos em suspensão. Além disso, o curso do rio ficou melhor definido, quase sem trechos descontínuos. Outro fato a ser destacado, foi a

preservação da classe com alto nível de sedimentos em suspensão, que antes fora descartada da classificação por não atender ao critério de tamanho mínimo de classe.

5.1.1.5. - Área 3 - Alvo urbano

Diferentemente dos procedimentos anteriores, ao invés de se analisar uma parte da cena que continha o alvo, quatro regiões contendo área urbana foram utilizadas para a análise dos resultados. Isto se deveu pelo fato de se encontrar área urbana espacialmente distribuída em diversos pontos da imagem. A partir do resultado dos dois métodos sobre as quatro áreas destacadas nas respectivas imagens de classificação, analisaram-se os desempenhos dos segmentadores para o alvo urbano.

5.1.1.5.1. - Três Bandas - TM345

Nesta primeira comparação, os dois métodos tiveram um bom desempenho no interior dos retângulos, onde o alvo urbano foi bem classificado. No entanto, devido à textura característica de área urbana, o método Iseseg não foi capaz de encontrar uma única classe homogênea que representasse este alvo, havendo encontrado duas classes para o alvo urbano, como ilustra a Figura 5.14a.

Fora dos retângulos, ambos os métodos apresentaram erros de inclusão, ou seja, outros alvos foram classificados como urbano. As regiões onde ocorreram estes erros estão identificadas por setas pretas na imagem de classificação por matiz (Figura 5.14a), e por setas brancas na imagem de Iseseg (Figura 5.14b), onde houve maior ocorrência deste tipo de erro. Então, baseado nestas observações, pode-se dizer que houve para estas três bandas, na composição TM453, um resultado de comparação visual favorável ao método de matiz.

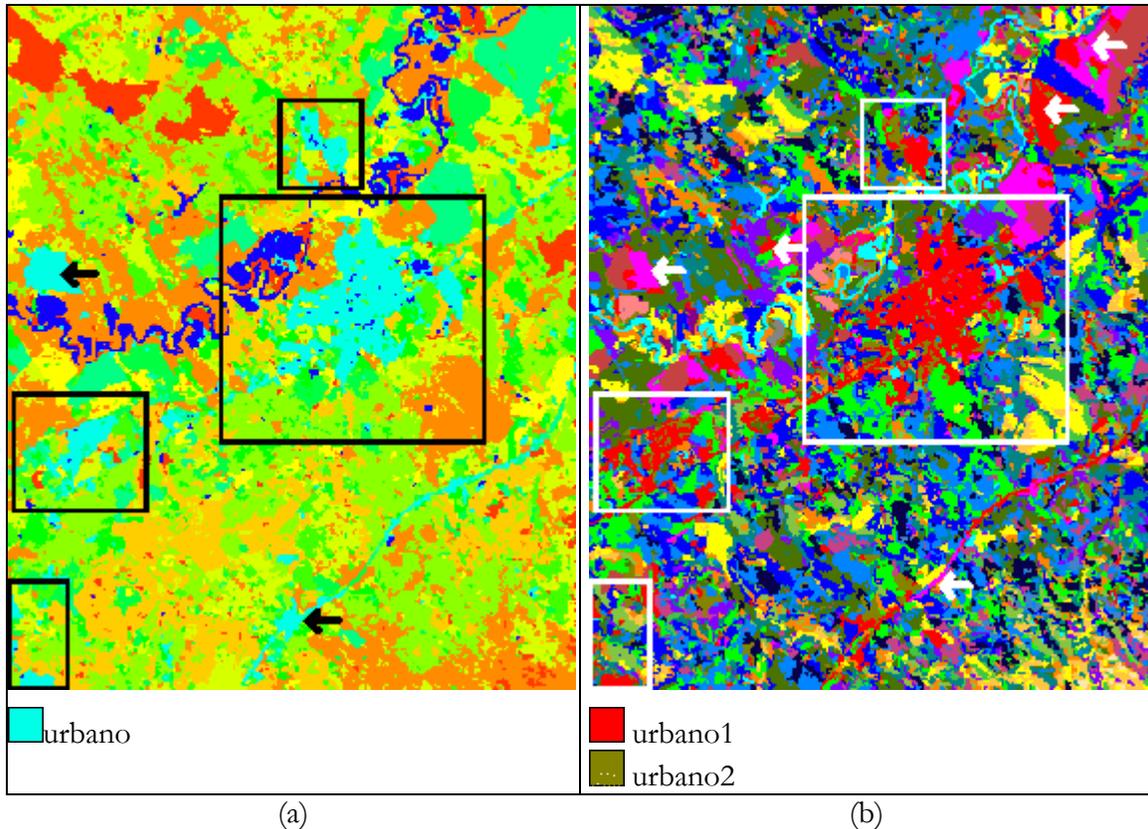


Fig. 5.14 - Resultados de classificação sobre as bandas TM345:

- (a) método por matiz, limiar de segmentação 25. As setas em preto apontam para regiões onde houve erros de inclusão de um alvo não-urbano na classe urbano;
- (b) Isoseg, limiar de similaridade 30 e limiar de aceitação 95%. As setas em branco apontam para regiões onde houve erros de inclusão de um alvo não-urbano na classe urbano.

5.1.1.5.2. - Quatro Bandas - TM3457

Nesta nova situação, a área urbana presente no interior dos retângulos foi bem classificada em ambos os métodos. Novamente o Isoseg classificou o alvo urbano em duas classes, identificadas com as cores vermelho e magenta, enquanto o matiz da composição TM4537, representa o alvo com cor azul.

No entanto, ao analisar-se a Figura 5.15a fora dos limites dos retângulos, vê-se que o matiz encontrou área urbana em algumas regiões, identificadas por setas pretas, onde na verdade estão outros alvos. Este erro de inclusão, atingiu uma área bem menor na imagem de

classificação obtida pelo método Isoseg (Figura 5.15b). Portanto, houve um desempenho superior do método Isoseg com relação ao método de segmentação por matiz.

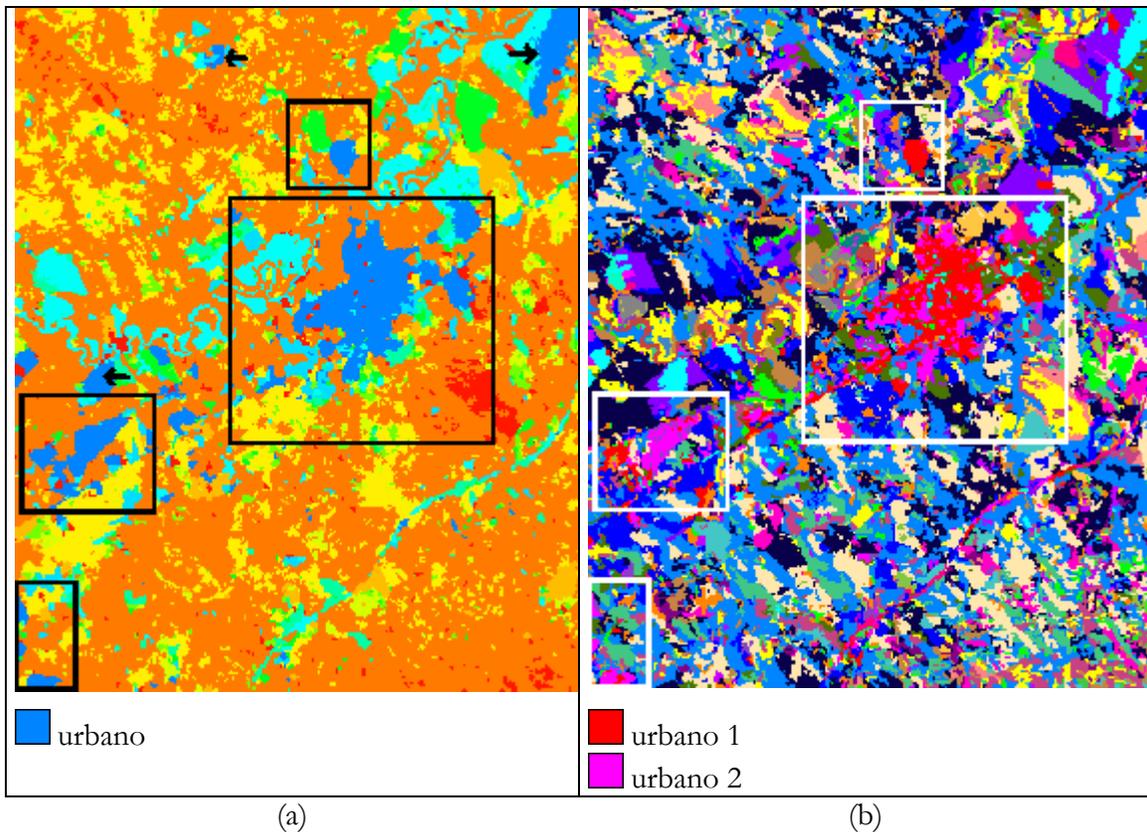


Fig. 5.15 - Resultados de classificação sobre as bandas TM3457:

- (a) método por matiz, limiar de segmentação 20. As setas em preto apontam para regiões onde houve erros de inclusão de um alvo não-urbano na classe urbano;
- (b) Isoseg, limiar de similaridade 40 e limiar de aceitação 75%. As setas em branco apontam para regiões onde houve erros de inclusão de um alvo não-urbano na classe urbano.

5.1.1.5.3. - Cinco Bandas - TM23457

Foram com estas cinco bandas que ambos os métodos obtiveram o melhor desempenho, havendo poucos erros de inclusão fora dos retângulos. As confusões ocorridas no matiz, localizaram-se nos trechos do rio e na represa, destacados com setas pretas na Figura 5.16a. No canto esquerdo inferior da imagem, há um erro de omissão, com área urbana sendo classificada como corpo d'água.

No Isoseg, que mais uma vez dividiu o alvo urbano em duas classes, igualmente em poucos pontos ocorreu erro de inclusão. Alguns foram identificados com setas brancas. Esses erros não chegam a comprometer a avaliação positiva das imagens de classificação dos dois métodos, que mostraram um bom desempenho na identificação do alvo urbano.

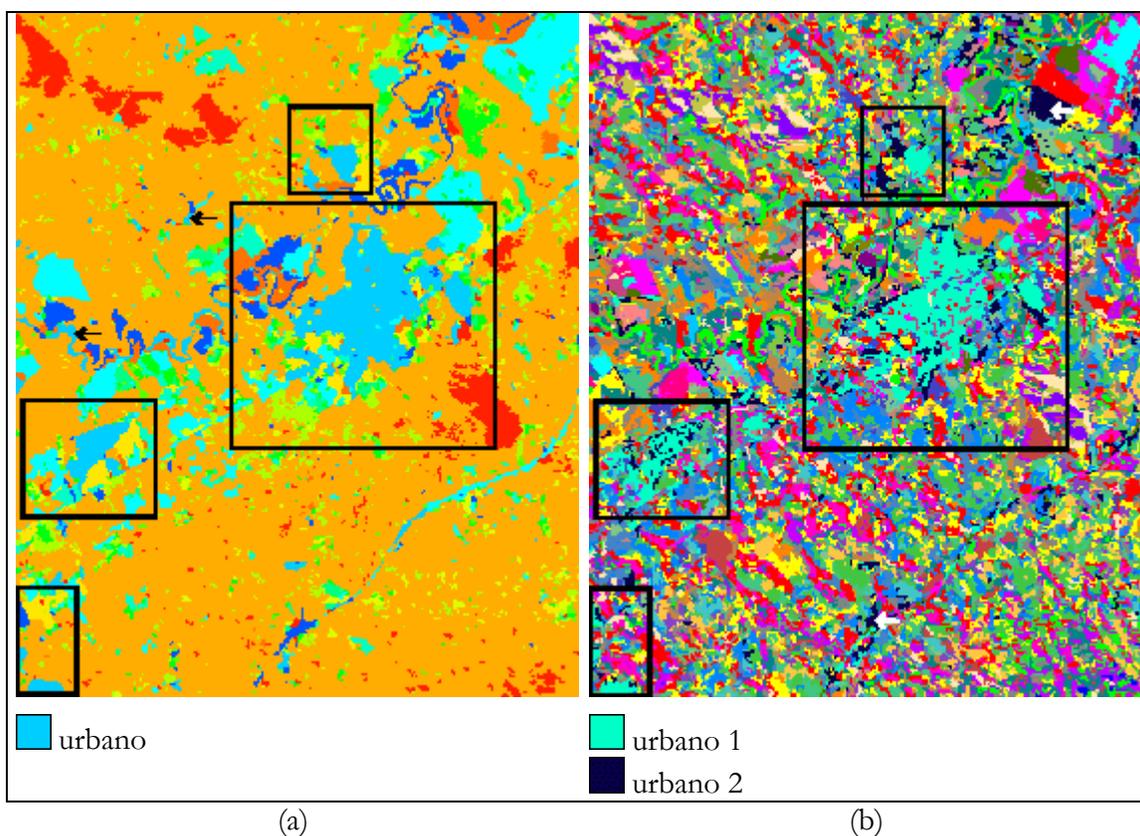


Fig. 5.16 - Resultados de classificação sobre as bandas TM23457:

- (a) método por matiz, limiar de segmentação 25; As setas em branco apontam para regiões onde houve erros de inclusão de um alvo não-urbano na classe urbano.
- (b) Isoseg, limiar de similaridade 20 e limiar de aceitação 90%. As setas em branco apontam para regiões onde houve erros de inclusão de um alvo não-urbano na classe urbano.

Apesar de haver aqui um certo equilíbrio entre os desempenhos dos dois métodos, convém ressaltar que se compararam apenas os melhores resultados e, na maior parte das observações feitas, o resultado do método Isoseg superestima o número de classes dos alvos analisados. Isto torna difícil o mapeamento das classes e, por mais criterioso que este

seja realizado, um componente de subjetividade sempre estará contido no resultado final. Já o resultado por matiz é todo ele obtido sem mapeamento, ou seja, sem interferência de intérprete.

5.1.2. - Tremembé

A característica dos dados de matiz, de sofrerem pouca influência da variação de luminosidade sobre o terreno, motivou o estudo de sua aplicação em outra região com relevo ainda mais acidentado que Caçapava, inclusive para avaliar até que ponto esta característica do matiz é válida (em regiões de sombra muito escura, sabe-se que o valor de matiz se torna instável).

O objetivo principal agora é o de separar as regiões de floresta das de não-floresta. A imagem de Tremembé (Figura 5.17) apresenta predominantemente áreas de floresta sobre a serra da Mantiqueira - de terreno muito acidentado - e, na parte inferior direita, agricultura e área urbana.

Sobre a serra da Mantiqueira é que está situada a maioria das regiões de sombra na imagem, onde os valores de matiz tornam-se instáveis. Estas regiões são ignoradas pelo segmentador, e seus pixels aparecem em preto na imagem classificada, caracterizando uma classe não-válida, ou não-definida na classificação.

Uma parte da cena foi escolhida para avaliar-se o desempenho dos dois métodos de classificação, na tarefa identificar o alvo floresta. Localizada próximo ao canto superior direito da imagem, esta área está destacada por um retângulo branco na Figura 5.17.

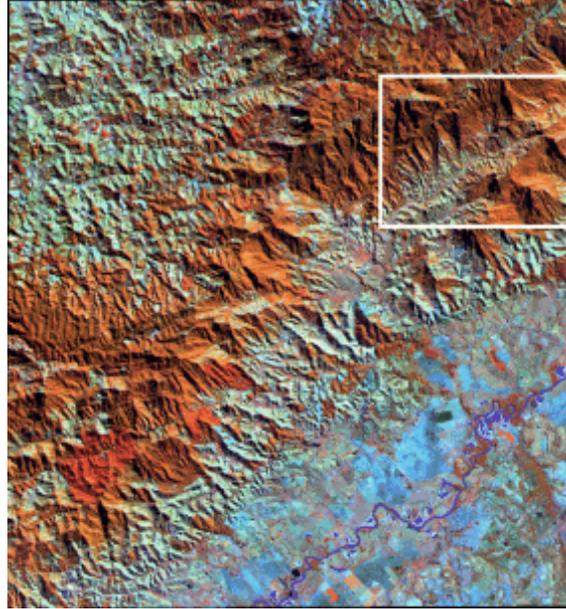


Fig. 5.17 - Composição TM453 de Tremembé. Em destaque está a região com forte presença de sombra, onde a classificação foi avaliada qualitativamente.

5.1.2.1. - Três Bandas - TM453

Na composição colorida (Figura 5.18a) desta parte da cena, há grande presença de sombra, a qual resulta em valores instáveis de matiz nos respectivos pixels, vistos na cor azul na Figura 5.18b. Nota-se que no resultado de classificação pelo método Isoseg (Figura 5.19b), as regiões de sombra, identificadas principalmente pela classe na cor amarelo, têm uma presença maior quando comparado com o resultado de matiz.

Isto mostra que, apesar de a sombra causar grande instabilidade no matiz, sua área de influência é menor que no Isoseg. Ou seja, um área maior da imagem será classificada com as classes que realmente interessam. Apesar disso, o resultado do método Isoseg, mostrado à Figura 5.19, foi muito bom, onde o alvo floresta aparece bem classificado por duas classes nas cores ciano e verde.

