



Universidade Católica Dom Bosco

Centro de Ciências Exatas e Tecnológicas

Curso de Engenharia de Computação

**Segmentação de Imagens de Satélite para
Detecção de Degradação de Pastagens**

Guilherme Ribeiro Baganha

Hemerson Pistori

*Relatório Final submetido como um dos requisitos
para a obtenção do grau de Engenheiro de Com-
putação.*

UCDB - Campo Grande - MS - FEVEREIRO/2006

Estás entre nós

Tu é minha vida, outro Deus não há. Tu és minha estrada, a minha verdade.

Em tua Palavra eu caminharei, enquanto eu viver e até quando tu quiseres.

Já não sentirei temor, pois estás aqui, Tu estás no meio de nós!

Creio em ti, Senhor, vindo de Maria, Filho Eterno e Santo, homem como nós.

Tu morreste por amor, vivo estás em nós, Unidade trina com o Espírito e o pai

E um dia, eu bem sei, tu retornarás. E abrirás o Reino dos céus!

Tu és minha força, outro Deus não há, Tu és minha paz, minha liberdade,

Nada nesta vida nos separará. Em tuas mãos seguras minha vida guardarás.

Eu não temerei o mal, Tu me livrarás e no teu perdão viverei!

Ó Senhor da vida, creio sempre em ti! Filho Salvador, eu espero em ti!

Santo Espírito de Amor, desce sobre nós. Tu, de mil caminhos nos conduzes a uma fé

E por mil estradas onde andamos nós, Qual semente, nos levarás?

Agradecimentos

Agradeço a Deus em primeiro lugar que sempre esteve comigo me orientando espiritualmente e emocionalmente, e lógico a Jesus pois ninguém pode ir ao pai senão por ele e a paciência do Espírito Santo.

Agradeço ao meu orientador Hemerson Pistori, pela atenção a mim dedicada durante a realização deste trabalho, que tão sofrido foi e o acompanhamento rigoroso e metódico que sempre me dedicou em todas as fases do projeto, revelando, sempre, uma incrível dedicação e quase infinita paciência.

Agradeço aos meus pais Robertson Ruas Baganha e Josélia de Fátima Ribeiro Baganha, pelo apoio dado, não só por acreditar em mim em toda minha caminhada durante o curso, mas por me aturar.

Agradeço meu amigo Álvaro Afialho por me dar ajuda na parte mais difícil, e nas horas mais difíceis.

Agradeço pela companhia do meu mais que amigo Wagner Belotti nas discussões extravagantes, mas sempre satisfatória.

Agradeço a ajuda muito importante do meu amigo Alexsandro Ferreira de Souza - “Chokito”, pelos conselhos espirituais, que sempre não tinham hora para acabar e principalmente a ajuda na análise do meu texto. Não posso esquecer da Gracyelly Oliveira - “Gra” que liberou o namorado para me ajudar e soube me compreender nas horas difíceis.

Enfim, agradeço a todos que, de alguma forma, contribuíram não só para realização deste trabalho, mas para a conclusão de mais uma etapa de minha vida.

Resumo

A principal fonte de alimentação da pecuária bovina, no Brasil, são as pastagens. Com o crescimento dessa atividade, nas últimas décadas, observou-se um aumento significativo na quantidade de áreas degradadas. A necessidade de se acompanhar e controlar a ocorrência de degradação estimulou as pesquisas na área de visão computacional que buscam a automatização desses processos através da análise de imagens de satélite. Uma etapa crucial para o trabalho é a segmentação da imagem, responsável em obter as regiões dentro da imagem. Este trabalho tem como objetivo a criação de um módulo capaz de detectar as degradações de pastagens, utilizando algumas técnicas de segmentação de imagens já existentes. Para a análise do resultado foram utilizadas imagens adquiridas pela FLORAMAP, empresa de consultoria e mapeamentos.

Abstract

The bovine cattle's main feeding source, in Brazil, are the pastures. The continuous growth of this activity at the last decades has led to a significant increase at the amount of degraded areas. The necessity of managing and controlling the degradation occurrence stimulated researches at the computer vision area, trying to automate these processes through the analysis of satellite images. A crucial stage for this task is the image segmentation, responsible of obtaining the important regions inside the image. This work has the objective of creating a module capable of detecting the pastures degradations, with the utilization of some segmentation techniques already existent. For the image analysis, images acquired from FLORAMAP (a consulting and mapping enterprise) were used.

Conteúdo

1	Introdução	12
2	Fundamentação Teórica	15
2.1	Degradação de Pastagens	15
2.2	Segmentação de Imagens	18
2.3	Imagem de Satélite Multi-espectral	19
2.4	Modelos de Cores	23
2.4.1	Modelo de Cor RGB	24
2.4.2	Modelo de Cor HSI	25
3	Técnicas de Segmentação	27
3.1	Crescimento de regiões (<i>Region Growing</i>)	27
3.2	Junção e Separação (<i>Split & Merge</i>)	30
3.3	Aglomerção (<i>Clustering</i>)	32
4	Limiarização (<i>Thresholding</i>)	36
4.1	Métodos de Limiarização	38
4.1.1	Método de Otsu	39
4.1.2	Método de Entropia Máxima	40
5	Desenvolvimento	41
5.1	Algoritmos de Segmentação	42
5.1.1	Método de Otsu	42
5.1.2	Método da Máxima Entropia	42
5.2	Software Desenvolvido	44
5.3	Algoritmo de Abertura (<i>Opening</i>)	45
6	Experimentos e Análise de Resultados	48
6.1	Experimentos Realizados	48
6.1.1	Aquisição das Imagens de Satélites e Amostras Utilizadas	49
6.1.2	Métrica Utilizada para a Avaliação da Segmentação	49

6.2	Resultados Obtidos e Análise	50
6.2.1	Avaliação dos Algoritmos de Limiarização	51
6.2.2	Resultados e Discussão da Escolha do Melhor Canal e do Algoritmo Desenvolvido	51
7	Considerações Finais e Trabalhos Futuros	59
A	Análise Manual das Imagens	60
	Referências Bibliográficas	62

Lista de Figuras

2.1	Pastagem recém formada (http://www.manejo.com.br/)	16
2.2	Pastagem degradada (http://www.manejo.com.br/)	16
2.3	Pastagem recuperada (http://www.manejo.com.br/)	17
2.4	Representação gráfica simplificada do processo de degradação de pastagens cultivadas em sua diferentes etapas de tempo.	18
2.5	Exemplo de uma segmentação de 5 conjuntos (http://www.lps.usp.br/)	19
2.6	Exemplo de funcionamento dos satélites classificados como passivo (http://www.intersat.com.br/)	20
2.7	Imagem da cidade de Brasília (a) Banda 3, (b) banda 4, (c) banda 5, (d) composição colorida (http://www.dgi.inpe.br/)	21
2.8	Exemplos de imagens de satélites do CBER-2 (http://www.dgi.inpe.br/)	23
2.9	Sistema de Cor RGB [1]	25
2.10	Triângulo HSI no cubo de cor RGB (http://www.profc.udec.cl/gabriel)	26
3.1	Crescimento de Regiões em todas as direções [2].	29
3.2	Fig 3.2