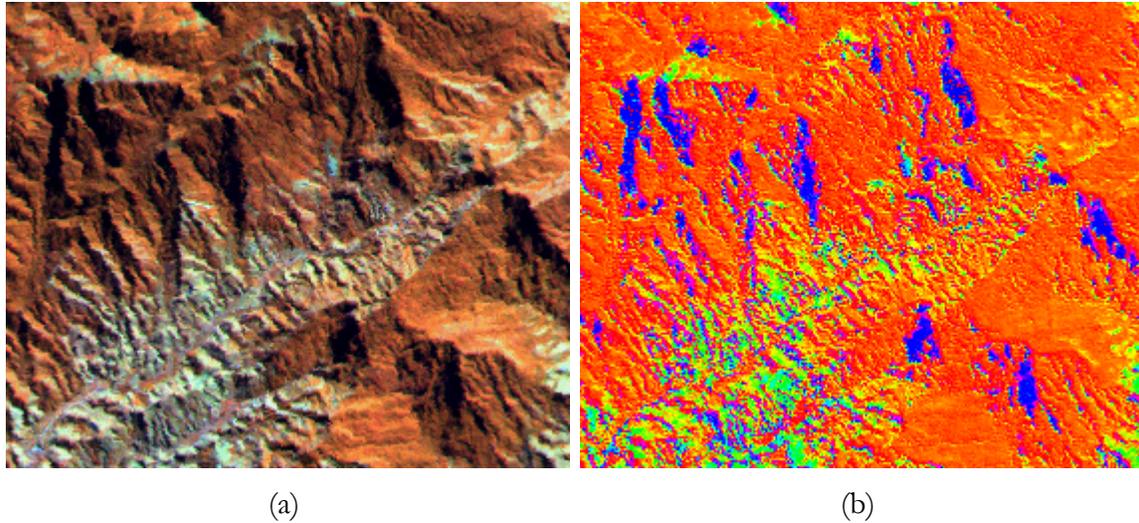


Fig. 5.18 - Detalhe de região com presença de floresta:

- (a) composição TM453, havendo forte presença de região com sombra;
- (b) matiz de TM453, onde a influência da sombra sobre os valores de matiz da região de floresta, é notada pelo matiz azul. Evidenciando uma instabilidade do matiz nestas áreas.

A classificação do matiz apresentou resultado semelhante para o alvo floresta, mas quando é comparado o resultado de áreas em torno do leito do córrego, diferentemente do que ocorrera nas vezes anteriores, o matiz encontrou um número superior de classes que o Isoseg. Logo, se fosse necessário, um mapeamento deveria ser feito agora sobre o resultado de matiz, implicando em uma interferência do intérprete no resultado.

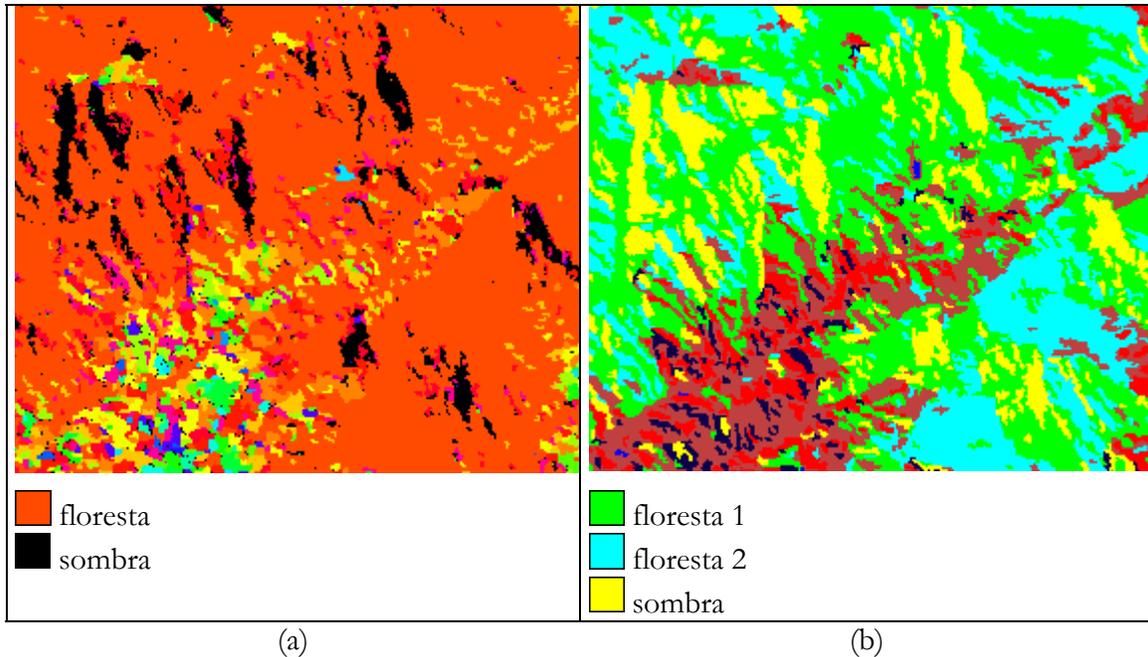
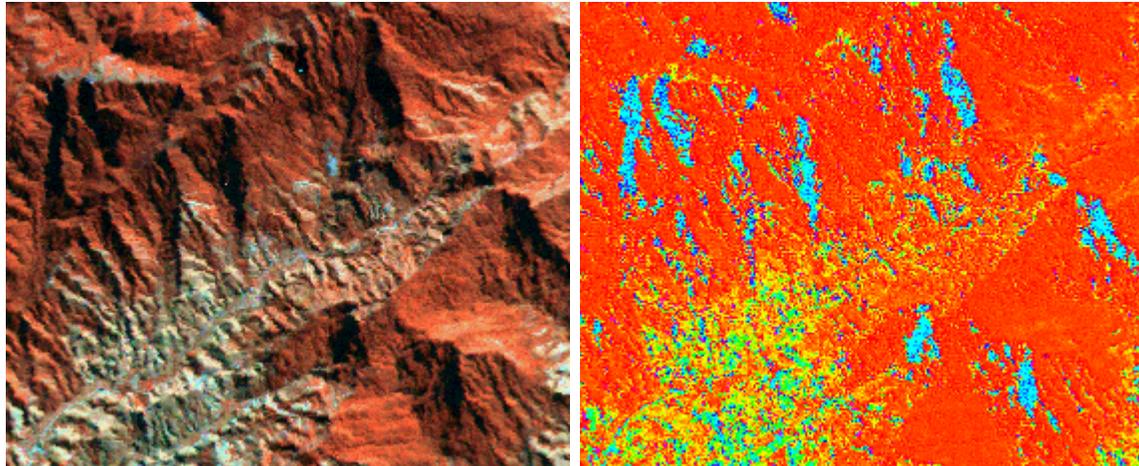


Fig. 5.19 - Resultados de classificação sobre as bandas TM345:
 (a) método por matiz, limiar de segmentação 20;
 (b) Iseseg, limiar de similaridade 40 e limiar de aceitação 99,9%.

5.1.2.2. - Quatro Bandas - TM3457

Conforme pode ser vista na Figura 5.20a, a composição colorida obtida com a adição da banda TM7, ficou visualmente muito próxima a anterior. Conseqüentemente, a imagem do matiz desta composição também tem valores que diferem pouco da situação anterior. As áreas de baixo brilho, ou de sombra, aparecem em ciano.

Logo, alterou-se pouco o panorama da classificação de matiz (Figura 5.21a), tendo esta como mudança mais visível, o avanço da área de floresta sobre a de vegetação menos densa próxima ao leito do córrego.



(a)

(b)

Fig. 5.20 - Detalhe de região com presença de floresta:

- (a) composição TM4537, havendo forte presença de região com sombra;
- (b) matiz de TM4537, onde a influência da sombra sobre os valores de matiz da região de floresta, é notada pelo matiz ciano. Evidenciando uma instabilidade do matiz nestas áreas.

As mudanças no resultado de Iseseg, visto na Figura 5.21b, também foram pouco percebidas. Houve, numa menor intensidade, um aumento da área das classes atribuídas ao alvo floresta, tal como ocorrera no matiz. Afora isso, nenhuma outra alteração que merecesse registro foi observada.

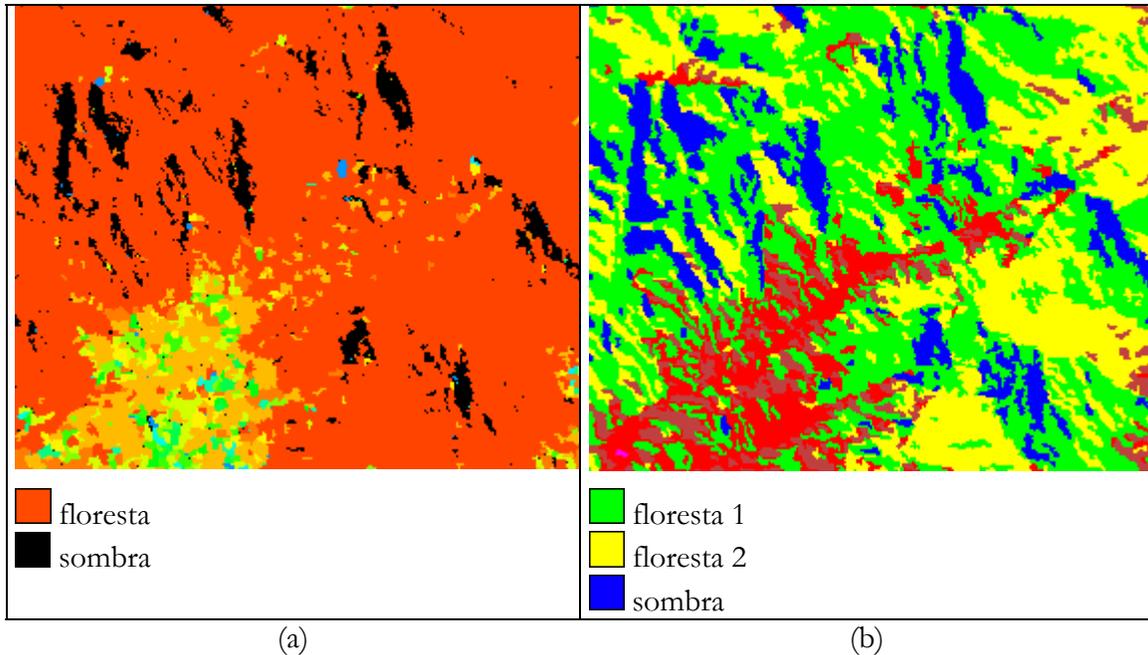


Fig. 5.21 - Resultados de classificação sobre as bandas TM4573:
 (a) método por matiz, limiar de segmentação 20;
 (b) Iseseg, limiar de similaridade 40 e limiar de aceitação 99,9%.

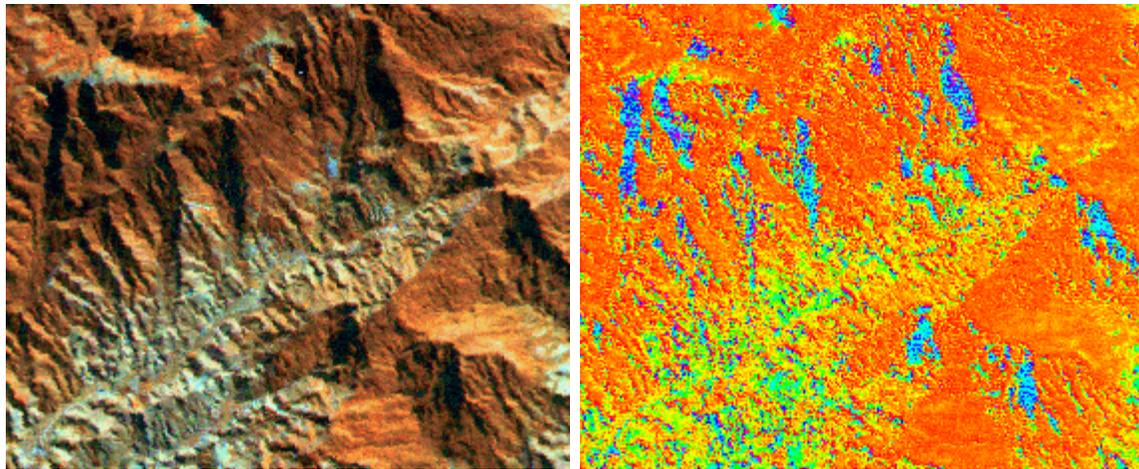
5.1.2.3. - Cinco Bandas - TM23457

A composição de bandas empregada com cinco bandas foi TM45273, que apresentou pouca diferença visual com relação as composições anteriores. A imagem de matiz (Figura 5.22b) mostra as regiões de valores de matiz instáveis, de baixa luminosidade, em tons que variam do azul ao ciano.

As regiões de baixo brilho, representadas pela cor preto na classificação da imagem de matiz, diferenciam-se das existentes nos resultados de classificação apresentados até então, pelo fato de terem sido obtidas a partir de um valor maior de intensidade mínima. Anteriormente, pixels com valores de intensidade abaixo de 0,10 eram descartados da classificação. Agora, apenas os pixels com valores acima de 0,175 foram levados em conta.

Como pode ser visto na Figura 5.23, ao usar-se o valor 0,10 como limite para o qual, abaixo dele todos os pixels são considerados instáveis quanto ao matiz, poucos destes pixels são

encontrados. Isto ocorre devido à adição da banda TM2 na composição obtida através de cinco bandas espectrais.



(a)

(b)

Fig. 5.22 - Detalhe de região com presença de floresta:

- (a) composição TM45273, havendo forte presença de região com sombra;
- (b) matiz de TM45273, onde a influência da sombra sobre os valores de matiz da região de floresta, é notada pelos matizes azul e ciano. Evidenciando assim, uma instabilidade do matiz nestas áreas.

Esta banda espectral está mais sujeita à influência da atmosfera na sua aquisição do que as demais utilizadas até então. Como consequência disso, as regiões de sombra da composição colorida mostrada na Figura 5.22a, sofrem um efeito de bruma, e seu brilho na imagem é maior que anteriormente. Para corrigir este problema, o mais adequado é utilizar imagens que passaram por uma correção atmosférica antes de se fazer a composição colorida.

Como este problema foi detectado num estágio avançado deste trabalho, optou-se então por uma solução alternativa. Aumentou-se o valor de intensidade mínima gradativamente, até que a maioria dos pixels onde o matiz se torna instável fosse localizada, donde chegou-se ao valor 0,175 de intensidade. Na classificação no matiz (Figura 5.24a), ao compará-la resultados anteriores, nota-se não haver tanta predominância da classe floresta sobre as demais, o que torna este resultado mais próximo do resultado obtido pelo método Isoseg (Figura 5.24b).

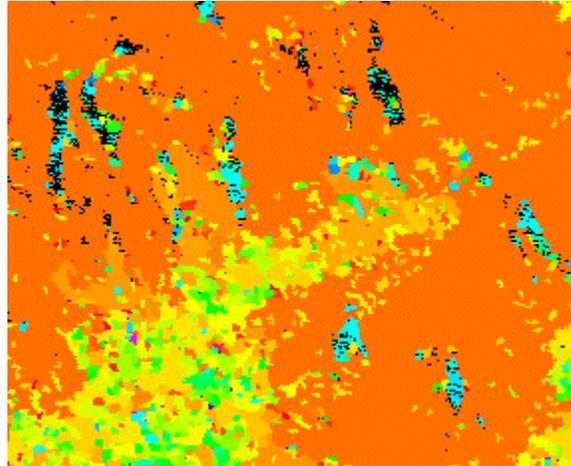


Fig. 5.23 - Resultado de classificação com regiões de valores instáveis de matiz, com intensidade menor que 0,10. Nem todas as regiões com sombra são corretamente mapeadas.

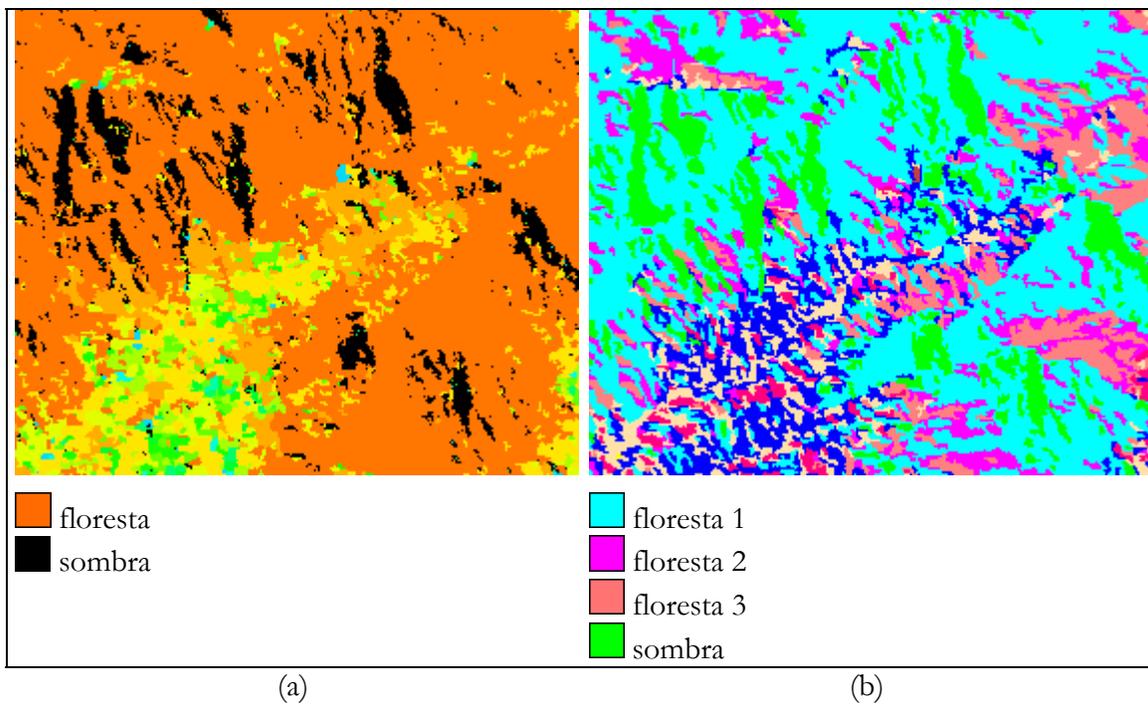


Fig. 5.24 - Resultados de classificação sobre as bandas TM23457:
 (a) método por matiz, limiar de segmentação 20;
 (b) Isoseg, limiar de similaridade 30 e limiar de aceitação 99,9%.

5.2. - Avaliação Quantitativa

A avaliação estatística foi utilizada com o propósito de se ter uma medida aproximada da qualidade da classificação realizada, de se comparar os resultados obtidos através dos métodos de matiz e Isoseg. Pretendeu-se também realizar comparação o resultado de segmentação entre as diferentes imagens de matiz, a partir de composições coloridas obtidas através de N bandas. Principalmente para verificar se o incremento de bandas traz alguma melhora no resultado da classificação por matiz.

5.2.1. - Caçapava, 146 Pontos

Duas comparações foram realizadas nesta etapa. Uma para verificar se há melhora na discriminação dos alvos urbano e não-urbano ao aumentar-se o número de bandas na obtenção do matiz, e outra para verificar se o resultado de matiz supera o resultado alcançado com o método Isoseg.

Houve uma sensível melhora na classificação por matiz, ao se utilizar quatro bandas ao invés de três, como pode ser constatado pelos valores estimados de kappa da Tabela 5.1, e visto no gráfico da Figura 5.25. Para todos os limiares, o matiz da composição TM4537 apresentou valor estimado de kappa maior do que o matiz da composição com três bandas.

Este fato tem como explicação, além de uma melhor separabilidade visual do alvo urbano, o erro de inclusão existente na classificação de matiz da composição TM453. No entanto, em nenhum caso esta diferença dos kappas estimados entre quatro e três bandas foi significativa a um nível de significância de 10%. Nas Seções seguintes, onde se utilizaram amostras de tamanhos superiores, começa a haver diferenças significativas entre os valores dos kappas estimados, confirmando a tendência observada aqui.

TABELA 5.1 - KAPPA ESTIMADO, SUA VARIÂNCIA AMOSTRAL E VALORES DE ESTÍSTICA Z DE COMPOSIÇÕES TM453, TM4537 E TM45273

limiar	kappa			Var. kappa			Z		
	TM453	TM4537	TM45273	TM453	TM4537	TM45273	4 e 3	4 e 5	3 e 5
20	0,719	0,777	0,703	8,84E-03	7,66E-03	9,79E-03	0,451	0,562	0,119
25	0,703	0,777	0,885	9,79E-03	7,66E-03	4,24E-03	0,562	-0,991	-1,539
30	0,734	0,851	0,789	7,99E-03	5,28E-03	6,89E-03	1,022	0,563	-0,456
35	0,693	0,829	0,761	9,26E-03	5,53E-03	7,49E-03	1,124	0,599	-0,528
40	0,656	0,763	0,734	1,13E-02	8,53E-03	7,99E-03	0,765	0,231	-0,562

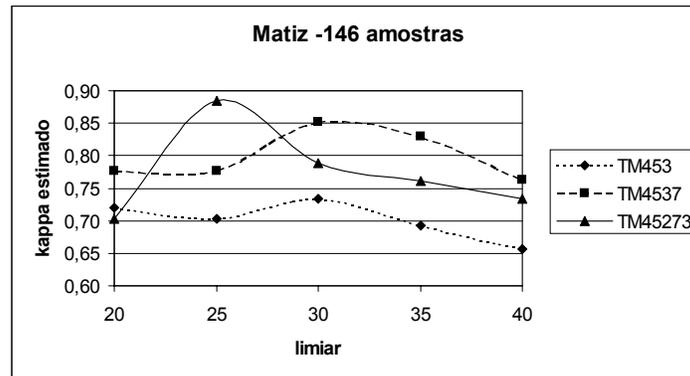


Fig. 5.25 - Valores estimados de kappa para matiz de três, quatro e cinco bandas.

As matrizes de confusão apresentadas na Figura 5.26a, são de duas classificações a limiar de segmentação 30. Ao analisá-las, percebe-se que na composição TM453, houve maior ocorrência de erro de inclusão no alvo urbano (Figura 5.26a), que na composição TM4537 (Figura 5.26b). Como a classe urbano possui um número pequeno de pixels, variações pequenas no erro de inclusão, causam uma diferença considerável no valor do coeficiente kappa.

TM453				
	Urb	N Urb	total	inclusão
Urb	13	5	18	27,78%
N Urb	3	125	128	2,40%
total	16	130	146	
omissão	18,75%	3,85%		

(a)

TM4537				
	Urb	N Urb	total	inclusão
Urb	13	1	14	7,14%
N Urb	3	129	132	2,33%
total	16	130	146	
omissão	18,75%	0,77%		

(b)

Fig. 5.26 - Matriz de confusão de classificação com limiar de segmentação 30, sobre:
 (a) matiz de composição TM453;
 (b) matiz de composição TM4537.

Os valores estimados de kappa são $\hat{\kappa}_1=0,734$ e $\hat{\kappa}_2=0,851$, para matiz de composição TM453 e TM4537, respectivamente. Esta diferença é consequência justamente do maior erro de inclusão na primeira classificação.

Na classificação de matiz da composição TM453, um total de 17890 pixels foram classificados como área urbana, contra 15976 pixels na de matiz de TM4537 e 21859 pixels na de TM45273. Supondo-se que os erros de inclusão detectados, sejam proporcionais ao número de pixels existentes da classe urbana na classificação. Logo, para três e quatro bandas, os erros de inclusão se mostram coerentes com este raciocínio. No entanto, para cinco bandas o erro de inclusão não foi o mais elevado (Figura5.27).

TM45273	Referência			inclusão
	Urb	N Urb	total	
Urb	13	3	16	18,75%
N Urb	3	127	130	2,36%
total	16	130	146	
omissão	18,75%	2,31%		

Fig. 5.27 - Matriz de confusão de classificação com limiar de segmentação 30, sobre matiz de composição TM45273:

Com relação à composição TM453, a explicação poder ser a distribuição espacial dos pixels mal classificados. Na classificação do matiz de TM45273, os pixels erroneamente classificados como urbano foram basicamente os pixels de água, localizados à noroeste da mancha urbana. Enquanto isso, para três bandas, a classe urbano mal classificada está distribuída em diversos locais da cena.

Com esta amostragem aleatória de 146 pontos, não se foi capaz de perceber este maior erro de inclusão ocorrido na classificação a partir de cinco bandas, devido a distribuição espacial deste erro. Nas próximas Seções, se mostrará que para amostragens de tamanhos maiores, o desempenho da classificação com cinco bandas tenderá a ser o mais fraco. É importante ainda frisar que as análises dos resultados feitas nesta seção, nem sempre coincidirão com a análise qualitativa

Na Tabela 5.2 estão expostos os valores estimados de kappa e suas variâncias amostrais para os métodos Isoseg e de segmentação no matiz. Para cada limiar de aceitação e de segmentação utilizados, respectivamente, no método Isoseg e de matiz, gerou-se um kappa estimado para os resultados de classificação utilizando-se as bandas TM345, TM3457 e TM23457, com limiares de similaridade 20, 30 e 40.

Na comparação com o método Isoseg do "software" SPRING, o valor estimado de kappa de matiz foi superior na maior parte da vezes, exceto para três casos. Na Tabela 5.3, estão os valores da estatística Z, resultante da comparação entre a classificação do matiz, e os resultados obtidos pelo método Isoseg, sob vários limiares de aceitação.

TABELA 5.2 - VALORES ESTIMADOS DE KAPPA E SUAS VARIÂNCIAS, ISOSEG COM VÁRIOS LIMIARES DE ACEITAÇÃO E CLASSIFICAÇÃO DE MATIZ

bandas	limiar	kappa						Var kappa					
		99.9%	99.0%	95.0%	90.0%	75.0%	matiz	99.9%	99.0%	95.0%	90.0%	75.0%	matiz
345	20	0,471	0,438	0,531	0,579	0,522	0,719	1,54E-02	1,38E-02	1,31E-02	1,30E-02	1,55E-02	8,84E-03
	30	0,076	0,643	0,732	0,522	0,696	0,734	1,02E-02	9,81E-03	9,23E-03	1,55E-02	1,14E-02	7,99E-03
	40	0,597	0,459	0,527	0,503	0,550	0,656	9,27E-03	1,40E-02	1,43E-02	1,42E-02	1,54E-02	1,13E-02
3457	20	0,412	0,227	0,580	0,550	0,664	0,777	1,62E-02	1,46E-02	1,40E-02	1,54E-02	1,20E-02	7,66E-03
	30	0,518	0,514	0,553	0,580	0,488	0,851	1,09E-02	1,20E-02	1,42E-02	1,40E-02	1,67E-02	5,28E-03
	40	0,667	0,667	0,685	0,579	0,394	0,763	9,57E-03	9,57E-03	1,09E-02	1,20E-02	1,74E-02	8,53E-03
23457	20	0,579	0,401	0,703	0,703	0,715	0,703	1,20E-02	1,32E-02	9,79E-03	9,79E-03	1,03E-02	9,79E-03
	30	0,578	0,556	0,262	0,703	0,580	0,789	1,10E-02	1,20E-02	1,58E-02	9,79E-03	1,40E-02	6,89E-03
	40	0,643	0,660	0,629	0,503	0,634	0,734	9,81E-03	8,93E-03	1,16E-02	1,42E-02	1,25E-02	7,99E-03

Valor positivo de estatística Z indica, embora nem sempre com certeza, que o resultado de matiz é melhor. Para valores negativos de estatística Z, a tendência é considerar o Isoseg melhor. Valores nulos indicam total indefinição.

Para se poder afirmar que um resultado de classificação é superior a outro, deve-se utilizar o teste de hipótese. Em cinza estão destacados treze valores de estatística Z, que passam no teste de hipótese bilateral, a um nível de significância (α) igual a 10%.

Nas Figuras 5.28, 5.29 e 5.30 são mostrados os valores estimados de kappa das classificações pelo método Isoseg e por matiz. Estas figuras ilustram uma aparente

superioridade da classificação por matiz para as composições utilizando três, quatro e cinco bandas respectivamente.

TABELA 5.3 - COMPARAÇÃO ENTRE DESEMPENHOS DE CLASSIFICAÇÃO DE ISOSEG E MATIZ

bandas	limiar	Z				
		99,9%	99,0%	95,0%	90,0%	75,0%
345	20	1,593	1,868	1,271	0,947	1,263
	30	4,878	0,679	0,011	1,381	0,271
	40	0,410	1,240	0,806	0,957	0,645
3457	20	2,364	3,684	1,339	1,494	0,807
	30	2,621	2,575	2,141	1,953	2,453
	40	0,715	0,715	0,566	1,290	2,293
23457	20	0,841	1,989	0,000	0,000	-0,087
	30	1,577	1,698	3,505	0,670	1,448
	40	0,679	0,564	0,751	1,549	0,698

Esta tendência é mais forte para quatro bandas, composição que a limiar de segmentação 30, todos os valores da estatística Z confirmam a hipótese alternativa de que os kappa de matiz e Isoseg são realmente diferentes a um nível de significância de 10% . Portanto, os resultados verificados, para a amostragem com 146 pontos avaliados por três intérpretes, tendem a ser favoráveis à classificação feita sobre o matiz.

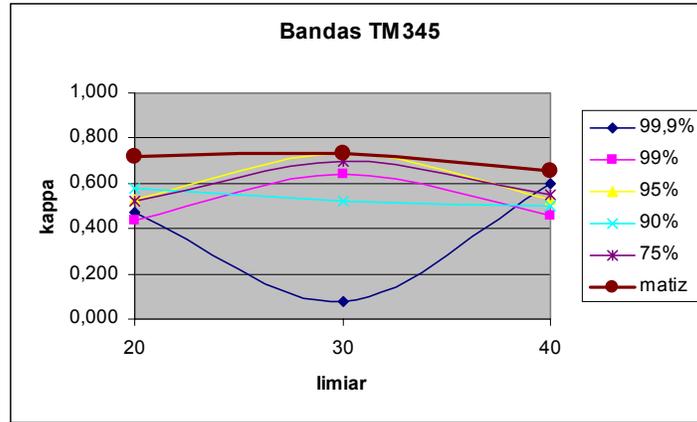


Fig. 5.28 - Comparação entre o método Iseseg, com diferentes limiares de aceitação, e o método de matiz para três bandas.

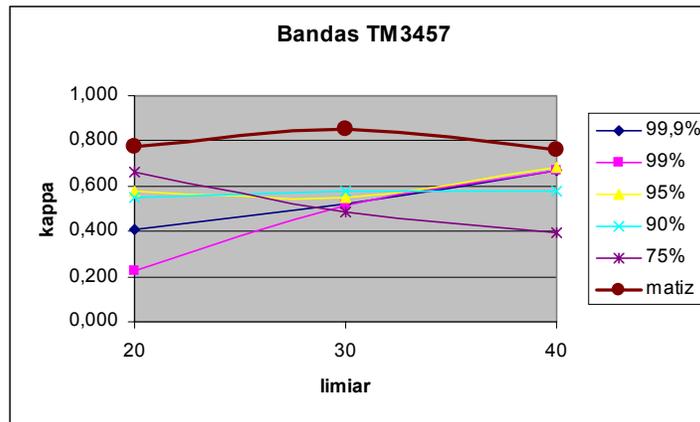


Fig. 5.29 - Comparação entre o método Iseseg, com diferentes limiares de aceitação, e o método de matiz para quatro bandas.

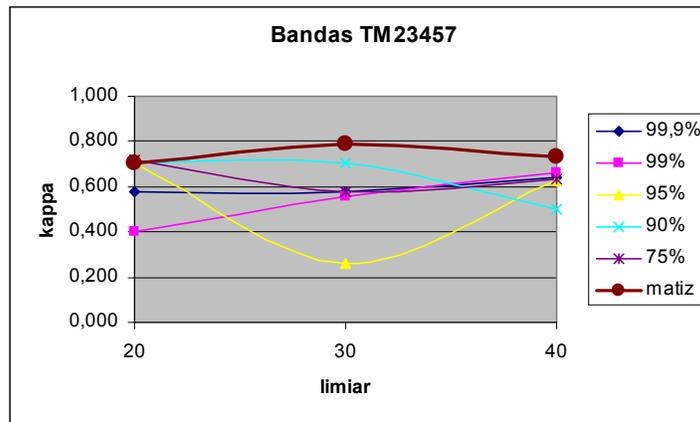


Fig. 5.30 - Comparação entre o método Iseseg, com diferentes limiares de aceitação, e o método de matiz para cinco bandas.

5.2.2. - Caçapava, 475 Pontos

Neste conjunto de pontos, o panorama dos resultados para o matiz se altera para composição com cinco bandas. A tendência de se situarem abaixo do desempenho da composição com três bandas se confirma, exceto para o limiar de segmentação igual a 25, para o qual tem-se resultado bem superior aos demais limiares.

TABELA 5.4 - KAPPA ESTIMADO, SUA VARIÂNCIA AMOSTRAL E VALORES DE ESTÁTICA Z DE COMPOSIÇÕES TM453, TM4537 E TM45273

limiar	kappa			Var. kappa			Z		
	TM453	TM4537	TM45273	TM453	TM4537	TM45273	4 e 3	4 e 5	3 e 5
20	0,651	0,797	0,620	4,55E-03	2,97E-03	4,24E-03	1,690	2,085	0,326
25	0,681	0,810	0,766	4,24E-03	2,84E-03	3,65E-03	1,535	0,554	-0,952
30	0,687	0,824	0,628	3,89E-03	2,69E-03	3,90E-03	1,688	2,403	0,658
35	0,630	0,778	0,620	4,41E-03	3,04E-03	4,07E-03	1,720	1,875	0,105
40	0,643	0,734	0,579	5,21E-03	4,61E-03	4,07E-03	0,922	1,673	0,669

Ao analisar-se na Tabela 5.4, os valores estimados de kappa para cada matiz de composição utilizada, percebe-se que para quatro bandas (TM4537), em todos os limiares de segmentação os valores foram maiores que para três e cinco bandas. Para o teste bilateral, a um nível de significância de 10%, esta diferença foi significativa na maioria dos casos, que estão destacados em cinza na Tabela 5.4. Portanto, confirma-se aqui o que foi constatado na Seção anterior, de que o resultado com quatro bandas é superior ao de três e, como visto agora, ao de cinco bandas.

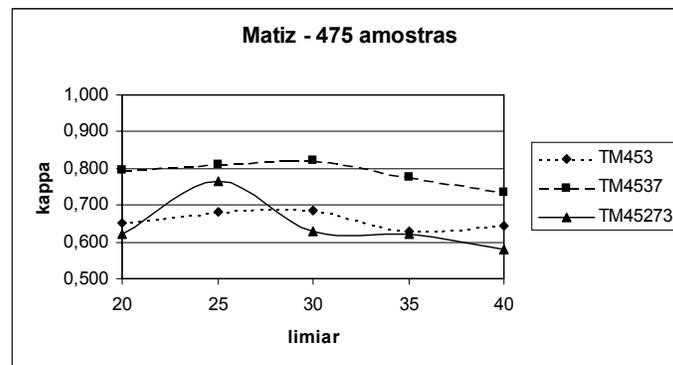


Fig. 5.31 - Valores de kappa para matiz de três, quatro e cinco bandas.

As matrizes de confusão novamente são úteis para compreender o comportamento das classificações para as diferentes composições. Na Figura 5.32, têm-se as matrizes de confusão da classificação por matiz a partir de composições com três, quatro e cinco bandas, e sob limiar de segmentação 30. Todas com baixo erro de omissão, a indicar boa identificação do alvo urbano. Porém, em duas classificações (TM453 e TM45273), o erro de inclusão foi mais elevado.

		Referência			inclusão
		Urb	N Urb	total	
Urb		27	19	46	41,3%
N Urb		3	426	429	0,7%
total		30	445	475	
omissão		10,0%	4,3%		

(a)

		Referência			inclusão
		Urb	N Urb	total	
Urb		28	9	37	24,3%
N Urb		2	436	438	0,5%
total		30	445	475	
omissão		6,7%	2,0%		

(b)

		Referência			inclusão
		Urb	N Urb	total	
Urb		28	27	55	49,1%
N Urb		2	418	420	0,5%
total		30	445	475	
omissão		6,7%	6,1%		

(c)

Fig. 5.32 - Matriz de confusão de classificação com limiar de segmentação 30, sobre:
 (a) matiz de composição TM453;
 (b) matiz de composição TM4537;
 (c) matiz de composição TM45273.

Este maior erro de inclusão para três bandas e cinco bandas, por sua vez, pode ser entendido ao se analisar a Tabela 5.5 e a Figura 5.33. Em branco aparece a classe urbano de referência (11777 pixels), e em vermelho estão as regiões as quais, para três bandas, foram classificadas como da classe urbano que não coincidem com a imagem referência. O mesmo vale para pixels destacados nas cores verde e azul, para quatro e cinco bandas, respectivamente.

TABELA 5.5 - NÚMERO DE PIXELS QUE NÃO COINCIDEM COM A REFERÊNCIA, NA CLASSIFICAÇÃO DE MATIZ COM LIMAR DE SEGMENTAÇÃO 30

imagem	cor	pontos
referência	branco	11.777
TM45273	azul	7.732
TM453	vermelho	4.500
TM4537	verde	4.199
TM453 e TM45273	magenta	2.520
TM4537 e TM45273	ciano	683
TM453 e TM45273	amarelo	304
todas	preto	995

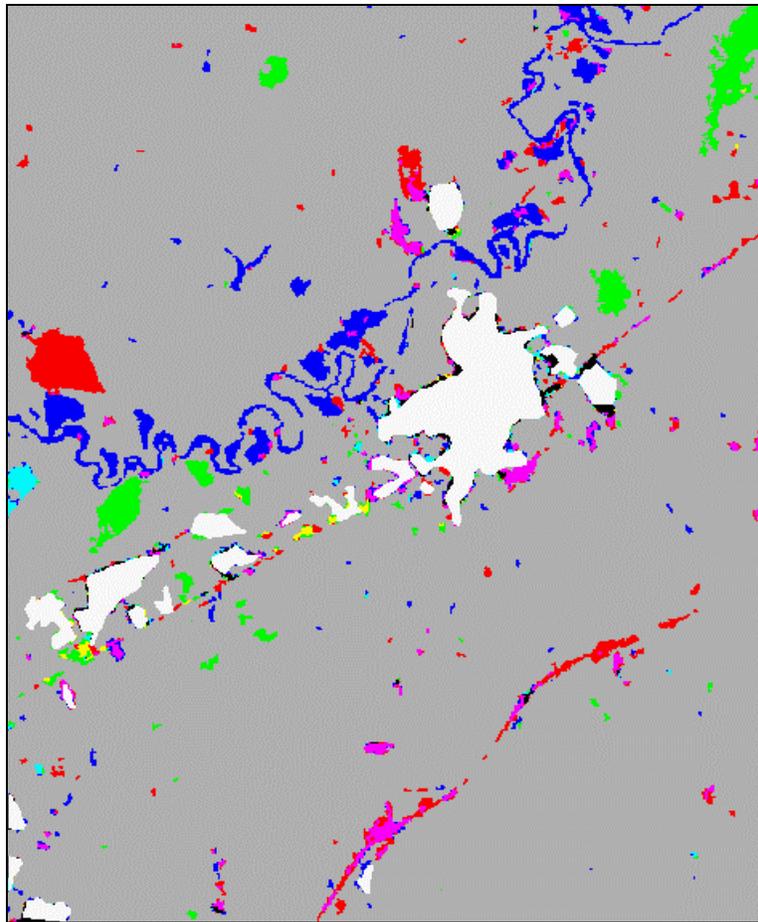


Fig. 5.33 - Regiões consideradas da classe urbano pela classificação por matiz, a limiar 30, que não coincidem com a referência.

A vantagem do resultado de matiz sobre Isoseg permanece. No entanto já não é tão predominante como antes, pois mais alguns resultados de Isoseg apresentam desempenho

de classificação superior, principalmente para cinco bandas. Se antes havia um único valor negativo de Z, agora há oito, sendo que um inclusive é significativamente superior a $\alpha=10\%$, destacado em preto na Tabela 5.7. Para três e quatro bandas, apesar de agora aparecer resultado de Iseseg superior, contraditoriamente houve um aumento no número de valores de Z que passam no teste de hipótese.0

TABELA 5.6 - VALORES ESTIMADOS DE KAPPA E SUAS VARIÂNCIAS; ISOSEG COM VÁRIOS LIMIARES DE ACEITAÇÃO E CLASSIFICAÇÃO DE MATIZ

bandas	limiar	kappa						Var kappa					
		99.9%	99.0%	95.0%	90.0%	75.0%	matiz	99.9%	99.0%	95.0%	90.0%	75.0%	matiz
345	20	0,371	0,316	0,517	0,460	0,621	0,651	6,67E-03	5,45E-03	6,37E-03	5,73E-03	6,08E-03	4,55E-03
	30	0,146	0,492	0,639	0,686	0,686	0,687	5,20E-03	3,99E-03	4,39E-03	5,46E-03	5,46E-03	3,89E-03
	40	0,465	0,463	0,499	0,559	0,661	0,643	3,50E-03	4,90E-03	5,66E-03	5,31E-03	5,89E-03	5,21E-03
3457	20	0,610	0,442	0,706	0,409	0,749	0,797	5,07E-03	7,97E-03	4,85E-03	8,70E-03	4,46E-03	2,97E-03
	30	0,405	0,458	0,595	0,635	0,663	0,824	3,42E-03	4,19E-03	6,45E-03	6,64E-03	6,16E-03	2,69E-03
	40	0,588	0,567	0,793	0,557	0,369	0,734	3,75E-03	3,72E-03	3,37E-03	4,61E-03	9,39E-03	4,61E-03
23457	20	0,550	0,326	0,663	0,747	0,757	0,620	5,29E-03	4,92E-03	4,70E-03	3,67E-03	4,19E-03	4,24E-03
	30	0,505	0,511	0,356	0,455	0,645	0,628	4,05E-03	4,92E-03	6,46E-03	6,37E-03	5,70E-03	3,90E-03
	40	0,496	0,526	0,641	0,512	0,765	0,579	4,85E-03	3,62E-03	4,78E-03	5,43E-03	3,95E-03	4,07E-03

TABELA 5.7 - COMPARATIVO ENTRE DESEMPENHOS DE CLASSIFICAÇÃO DE ISOSEG E MATIZ

bandas	limiar	Z				
		99,9%	99,0%	95,0%	90,0%	75,0%
345	20	2,638	3,344	1,279	1,877	0,291
	30	5,668	2,195	0,519	0,005	0,005
	40	1,910	1,793	1,385	0,815	-0,167
3457	20	2,089	3,400	1,028	3,594	0,555
	30	5,353	4,400	2,390	1,949	1,706
	40	1,597	1,840	-0,655	1,844	3,090
23457	20	0,715	3,069	-0,455	-1,426	-1,496
	30	1,390	1,246	2,675	1,709	-0,173
	40	0,872	0,595	-0,664	0,687	-2,083

Novamente na comparação com o matiz a limiar de segmentação 30, para todos os limiares de aceitação de Iseseg, os valores de Z indicam que os coeficientes kappa de Iseseg e de matiz são diferentes a um nível de significância (α) de 10%. Convém destacar também que, sob limiar de aceitação 99%, apenas dois resultados de matiz não seriam considerados superiores ao Iseseg, justamente resultados obtidos através de cinco bandas.

Isto se explica devido ao menor desempenho do método por matiz na composição TM45273, que pôde ser melhor aferido numa amostragem de tamanho maior a utilizada na Seção anterior. Enquanto as Figura 5.34 e 5.35 mostram ainda uma tendência favorável ao resultado de matiz, na Figura 5.36 o resultado de matiz já não se mostra tão superior a ponto de se afirmar o mesmo.

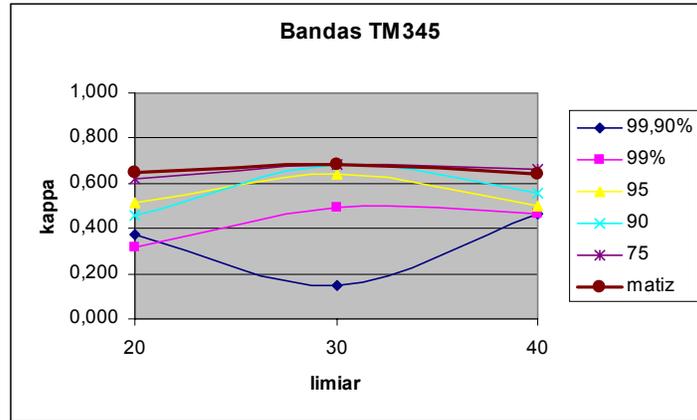


Fig. 5.34 - Comparação entre o método Iseseg, com diferentes limiares de aceitação, e o método de matiz para três bandas.

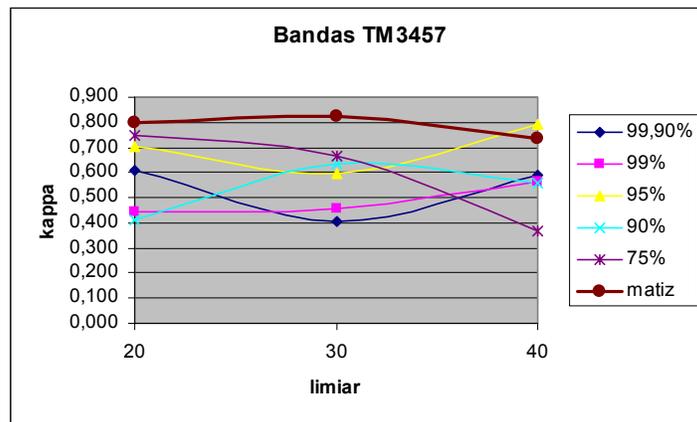


Fig. 5.35 - Comparação entre o método Iseseg, com diferentes limiares de aceitação, e o método de matiz para quatro bandas.

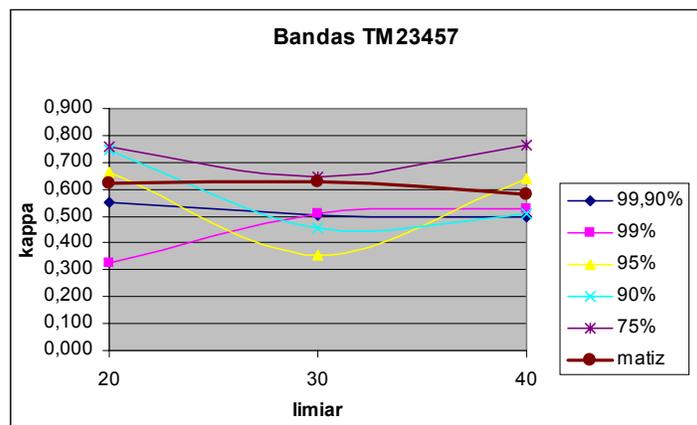


Fig. 5.36 - Comparação entre o método Iseseg, com diferentes limiares de aceitação, e o método de matiz para cinco bandas.

5.2.3. - Caçapava, 803 Pontos

Mantiveram-se aqui os bons resultados de matiz obtidos para quatro bandas, quando comparados com os de três, conforme se observa pelos valores da estatística na Tabela 5.8. Se acentuou a queda que ocorre no rendimento em cinco bandas, sendo este claramente, como visto na Figura 5.37, o de mais baixo desempenho.

TABELA 5.8 - KAPPA ESTIMADO E SUAS VARIÂNCIAS AMOSTRAIS

limiar	kappa			Var. kappa			Z		
	TM453	TM4537	TM45273	TM453	TM4537	TM45273	4 e 3	4 e 5	3 e 5
20	0,582	0,712	0,503	3,53E-03	2,86E-03	3,14E-03	1,626	2,705	0,974
25	0,604	0,704	0,646	3,31E-03	2,90E-03	3,47E-03	1,273	0,724	-0,517
30	0,605	0,743	0,535	3,20E-03	2,63E-03	3,13E-03	1,812	2,734	0,869
35	0,579	0,672	0,520	3,30E-03	2,92E-03	3,09E-03	1,184	1,958	0,731
40	0,575	0,675	0,479	4,20E-03	3,73E-03	3,06E-03	1,126	2,372	1,118

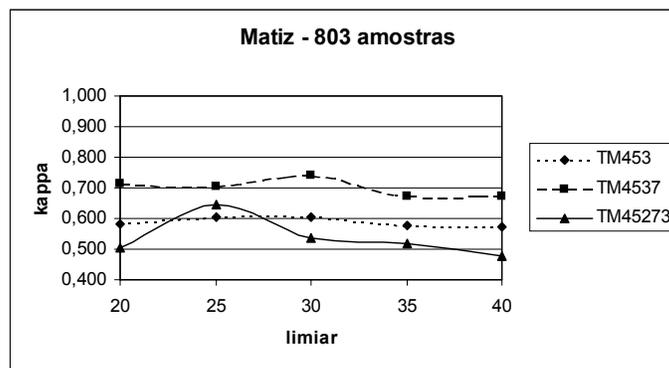


Fig. 5.37 - Valores de kappa para matiz de três, quatro e cinco bandas.

Através do elevado erro de inclusão na classe urbana, se explica o baixo desempenho do método de matiz no matiz da composição TM45273. De acordo com a matriz de confusão mostrada na Figura 5.38c, este erro é de 57%.

		Referência			inclusão
		Urb	N Urb	total	
Urb		34	33	67	49,3%
N Urb		7	729	736	1,0%
total		41	762	803	
omissão		17,1%	4,3%		

(a)

		Referência			inclusão
		Urb	N Urb	total	
Urb		36	18	54	33,3%
N Urb		5	744	749	0,7%
total		41	762	803	
omissão		12,2%	2,4%		

(b)

		Referência			inclusão
		Urb	N Urb	total	
Urb		34	45	79	57,0%
N Urb		7	717	724	1,0%
total		41	762	803	
omissão		17,1%	5,9%		

(c)

Fig. 5.38 - Matriz de confusão de classificação com limiar de segmentação 30, sobre:
 (a) matiz de composição TM453;
 (b) matiz de composição TM4537;
 (c) matiz de composição TM45273.

Como consequência, para cinco bandas, existe agora uma vantagem do Isoseg sobre o método por matiz. Observe os valores da estatística Z mostrados na Tabela 5.10, para cinco bandas nos limiares de similaridade 20 e 40, para os limiares de aceitação de 75%, 90% e 95%. Eles apontam para um desempenho significativamente superior (a um $\alpha=10\%$ e teste bilateral com $Z_{5\%}=1,645$) do método Isoseg em cinco casos, destacados em preto.

TABELA 5.9 - VALORES ESTIMADOS DE KAPPA E SUAS VARIÂNCIAS. ISOSEG COM VÁRIOS LIMIARES DE ACEITAÇÃO E CLASSIFICAÇÃO DE MATIZ

bandas	limiar	kappa						Var kappa					
		99.9%	99.0%	95.0%	90.0%	75.0%	matiz	99.9%	99.0%	95.0%	90.0%	75.0%	matiz
345	20	0,314	0,274	0,507	0,362	0,501	0,582	4,21E-03	3,48E-03	4,96E-03	4,13E-03	5,63E-03	3,53E-03
	30	0,127	0,386	0,545	0,632	0,641	0,605	2,88E-03	2,74E-03	3,48E-03	4,45E-03	4,42E-03	3,20E-03
	40	0,406	0,402	0,474	0,542	0,632	0,575	2,32E-03	3,34E-03	4,07E-03	4,00E-03	4,45E-03	4,20E-03
3457	20	0,523	0,405	0,613	0,424	0,612	0,712	4,27E-03	5,51E-03	4,49E-03	6,30E-03	4,85E-03	2,86E-03
	30	0,329	0,384	0,575	0,590	0,590	0,743	2,23E-03	2,84E-03	4,88E-03	5,28E-03	5,28E-03	2,63E-03
	40	0,496	0,476	0,672	0,504	0,396	0,675	2,73E-03	2,66E-03	3,51E-03	3,49E-03	6,72E-03	3,73E-03
23457	20	0,477	0,251	0,663	0,741	0,745	0,503	3,78E-03	2,56E-03	3,54E-03	2,80E-03	3,33E-03	3,14E-03
	30	0,442	0,470	0,405	0,412	0,593	0,535	2,78E-03	3,61E-03	4,75E-03	4,59E-03	4,88E-03	3,13E-03
	40	0,465	0,463	0,578	0,741	0,684	0,479	3,45E-03	2,52E-03	3,91E-03	2,80E-03	3,69E-03	3,06E-03

Para três e quatro bandas, por outro lado, a diferença favorável ao matiz em relação ao Isoseg aumentou na maioria das vezes. Isto é afirmado baseando-se principalmente no aumento do número de diferenças significativas, a nível de significância (α) igual a 10%. Na Tabela 5.10, contam-se vinte valores de estatística Z superiores ao valor $Z_{5\%}=1,645$, utilizado no teste bilateral.

TABELA 5.10 - COMPARATIVO ENTRE DESEMPENHOS DE CLASSIFICAÇÃO DE ISOSEG E MATIZ

bandas	limiar	Z				
		99,9%	99,0%	95,0%	90,0%	75,0%
345	20	3,050	3,677	0,813	2,524	0,849
	30	6,118	2,838	0,725	-0,312	-0,423
	40	2,095	1,989	1,113	0,363	-0,615
3457	20	2,246	3,355	1,154	3,014	1,141
	30	5,936	4,852	1,935	1,717	1,717
	40	2,224	2,494	0,036	2,016	2,731
23457	20	0,313	3,335	-1,966	-3,093	-3,013
	30	1,217	0,792	1,473	1,407	-0,646
	40	0,184	0,216	-1,181	-3,420	-2,493

Apesar disso, como pode ser observado na Figura 5.39, para três bandas, algumas curvas representando limiares de aceitação do Isoseg, situaram-se acima da curva do método de matiz, nos limiares 30 e 40. Já com quatro bandas, todas as curvas presentes no gráfico da Figura 5.40, se localizam abaixo da curva de valores estimados de kappa do método de matiz.

Na Figura 5.41, é mostrada a representação gráfica do que ocorre na comparação dos dois métodos para cinco bandas. Não há, de forma alguma, um método com desempenho melhor que o outro em todos os limiares. No entanto, para alguns intervalos de limiar de aceitação e de segmentação/similaridade, houve uma tendência favorável a um dos métodos. Tal como ocorreu nos limiares de segmentação/similaridade 40 e 30, para o Isoseg e matiz, respectivamente.

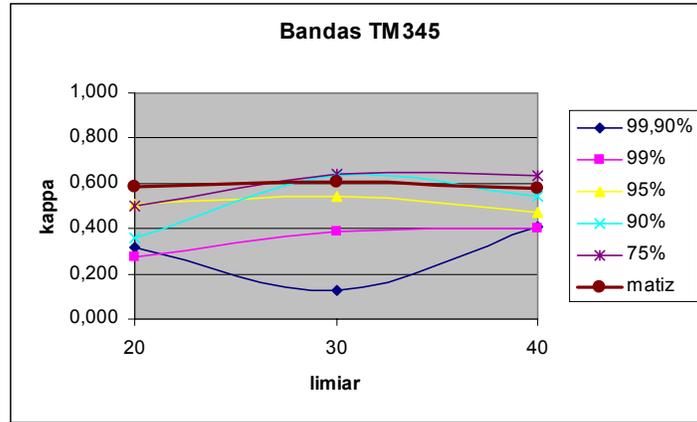


Fig. 5.39 - Comparação entre o método Iseeg, com diferentes limiares de aceitação, e o método de matiz para três bandas.

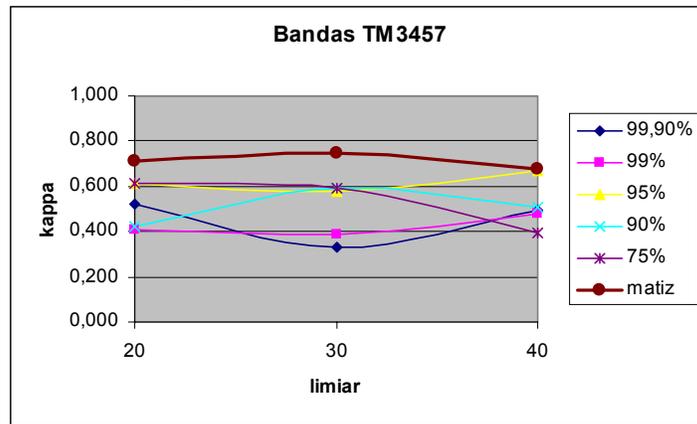


Fig. 5.40 - Comparação entre o método Iseeg, com diferentes limiares de aceitação, e o método de matiz para quatro bandas.

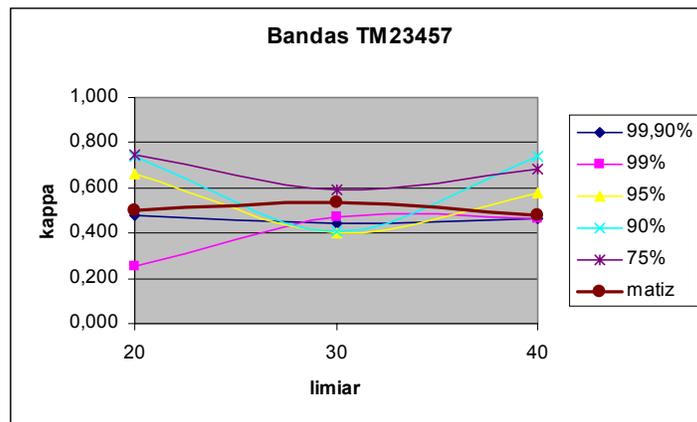


Fig. 5.41 - Comparação entre o método Iseeg, com diferentes limiares de aceitação, e o método de matiz para cinco bandas.

5.2.4. - Tremebé, 153 Pontos

Diferentemente do que ocorrera com a cena de Caçapava, não foi observada nenhuma superioridade de desempenho em quaisquer das composições analisadas. Há uma equivalência de resultados muito marcante, com ora o matiz de três bandas apresentando valor estimado de kappa superior, ora o matiz de quatro bandas e assim por diante. A Tabela 5.11, na coluna dos valores da estatística de Z, e a Figura 5.42, mostram bem este equilíbrio existente entre os resultados de classificação de matiz de composição com três, quatro e cinco bandas.

TABELA 5.11 - KAPPA, VARIÂNCIA DE KAPPA E Z PARA TRÊS, QUATRO E CINCO BANDAS

limiar	kappa			Var. kappa			Z		
	TM453	TM4537	TM45273	TM453	TM4537	TM45273	4 e 3	4 e 5	3 e 5
20	0,737	0,817	0,803	2,96E-03	2,18E-03	2,32E-03	1,105	0,197	-0,909
25	0,803	0,790	0,790	2,32E-03	2,45E-03	2,44E-03	-0,189	0,005	0,194
30	0,777	0,818	0,790	2,58E-03	2,08E-03	2,44E-03	0,601	0,416	-0,184
35	0,817	0,817	0,830	2,18E-03	2,17E-03	2,03E-03	0,002	-0,200	-0,203
40	0,817	0,766	0,817	2,16E-03	2,63E-03	2,16E-03	-0,743	-0,743	0,000

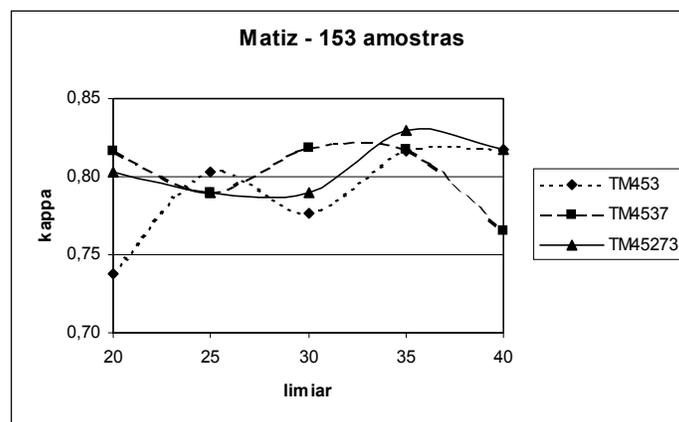


Fig. 5.42 - Valores de kappa para matiz de três, quatro e cinco bandas.

Estes resultados quando comparados com os obtidos pelo método Isoseg, se mostram bem melhores, possuindo valores estimados de kappa significativamente superiores. A níveis de significância (α) de 10% ($Z_{5\%}=1,645$) e 5% ($Z_{2,5\%}=1,920$), apenas em um caso, a limiar de similaridade igual a 30, a diferença não foi significativa para o teste bilateral. Até mesmo a

um $\alpha=2\%$ ($Z_{1\%}=2,325$), apenas em mais duas situações não foi possível afirmar que os kappa estimados eram diferentes (em branco na coluna de Z da Tabela 5.12).

TABELA 5.12 - COMPARATIVO ENTRE DESEMPENHOS DE CLASSIFICAÇÃO DE ISOSEG E MATIZ

bandas	limiar	kappa			Var. kappa			Z	
		99,9%	99,0%	matiz	99,9%	99,0%	matiz	99,9%	99,0%
345	20	0,277	0,304	0,737	2,99E-03	3,17E-03	2,96E-03	5,971	5,533
	30	0,467	0,467	0,777	3,75E-03	3,75E-03	2,58E-03	3,888	3,888
	40	0,535	0,589	0,817	3,73E-03	3,61E-03	2,16E-03	3,673	3,003
3457	20	0,562	0,495	0,817	3,69E-03	3,76E-03	2,18E-03	3,325	4,179
	30	0,508	0,481	0,818	3,76E-03	3,76E-03	2,08E-03	4,055	4,408
	40	0,602	0,589	0,766	3,57E-03	3,61E-03	2,63E-03	2,075	2,238
23457	20	0,427	0,372	0,803	3,69E-03	3,52E-03	2,32E-03	4,860	5,642
	30	0,763	0,427	0,790	2,61E-03	3,69E-03	2,44E-03	0,384	4,638
	40	0,562	0,454	0,817	3,78E-03	3,74E-03	2,16E-03	3,304	4,728

As Figuras 5.43, 5.44 e 5.45, ilustram bem este melhor desempenho de classificação do método por matiz com relação ao Isoseg. As comparações realizadas entre matiz e o método Isoseg, se limitaram aos limiares de aceitação 99,9% e 99%, devido ao número excessivo de classes que se obtém com outros percentuais na região de floresta.

Este número excessivo de classes, torna praticamente inviável a escolha de uma única classe que represente o alvo floresta, havendo a necessidade de um mapeamento das classes presentes na região de floresta. No entanto, um mapeamento retiraria parte da natureza não-supervisionada do resultado de classificação por Isoseg.

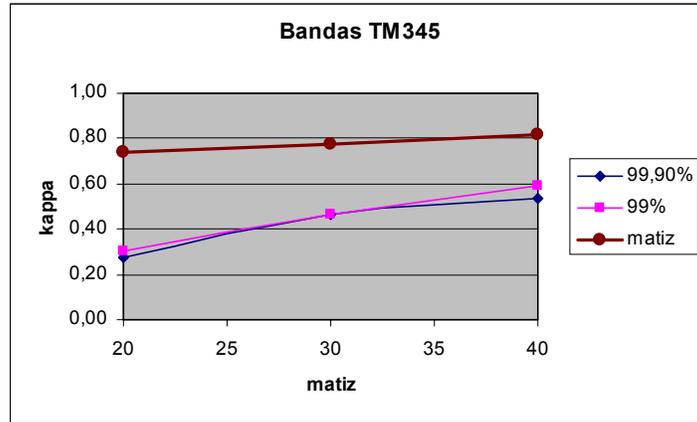


Fig. 5.43 - Comparação entre o método Iseseg, com limiares de aceitação 99,9% e 99%, e o método de matiz para três bandas.

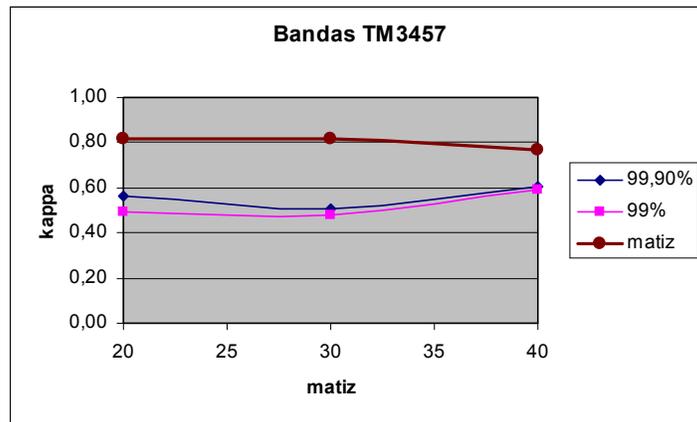


Fig. 5.44 - Comparação entre o método Iseseg, com limiares de aceitação 99,9% e 99%, e o método de matiz para quatro bandas.

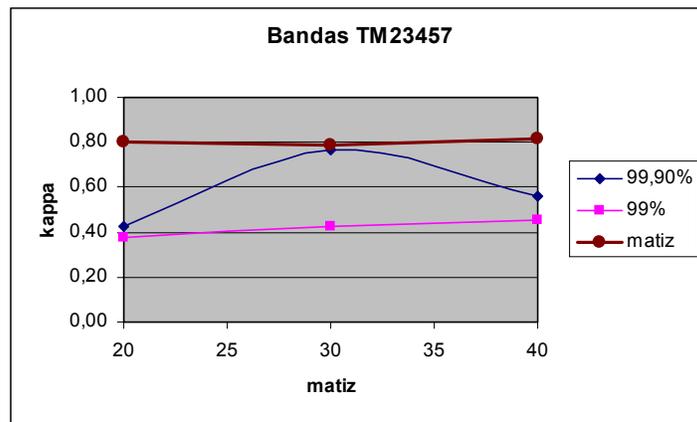


Fig. 5.45 - Comparação entre o método Iseseg, com limiares de aceitação 99,9% e 99%, e o método de matiz para cinco bandas.

5.2.5. - Tremembé, 231 Pontos.

Originalmente, o principal motivo de se utilizar estes 231 pontos (e os outros 528 pontos), foi o de verificar se as diferenças entre os coeficientes kappas das três composições seriam significativas ou não. Entretanto, para 153 pontos foi verificado um equilíbrio entre os desempenhos de classificação no matiz de composição feita com três, quatro e cinco bandas.

Logo, para um conjunto de pontos de referência menos rigoroso, uma classificação de matiz a partir de três bandas pode ser mais próxima a interpretação dada a este conjunto de pontos, que a obtida com quatro ou cinco bandas e vice-versa. E é isso que será visto nesta e na Seção seguinte.

Os 231 pontos de referência são menos rigorosos na exatidão não por terem sido interpretados com menos minúcia ou cuidado. Possuem exatidão menor, simplesmente por que estes são consequência da coincidência de interpretação de dois intérpretes ao invés de três, como no caso dos 153 pontos da Seção anterior.

TABELA 5.13 - KAPPA, VARIÂNCIA DE KAPPA E Z PARA TRÊS, QUATRO E CINCO BANDAS

limiar	kappa			Var. kappa			Z		
	TM453	TM4537	TM45273	TM453	TM4537	TM45273	4 e 3	4 e 5	3 e 5
20	0,660	0,800	0,722	2,38E-03	1,56E-03	2,06E-03	2,236	1,307	-0,926
25	0,748	0,783	0,713	1,88E-03	1,67E-03	2,09E-03	0,594	1,147	0,555
30	0,730	0,766	0,721	2,00E-03	1,79E-03	2,04E-03	0,579	0,721	0,140
35	0,766	0,792	0,783	1,79E-03	1,61E-03	1,68E-03	0,453	0,158	-0,295
40	0,783	0,749	0,757	1,67E-03	1,88E-03	1,85E-03	-0,569	-0,128	0,439

Pode-se dizer, a partir dos dados contidos na Tabela 5.13 e do gráfico da Figura 5.46, que entre os limiares 20 a 35, há uma tendência de a classificação sobre o matiz da composição de quatro bandas ter valor de kappa superior aos das demais classificações. O mesmo comportamento não é observado no limiar 40. Para três e cinco bandas, a condição de melhor classificação oscila entre uma e outra dependendo do limiar. Portanto, aqui persiste o equilíbrio observado anteriormente.

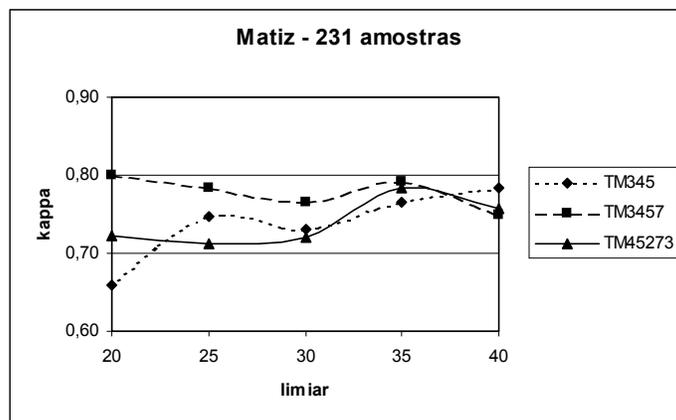


Fig. 5.46 - Valores de kappa para matiz de três, quatro e cinco bandas.

Estes dados quando comparados com o Isoseg, apresentam resultado muito semelhante ao já obtido com 153 pontos, havendo uma clara superioridade do matiz. A um nível de significância de 2% ($Z_{1\%}=2,325$), apenas uma diferença não foi significativa, enquanto que as restantes (em cinza na Tabela 5.14) foram consideradas significativas com certa folga.

TABELA 5.14 - COMPARATIVO ENTRE DESEMPENHOS DE CLASSIFICAÇÃO DE ISOSEG E MATIZ

bandas	limiar	kappa			Var. kappa			Z	
		99,9%	99,0%	matiz	99,9%	99,0%	matiz	99,9%	99,0%
345	20	0,201	0,274	0,660	1,57E-03	1,96E-03	2,38E-03	7,309	5,867
	30	0,409	0,382	0,730	2,48E-03	2,43E-03	2,00E-03	4,797	5,230
	40	0,481	0,445	0,783	2,54E-03	2,59E-03	1,67E-03	4,655	5,173
3457	20	0,454	0,409	0,800	2,59E-03	2,48E-03	1,56E-03	5,371	6,155
	30	0,490	0,481	0,766	2,60E-03	2,54E-03	1,79E-03	4,163	4,329
	40	0,553	0,499	0,749	2,62E-03	2,59E-03	1,88E-03	2,930	3,744
23457	20	0,373	0,319	0,722	2,33E-03	2,15E-03	2,06E-03	5,266	6,207
	30	0,650	0,445	0,721	2,28E-03	2,46E-03	2,04E-03	1,085	4,122
	40	0,482	0,418	0,757	2,75E-03	2,50E-03	1,85E-03	4,056	5,143

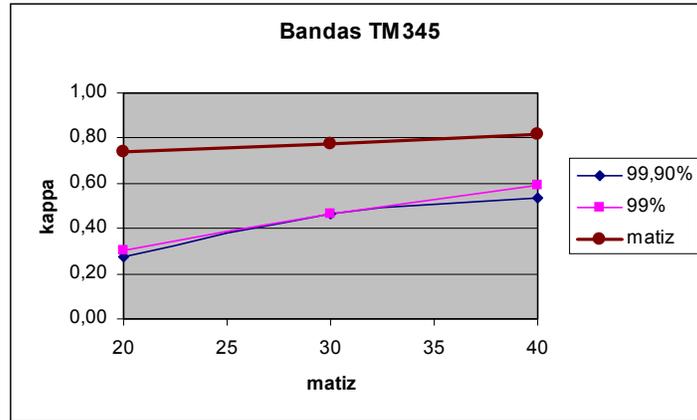


Fig. 5.47 - Comparação entre o método Iseseg, com limiares de aceitação 99,9% e 99%, e o método de matiz para três bandas.

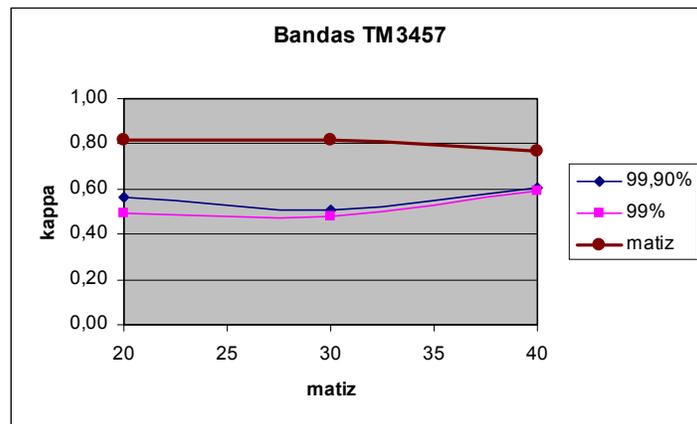


Fig. 5.48 - Comparação entre o método Iseseg, com limiares de aceitação 99,9% e 99%, e o método de matiz para quatro bandas.

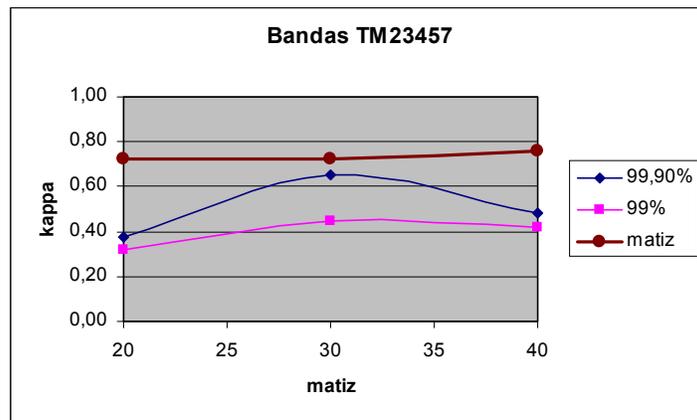


Fig. 5.49 - Comparação entre o método Iseseg, com limiares de aceitação 99,9% e 99%, e o método de matiz para cinco bandas.

5.2.6. - Tremembé, 528 Pontos.

Os 528 pontos de referência foram obtidos a partir de um intérprete somente, e sobre um outro conjunto aleatório de amostras diferente dos dois casos anteriores. Para esta situação, o matiz a partir de três bandas obteve valores estimados de kappa superiores aos das outras composições em quase todos os limiares, exceto no limiar 20. Resultado diferente do visto para 231 pontos, portanto.

Outra alteração percebida, foi o fato de que o desempenho com cinco bandas se manteve superior ao de quatro, o de mais fraco desempenho, em todos os limiares de segmentação. Justamente com quatro bandas foi que, com 231 pontos, a classificação obteve os melhores resultado na maior parte das vezes.

TABELA 5.15 - KAPPA, VARIÂNCIA DE KAPPA E Z PARA TRÊS, QUATRO E CINCO BANDAS

limiar	kappa			Var. kappa			Z		
	TM453	TM4537	TM45273	TM453	TM4537	TM45273	4 e 3	4 e 5	3 e 5
20	0,694	0,685	0,726	1,07E-03	1,01E-03	9,72E-04	-0,202	-0,909	-0,691
25	0,741	0,664	0,700	9,32E-04	1,05E-03	1,05E-03	-1,725	-0,795	0,908
30	0,731	0,636	0,680	9,46E-04	1,06E-03	1,10E-03	-2,129	-0,950	1,130
35	0,713	0,620	0,639	9,69E-04	1,11E-03	1,15E-03	-2,037	-0,402	1,601
40	0,701	0,568	0,626	9,72E-04	1,10E-03	1,14E-03	-2,919	-1,221	1,637

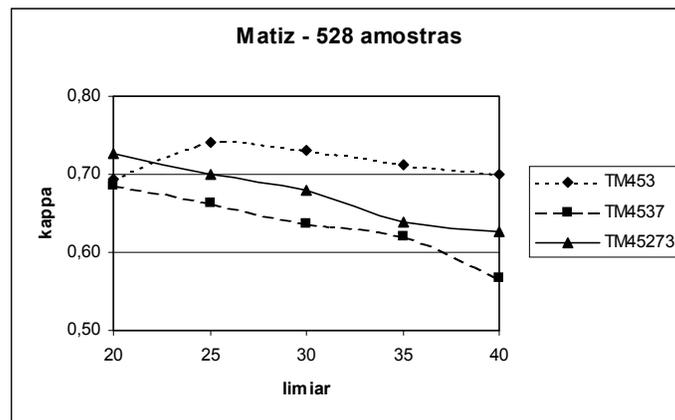


Fig. 5.50 - Valores de kappa para matiz de três, quatro e cinco bandas.

A superioridade com relação ao Iseseg permanece bem nítida, havendo apenas um resultado onde a diferença dos kappas estimados não foi significativa a $\alpha=2\%$ ($Z_{1\%}=2,235$), a limiar de segmentação/similaridade 40 com quatro bandas. As curvas dos valores dos kappas estimados presentes na Tabela 5.16 para três, quatro e cinco bandas são mostradas nas Figura 5.51, 5.52 e 5.53 respectivamente.

TABELA 5.16 - COMPARAÇÃO ENTRE DESEMPENHOS DE CLASSIFICAÇÃO DE ISESEG E MATIZ

bandas	limiar	kappa			Var. kappa			Z	
		99,9%	99,0%	matiz	99,9%	99,0%	matiz	99,9%	99,0%
345	20	0,188	0,345	0,694	1,13E-03	1,46E-03	1,07E-03	10,780	6,944
	30	0,409	0,424	0,731	1,66E-03	1,60E-03	9,46E-04	6,311	6,108
	40	0,472	0,435	0,701	1,63E-03	1,68E-03	9,72E-04	4,492	5,171
3457	20	0,412	0,360	0,685	1,69E-03	1,62E-03	1,01E-03	5,256	6,350
	30	0,393	0,443	0,636	1,74E-03	1,64E-03	1,06E-03	4,595	3,706
	40	0,398	0,556	0,568	1,77E-03	1,46E-03	1,10E-03	3,169	0,241
23457	20	0,415	0,379	0,726	1,58E-03	1,53E-03	9,72E-04	6,158	6,923
	30	0,539	0,458	0,680	1,51E-03	1,53E-03	1,10E-03	2,755	4,327
	40	0,390	0,422	0,626	1,78E-03	1,64E-03	1,14E-03	4,359	3,861

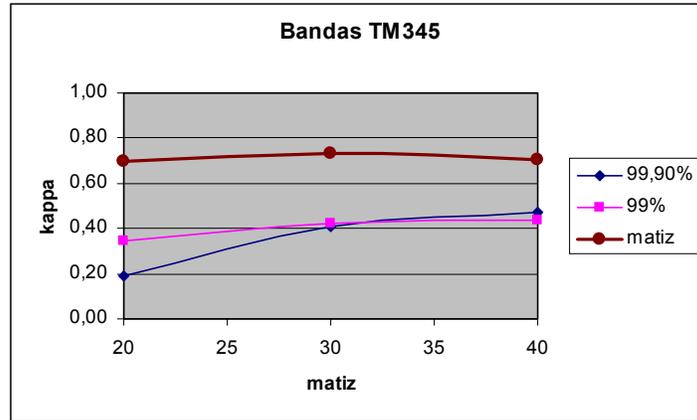


Fig. 5.51 - Comparação entre o método Iseseg, com limiares de aceitação 99,9% e 99%, e o método de matiz para três bandas.

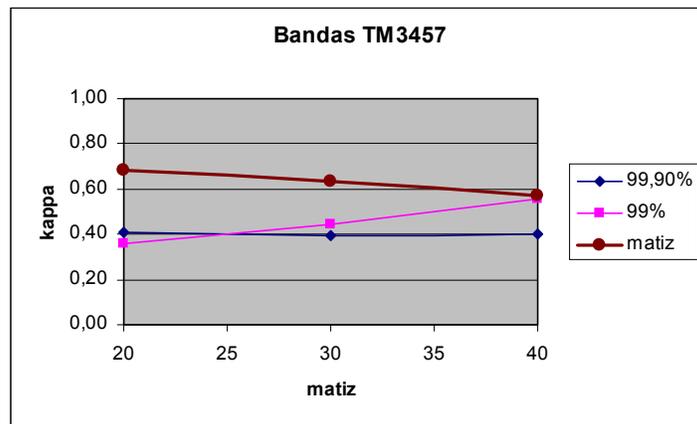


Fig. 5.52 - Comparação entre o método Iseseg, com limiares de aceitação 99,9% e 99%, e o método de matiz para quatro bandas.

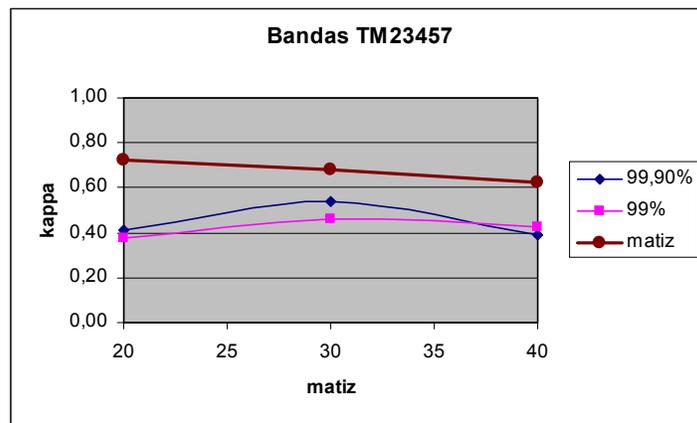


Fig. 5.53 Comparação entre o método Iseseg, com limiares de aceitação 99,9% e 99%, e o método de matiz para cinco bandas.

CAPÍTULO 6

CONCLUSÕES E SUGESTÕES

Os objetivos propostos neste trabalho de dissertação puderam ser atingidos, pois um algoritmo de obtenção de matiz através de N bandas foi implementado. A partir disso, foram gerados diversos resultados de classificação não-supervisionada, via segmentação, que apresentaram alguns resultados satisfatórios para o que se propunham. Com base nas experiências acumuladas durante a elaboração desta dissertação, e das observações feitas sobre todo o processo de trabalho com dados de matiz, foi elaborada uma relação de conclusões e de sugestões, com o intuito de aprimorar a técnica utilizada e visando uma maior utilização da mesma entre a comunidade acadêmica.

6.1. - Conclusões

1. Com relação às composições e ao número de bandas espectrais utilizadas na formação da imagem de matiz, algumas considerações podem ser levantadas:
 - a) Não há diferença no resultado de segmentação entre diferentes composições ao utilizar-se o mesmo conjunto de bandas. Por exemplo, o resultado da segmentação sobre o matiz da composição TM345 é igual ao resultado sobre o matiz de TM453 e de TM543. O que irá diferenciar o resultado de segmentação sobre o matiz, obtido através de uma composição com N bandas, é quais são estas N bandas e não a ordem em que estão;
 - b) O acréscimo de bandas à composição colorida não é garantia de uma melhor separabilidade entre os alvos analisados. Em pelo menos duas situações estudadas, uma em Caçapava e outra em Tremembé, o incremento de mais uma banda não trouxe benefício algum. Em Caçapava, a composição utilizada com cinco bandas apresentou desempenho de classificação inferior ao de quatro e três bandas. No caso de Tremembé, as composições com três, quatro e cinco bandas tiveram desempenhos similares;
 - c) No caso particular de Caçapava, o matiz da composição TM4537 apresentou uma separabilidade do alvo urbano superior ao matiz da composição TM453;

2. O valor médio de matiz da imagem foi preservado em todas as etapas de processamento, observado nas imagens de segmentação, filtrada e agrupada obtidas, sendo seus respectivos valores médios praticamente iguais. As diferenças existentes situam-se após a segunda casa decimal, e são consequência de possíveis erros de arredondamento e/ou truncamento feitos durante o processamento das imagens. Isto evidencia a consistência do método de cálculo de valor médio de matiz utilizado.
3. O matiz de modo geral se comportou muito bem sobre as regiões onde havia diferença de luminosidade. Isto ocorreu devido a característica do matiz de levar em consideração a cor predominante da composição colorida no pixel. Entretanto, em regiões onde a luminosidade foi excessivamente baixa, o valor de matiz tornou-se instável, recebendo valores sem qualquer significado com o contexto da cena.

A alternativa encontrada para contornar este obstáculo, foi ignorar os pixels com baixa luminosidade e saturação e separá-los numa única classe. Apesar de paliativa, esta solução mostrou-se adequada, principalmente ao comparar-se com o resultado do método Isoseg. Enquanto este superestimou a área da classe sombra, o método por matiz conseguiu resolver algumas regiões de floresta onde havia uma região de sombra ao redor.

4. Tanto em Caçapava quanto em Tremembé, para cada classificação de matiz com três, quatro ou cinco bandas, na comparação com o respectivo resultado de Isoseg, a vantagem com relação a este foi quase sempre acentuada.

6.2. - Sugestões

- 1) Pode-se em trabalhos futuros, utilizar-se um procedimento automático da escolha das bandas espectrais que formam as composições coloridas. Como critério, levaria-se em conta, por exemplo, a correlação existente entre as bandas. O processo de escolha das bandas e composição utilizada, teve como principal critério a separabilidade percebida

visualmente dos alvos de interesse. Acredita-se que automatizando este processo, serão geradas imagens de matiz com melhor separabilidade e mais adequadas para o procedimento de segmentação.

A aplicação de um método que automatizasse a escolha da melhor composição para um conjunto de N bandas espectrais, pode trazer alguns benefícios:

- a) Eliminação do componente subjetivo da escolha pessoal da composição;
 - b) Agilizaria o processo de escolha, possibilitando que um número maior de bandas seja utilizado, sem demandar muito tempo na escolha da melhor composição colorida;
 - c) Identificação de um número maior de alvos e até mesmo de diferentes categorias de um mesmo alvo. Por exemplo, poder-se-ia separar na classificação os tipos de floresta primária e secundária presentes na imagem de Tremembé.
- 2) Estudar e desenvolver algoritmos que consigam extrair informação coerente de matiz, mesmo em regiões de muito baixa luminosidade e/ou saturação, ao invés de simplesmente deixá-las em separado. Uma alternativa poderia ser o uso da informação de intensidade no processo de segmentação nestas regiões.
 - 3) Intensificar os testes, realizando classificações variando-se o tamanho mínimo de regiões, os limiares de agrupamento e de tamanho mínimo de classe.
 - 4) Realizar comparações estatísticas, utilizando coeficiente kappa, entre diferentes imagens classificadas de matiz. Se teria uma noção do quão diferentes são os resultados de classificação em função do o número de bandas.
 - 5) Trabalhar com dados hiperespectrais, ou seja, um número N de bandas ainda maior.
 - 6) Trabalhar com dados de diferença de fase, originados de radar.

REFERÊNCIAS BIBLIOGRÁFICAS

- Bishop, Y. M. M.; Fienberg, S. E.; Holland, P.W. **Discrete multivariate analysis: theory and practice**. Cambridge, MA: MIT Press, 1975. 528p.
- Bruton, D. **Color Science**. [online].<<http://www.physics.sfasu.edu/astro/color.html>> Jun. 2000.
- Cohen, J. A coefficient of agreement for nominal scales. **Educational and psychological measurement**, v.20, n.1, p.37-46, 1960.
- Congalton, R. G.; Mead, R. A. A quantitative method to test for consistency and correctness In: Photointerpretation. **Photogrametric Engineering and Remote Sensing**, v.49, n.1, p.69-74, Fev. 1983.
- Crevier, D. Hue-based segmentation of color images. [CD ROM]. In: Canadian Conference on Electrical and Computer Engineering, 1993. **Anais**. New York, NY: IEEE, 1993. v.2, p.1250-1253.
- Fleiss J.L.; Cohen J., Everitt B.S. Large sample standard errors of kappa and weighted kappa. **Psychological Bulletin**, v.72, n.5, p.323, 1969.
- Foley, J. D.; Van Dam, A.; Feiner, S.K.; Hughes, J. F. **Computer graphics: principles and practice**. Reading, MA: Addison-Wesley, 1990. 1176p.
- Gardner, J. L. **Programa PCCOLOUR Versão 2.1, gerador de diagramas de cromaticidade**. Lindfield, Australia : CSIRO National Measurement Laboratory 1997.
- Ginevan, M. E. Testing land-use map accuracy: another look. **Photogrametric Engineering and Remote Sensing**, v.45, n.10, p.1371-1377, Oct. 1979.
- Gonzalez, R. C.; Woods, R. E. **Digital image processing**. Reading, MA: Addison-Wesley, 1992. 716p.
- Harris, R. **Satellite Remote Sensing: an Introduction**. London: Routledge & Kegan Paul, 1987. 220p.
- Harrison, B. A.; Jupp, D.L.B. **Introduction to remotely sensed data**. Canberra, Australia: CSIRO Publications, 1989. 148p.
- Hudson, W. D.; Ramm C. W. Correct formulation of the kappa coefficient of agreement. **Photogrametric Engineering and Remote Sensing**, v. 53, n. 4, p. 421-422, Abr. 1987.

- MacAdam, D. L. Visual Sensitivities to Color Differences in Daylight. **Journal of Optical Society of America**, v.32, n.5, p.247-273, May, 1942.
- Marshall, T. G. **YARC color tutorial**. [online]. <[http:// www.yarc.com/colortut.htm](http://www.yarc.com/colortut.htm)> 1996.
- Moik, J. **Digital processing of remotely sensed images**. Washington: NASA, 1980. 330p.
- Novo, E. M. L. de M. **Sensoriamento remoto: princípios e aplicações**. São Paulo: Editora Edgard Blücher, 1989. 308p.
- Pitas, I. **Digital image processing algorithms**. Londres: Prentice Hall, 1995. 362p.
- Pratt, W. K. **Digital image processing**. Mountain View, California: John Wiley & Sons, 1991. 698p.
- Richards, J. A. **Remote sensing digital image analysis: an introduction**. Berlin: Springer-Verlag, 1986. 340p.
- Simi Jr., R. Técnicas de sensoriamento remoto e geoprocessamento aplicadas ao Monitoramento de áreas impactadas pela exploração mineral. [CD-ROM]. In: Simposio latinoamericano SELPER, 8. , Mérida, Venezuela, 1997. **Anais**.
- Silva, D. A. **Segmentacao de imagens multiespectrais baseada na componente matiz da transformação HSV**. São José dos Campos. 137p. (INPE-7255-TDI/698). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, 1997.
- Tajima, J. Uniform color scale applications to computer graphics. **Computer Vision Graphics, and Image Processing**, v.21, n.3, p.305-325, Abr. 1983.
- Trivedi, K. S. **Probability and statistics with reliability, queuing, and computer Science Applications**. Englewood Cliffs: Prentice Hall, 1982. 624p.
- Tseng, D.; Chang, C. Color segmentation using perceptual attributes. [CD ROM]. In: Conference on Image, Speech and Signal Analysis, 11., The Hague, Netherlands, 1992. **Anais**. Los Alamitos, CA: IEEE Computer Society Press, 1992, p.228-231.
- Tseng, D.; Li, Y.; Tung, C. Circular Histogram thresholding for color image segmentation. [CD ROM]. In: International Conference on Documentation Analysis and Recognition, 3., Montréal, 1995. **Anais**. Los Alamitos, CA, EUA: IEEE Computer Society Press, 1995, v.2, p.673-676.

Valeriano, D. M. **Processamento digital de dados do MSS-LANDSAT aplicado ao mapeamento da cobertura da terra da planície costeira do rio Tubarão, SC:** metodologia e estimativa de exatidão de classificação. São José dos Campos. 87p. (INPE-3455-TDL/188). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, 1985.

Van Genderen, J. L.; Lock, B. F.; Vass, P. A. Remote Sensing: Statistical testing of thematic map accuracy. **Remote Sensing of Environment**, v.7, n.1, p.3-14, 1978.

APÊNDICE A

ALGORITMOS DE CONVERSÃO ENTRE ESPAÇO DE CORES

Adaptação do algoritmo de conversão de RGB para HSV, descrito por Foley et. al (1990):

```
Procedimento RGB_para_HSV (r, g, b: real; h, s, v: real)
início
  max = maximo(r,g,b)
  min = minimo(r,g,b)
  v = max
  se (max não_igual 0) então
    s = (max-min)/max
  senão s = 0 [ocorre quando r=b=g]
se (s igual 0) então
  h = indefinido
senão
  início bloco
    delta = max - min
    se (r igual max) então
      h = (g - b)/delta
    senão se (g igual max) então
      h = 2 + (b - r)/delta
    senão se (b igual max) então
      h = 4+ (r - g)/delta
    h = h * 60
    se (h menor_que 0) então
      h = h + 360
  fim bloco
fim
```

Adaptação do algoritmo de conversão de HSV para RGB, descrito por Foley et. Al (1990):

Procedimento HSV_para_RGB (r, g, b: **real**; h, s, v: **real**)

```
início
  se (s igual 0) então
    se (h igual indefinido) então
      início bloco
        r = v
        g = v
        b = v
      fim bloco
    senão ERRO
  senão
    início bloco
      se (h igual 360) então
        h = 0
      h = h/60
      i = floor(h) maior inteiro <= h
      f = h - i
      p = v*(1 - s)
      q = v*(1 - s*f)
      t = v*(1 - s*(1 - f))
      caso i seja
        0: (r,g,b) = (v,t,p)
        1: (r,g,b) = (q,v,p)
        2: (r,g,b) = (p,v,t)
        3: (r,g,b) = (p,q,v)
        4: (r,g,b) = (t,p,v)
        5: (r,g,b) = (v,p,q)
      fim caso
    fim bloco
fim
```

APÊNDICE B

INTERFACE GRÁFICA

O desenvolvimento de uma interface gráfica teve por finalidade facilitar a utilização dos programas de segmentação/classificação, de avaliação estatística e de visualização. A execução de programas por linha de comando, até a sua completa familiarização pelo usuário, por vezes torna-se uma tarefa pouco produtiva.

Através de comandos acessados via menus e submenus, o aprendizado torna-se menos demorado e a execução dos programas mais intuitiva. A interface gráfica desenvolvida consiste de um menu principal simples (Figura B.1), contendo três submenus que acessam os programas de visualização, de processamento das imagens e de avaliação estatística do resultado de classificação.



Fig. B.1 - Menu principal do programa.

A.1. - Visualização e processamento

No menu Arquivo, por meio do submenu Abrir, é possível abrir imagens para visualizar composições coloridas, imagens de fase (valores angulares de 0 a 360), imagens de classificação exportadas no formato TIFF. Estas três opções são vistas na Figura B.2.



Fig. B.2 - Opções de abertura de cenas no submenu Abrir.

A opção *imagem* permite que sejam abertas e visualizadas composições coloridas a partir de três bandas espectrais ou mais. Assim que a opção é selecionada, abre-se uma caixa de diálogo (Figura B.3), onde os parâmetros de entrada do programa de abertura das bandas espectrais são ser definidos pelo usuário.



Fig. B.3 - Caixa de diálogo para definir parâmetros de entrada para abertura de composição colorida.

Neste exemplo, cinco bandas no formato TIFF são escolhidas. A seqüência pela qual se abrem as bandas irá determinar como será a composição colorida. As cinco bandas espectrais abertas são, na ordem, TM4, TM5, TM2, TM7 e TM3. Deste modo, a composição colorida obtida é a TM45273 (Figura B.4a). Automaticamente, o matiz desta composição é gerado, sendo visualizado tal como é mostrado na Figura B.4b. Nesta nova janela, no canto esquerdo inferior está localizada uma caixa de texto, que contém o valor médio de matiz da imagem inteira.

É possível agora rodar o programa de segmentação da imagem de matiz, bastando acessar a opção *Cresc. Regioes* do menu *Processamento*, que executará o método de crescimento de regiões sobre a imagem presente na janela *Fase*, que necessariamente deve ser a janela ativa. Conforme visto na Figura B.5, somente a opção de chamada do programa que executa o crescimento de regiões está habilitada, visto que existe uma imagem de matiz ativa.

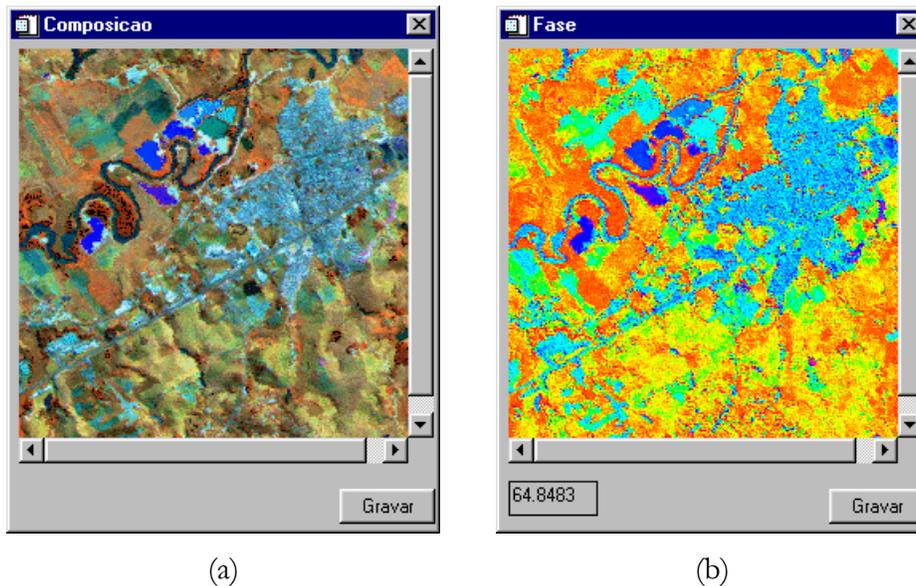


Fig. B.4 - Janelas de visualização de imagem:
 (a) Composição colorida TM45273;
 (b) Matiz da composição colorida.

Para que a opção de filtragem de regiões também fique habilitada, é necessário que uma imagem segmentada esteja aberta e sua respectiva janela de visualização ativa. A abertura desta imagem, como de qualquer outro resultado de processamento realizado, é feita através do submenu *Processadas* presente no menu *Arquivo*, como pode ser visto na Figura B.6.



Fig. B.5 - Menu de chamada do programa de crescimento de regiões.



Fig. B.6 - Menu para abertura dos resultados de processamentos.

Uma caixa de diálogo com parâmetros de segmentação a serem utilizados é apresentada, para que o usuário os defina (Figura B.7). Há uma lista de limiares de segmentação, onde se é permitido escolher valores entre 10 e 100, com intervalos de 5 entre um e outro.

Em outra opção da caixa de diálogo, o usuário escolhe se os pixels com baixos valores de brilho e saturação serão considerados à parte (Sim) ou serão segmentados junto aos demais (Não). Por fim, uma caixa de texto está disponibilizada para definir o nome principal do arquivo que armazenará o resultado da segmentação. O nome escolhido, conforme pode ser visto à Figura B.7, foi “cac45273”. Este nome refere-se ao local da cena (Caçapava) e a composição colorida que originou a imagem de matiz (TM45273).

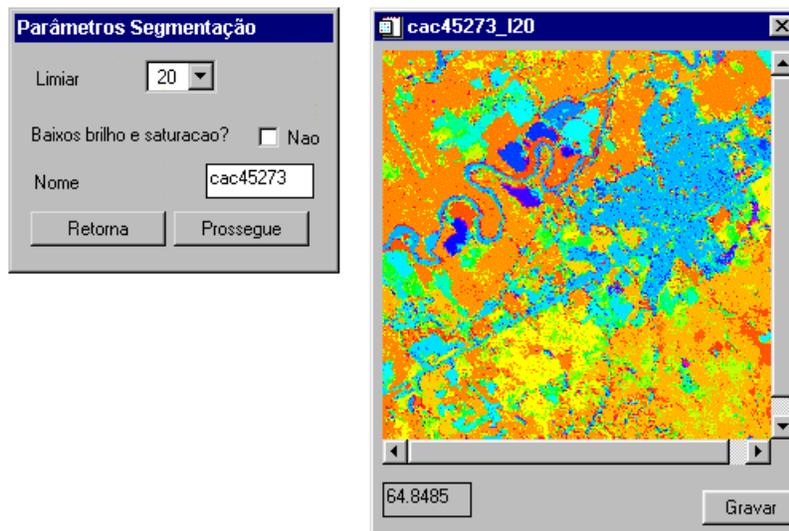


Fig. B.7 - Caixa de diálogo de definição dos parâmetros de segmentação e o respectivo resultado deste processamento.

Também na Figura B.7, ao lado da caixa de diálogo é mostrada janela com a imagem segmentada de matiz, aberta após o processamento. O título da janela “cac45273_l20”, diz respeito ao nome do arquivo de saída gerado na segmentação ao se utilizar limiar 20. Ao nome dado pelo usuário, foi acrescentado o sufixo “_l20”.

Para filtrar as regiões pequenas da imagem segmentada, segue-se procedimento semelhante, acessando a opção **Filtra Regioes** no menu **Processamento**. Abre-se então caixa de diálogo igual a mostrada na Figura B.8, para escolher-se o tamanho máximo de região que será filtrado. O resultado desta filtragem se vê na janela de visualização, cujo o título “cac45273_l20_p4”, informa o valor do parâmetro de filtragem utilizado.

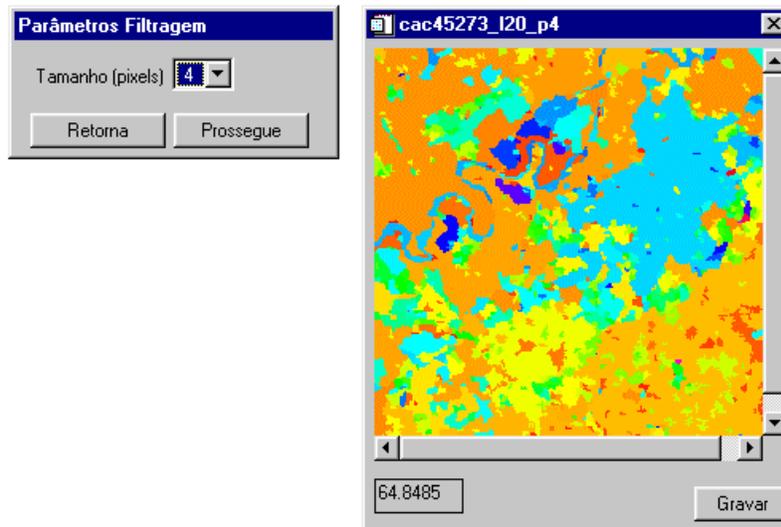


Fig. B.8 - Caixa de diálogo de definição dos parâmetros de filtragem de pequenas regiões e o respectivo resultado deste processamento.

A última etapa da classificação é o agrupamento das regiões, que é feito acessando a opção **Agrupar Regioes** no menu **Processamento**. Define-se nesta etapa os parâmetros de limiar de agrupamento e tamanho percentual mínimo das classes, numa caixa de diálogo como a mostrada na Figura B.9. Ao término deste processamento, é gerado o arquivo “cac45273_l20_p4_r10_perc100.dat”, que armazena o resultado final da classificação e qual pode ser aberto e visualizado.

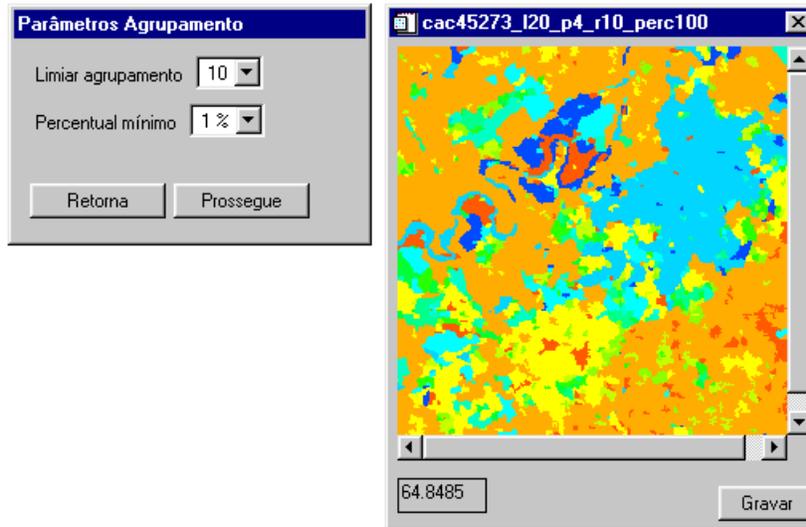


Fig. B.9 - Caixa de diálogo de definição dos parâmetros de agrupamento de regiões e o respectivo resultado deste processamento.

A.2. - Avaliação estatística

Depois de obtida a classificação não-supervisionada, é possível se obter uma estimativa da qualidade deste resultado, através de uma avaliação estatística de pontos amostrados aleatoriamente sobre toda a cena. Esta opção é executada pelo comando **Pontos**, disponível no submenu **Avaliacao** do menu **Estatística**, como visto na Figura B.10.



Fig. B.10 - Comandos de acesso a avaliação estatística dos pontos amostrados.

Abre-se então caixa de diálogo como a mostrada na Figura B.11, na qual se deve escolher o arquivo que contém os pontos de referência. Para escolher a classe que será considerada a principal na avaliação estatística, aperta-se o botão **Escolha** e será visualizada uma janela com legendas das classes presentes na imagem de classificação por matiz, semelhante a da Figura B.11. Basta mover o cursor até sobre a legenda correspondente ao matiz da classe principal e apertar o botão esquerdo do "mouse". O número referente a classe será

automaticamente colocado na caixa de texto localizada ao lado do botão **Escolha** da caixa de diálogo.

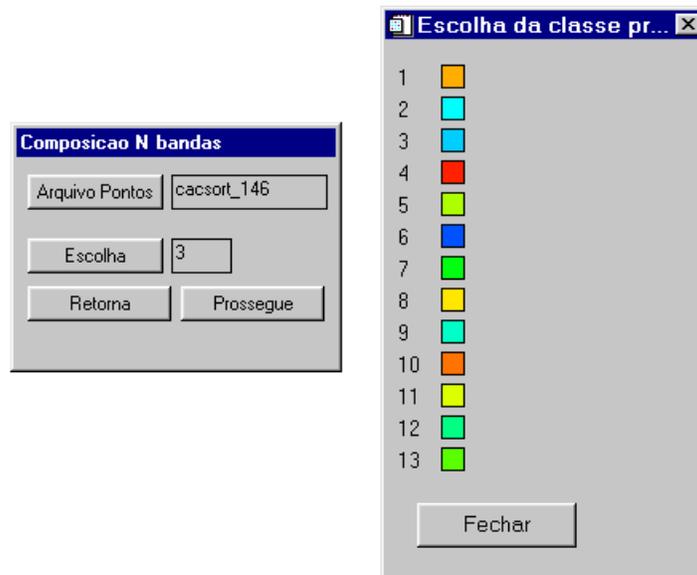


Fig. B.11 - Caixa de diálogo para carregar os pontos amostrados e de escolha da classe principal da classificação.

O passo seguinte consiste em carregar o arquivo que contém a classificação dos pontos feita pelo intérprete, que será considerada a referência para a análise estatística. Compara-se a interpretação de referência com a classificação de matiz dos pontos, obtendo-se a matriz de confusão, a exatidão global, o valor estimado de kappa, etc. Estes dados são armazenado em um arquivo de relatório de nome “cac45273_l20_p4_r10_perc100.rlt”, como o mostrado na Figura B.12.

Será exibido um gráfico mostrando as curvas das **fdp** binomiais do consumidor e do produtor, ressaltando as áreas de risco de ambos (Figura B.13). Os riscos são mostrados no canto superior direito do gráfica, assim como o número máximo de erros permitidos para que a classificação não seja refeitada, indicado por x_c (x crítico).

Estatística das classes - imagem			
Classe	Media	Total	Perc. (%)
1	41	184633	67.72
2	177	15311	5.62
3	192	14012	5.14
4	9	11132	4.08
5	80	10420	3.82
6	220	6364	2.33
7	124	5735	2.10
8	54	5434	1.99
9	165	5091	1.87
10	26	4589	1.68
11	69	4079	1.50
12	150	2975	1.09
13	97	2875	1.05

Estatística das classes - amostra			
Classe	Media	Pixels	Perc. (%)
1	40	119	68.79
2	179	7	4.05
3	206	13	7.51
4	5	6	3.47
5	65	7	4.05
6	205	3	1.73
7	111	4	2.31
8	87	5	2.89
9	170	3	1.73
10	18	2	1.16
11	93	3	1.73
12	***	0	0.00
13	158	1	0.58

Correlacao entre a imagem e a amostra: 0.998615

Classes agrupadas. Amostra válida de acordo com a observação do especialista.

Classe	Media	Variancia	Pixels	Perc. (%)
1	206	1047	13	8.90
2	48	2671	133	91.10

Matriz de Confusao

	1	2	Total OK (%)	INCLU (%)
1	13	0	13	100
2	3	130	133	97
	16	130	146	
	19	0		

Classe principal:	3
Tamanho da amostragem (n):	146
Pontos erroneamente classificados admissíveis:	14
Pontos erroneamente classificados observados:	3
Exatidão Global:	97.95%
Kappa:	0.88528037
Variancia kappa:	0.00424018
Exatidão do usuário:	85.00%
Risco do usuário (Ru):	5.00%
Risco real do usuário:	3.76%
Risco do produtor para Pp = 0.90:	49.62%

Fig. B.12 - Exemplo de relatório gerado da avaliação estatística realizada.

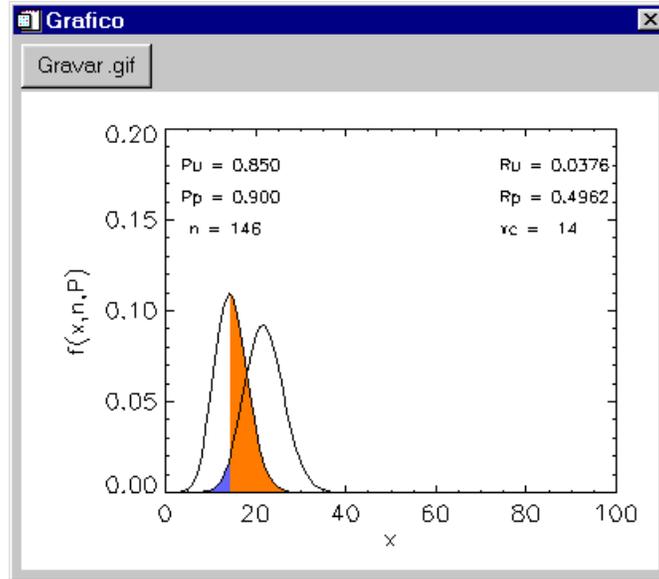


Fig. B.13 - Gráfico das **fdp** binomiais do consumidor (área azul) e do produtor (área laranja)

APÊNDICE C

AValiação ATRAVÉS DE AMostragem POR NÍVEL DE ACEITAÇÃO

Neste apêndice, será mostrado um exemplo de uso dos algoritmos de cálculo dos riscos, que usuário e produtor correm na avaliação de um resultado de classificação. Foi empregada uma classificação realizada sobre o matiz da composição colorida TM453 de Tremembé. Foi feito um estudo sobre 153 pontos amostrados.

Para 153 pontos amostrados, a uma exatidão requerida $P_u=85\%$, o risco do usuário aceitar uma classificação fora desta especificação é $R_u=4,04\%$. Por outro lado, conforme está ilustrado na Figura C.1, mesmo que a classificação tenha uma exatidão $P_p=90\%$, o risco de a mesma ser rejeitada pelo usuário é $R_p=46,42\%$.

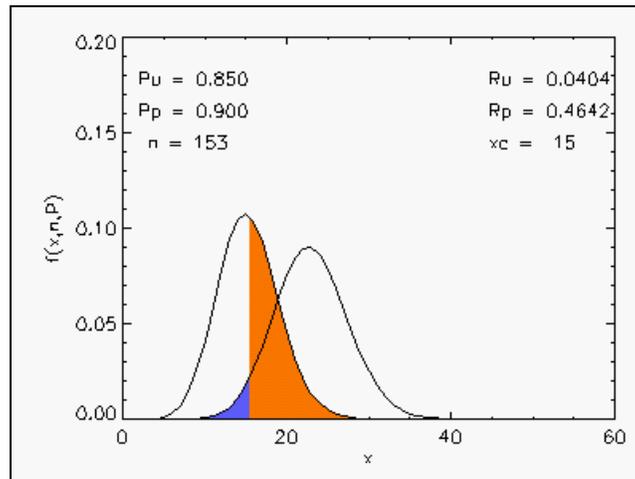


Fig. C.1 - Gráfico das **fdp** binomial do consumidor (área azul) e do produtor (área laranja)

O exemplo utilizado aqui é referente à avaliação feita de 153 pontos, sobre a classificação de matiz da composição TM453 de Tremembé, a limiar de segmentação 20. Para este resultado, conforme é mostrado na Figura C.2, houve 20 pontos erroneamente classificados. Portanto, a exatidão global da classificação é de 86,93%.

Tamanho da amostragem (n):	153
Pontos erroneamente classificados admissíveis:	15
Pontos erroneamente classificados observados:	20
Exatidão Global:	86.93%
Kappa:	0.73738414
Variancia kappa:	0.00296362
Exatidão do usuário:	85.00%
Risco do usuário (Ru):	5.00%
Risco real do usuário:	4.04%
Risco do produtor para $P_p = 0.90$:	46.42%
Exatidão mínima:	81.00%
Ru a $P_u=0.850$ e $pec= 15$:	4.04%
Rp a $P_p=0.869$ e $pec= 15$:	86.13%
Ru a $P_u=0.810$ e $pec= 20$:	3.44%
Rp a $P_p=0.900$ e $pec= 20$:	8.48%
Rp a $P_p=0.869$ e $pec= 20$:	44.08%
Exatidão mínima para aceitar $P_p = 0.869$:	76.00%
Ru a $P_u=0.760$ e $pec= 27$:	3.72%
Rp a $P_p=0.869$ e $pec= 27$:	4.06%

Fig. C.2 - Relatório gerado após a avaliação estatística.

O que o gráfico da Figura C.3 informa, é justamente o risco que o produtor está correndo de seu mapa ser rejeitado, se o usuário continuar a pedir uma exatidão mínima de 85%. Este risco é dado pela área em laranja e é de 86,13%. Os valores de risco mostrados nas Figuras C.2 e C.3, nem sempre são exatamente iguais por uma questão de truncamento de alguns dados de entrada no algoritmo de geração das curvas.

Esta classificação é rejeitada, pois há 20 pontos mal classificados, quando o máximo permitido são 15 pontos. Desenvolveu-se um algoritmo que calcula qual deve ser a exatidão mínima requerida pelo usuário, para que em um conjunto com n pontos, se aceite uma classificação com x_c pontos mal classificados. Neste exemplo específico, a nova exatidão mínima é de 81%. Mas mesmo assim, como pode ser visto na Figura C.4, apesar de a classificação ser aprovada, o risco do produtor ainda é muito alto, cerca de 44%.

Então, procura-se agora uma exatidão mínima que, além de aceitar a classificação dada, o risco do produtor seja tão baixo quanto ele queira. Também se desenvolveu um algoritmo para encontrar esta nova exatidão mínima, que para este caso é de 76%. O risco do produtor é agora em torno de 4%, correspondendo à pequena área destacada em laranja da Figura C.5.

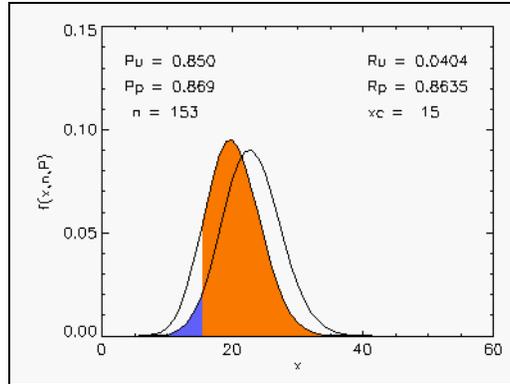


Fig. C.3 - Risco real do produtor com base na exatidão global $P_p=0,869$.

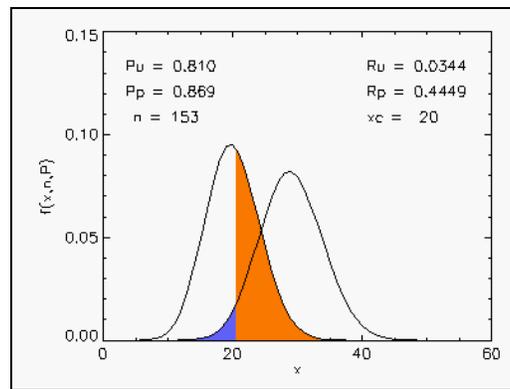


Fig. C.4 - Riscos que usuário e produtor teriam, caso o usuário baixasse a exatidão requerida a um valor no qual a classificação é aprovada tendo 20 pontos mal classificados.

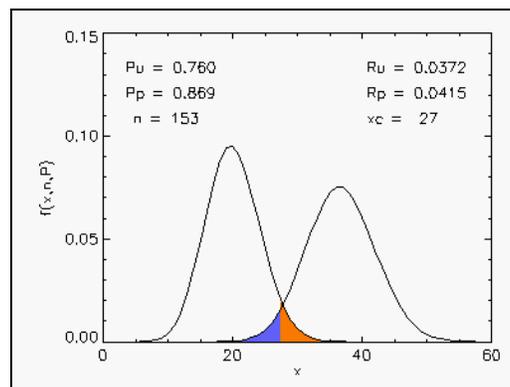


Fig. C.5 - Riscos que usuário e produtor teriam, caso o usuário baixasse a exatidão requerida a um valor no qual a classificação é aprovada, tendo 27 pontos mal classificados e com um risco menor que 5% de ser rejeitada erroneamente.

Digamos que tem-se agora um caso inverso, ou seja, a classificação foi muito boa e bem aprovada pelo teste. O que se deseja saber é qual a **exatidão máxima** que o usuário deve pedir para que a classificação não seja rejeitada, e com baixo risco de sê-lo.

O exemplo agora é de uma avaliação feita de 146 pontos, sobre a classificação de matiz da composição TM45273 de Caçapava, a limiar de segmentação 20. Para uma exatidão mínima requerida pelo usuário de 85%, em 146 pontos deve haver no máximo 14 erros de classificação. O resultado apresentado na Figura C.6 possui apenas 8 pontos mal classificados, tendo uma exatidão global de 94,52%. O risco do produtor mostrado Figura C.6, é o risco caso a exatidão do produtor fosse 90%, Mas na realidade, com a exatidão obtida, o risco calculado é de apenas 1,5%, conforme está ilustrado na Figura C.7.

Tamanho da amostragem (n):	146
Pontos erroneamente classificados admissíveis:	14
Pontos erroneamente classificados observados:	8
Exatidao Global:	94.52%
Kappa:	0.70295030
Variância kappa:	9.79215E-03
Exatidao do usuario:	85.00%
Risco do usuario (Ru):	5.00%
Risco real do usuario:	3.76%
Risco do produtor para Pp = 0.90:	49.62%

Fig. C.6 - Relatório gerado após a avaliação estatística.

A Figura C.8 ilustra a situação, onde se aumenta a exatidão requerida para até 90%, e a classificação ainda é aprovada, mas com um risco muito alto de ser considerada fora da especificação. O que se deseja é que classificação, ao aumentar-se a exatidão requerida, não corra um risco maior que 5% de ser erroneamente rejeitada. Conforme a Figura C.9, a exatidão do usuário que satisfaz estas condições é $P_u=0,86$, com o produtor correndo um risco em torno de 3%.

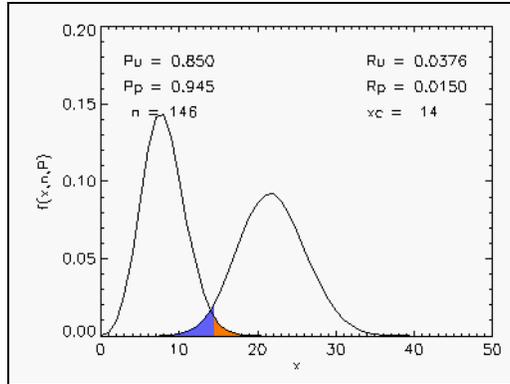


Fig. C.7 - Risco real do produtor com base na exatidão global $P_p=0,945$.

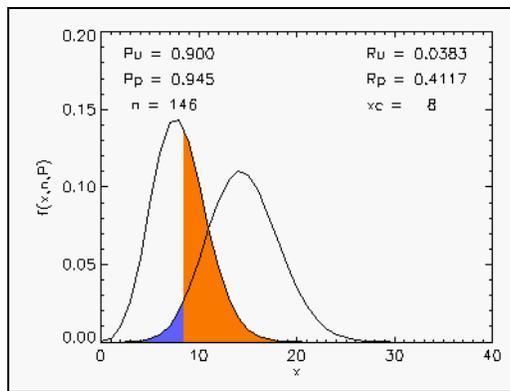


Fig. C.8 - Risco que usuário e produtor teriam, caso o usuário subisse a exatidão requerida até um valor onde ainda a classificação é aprovada com 8 pontos mal classificados.

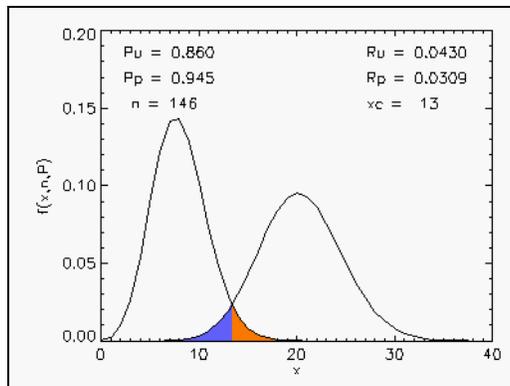


Fig. C.9 - Risco que usuário e produtor teriam, caso o usuário subisse a exatidão requerida até um valor onde a classificação é aprovada sem que o produtor corra um risco maior que 5%.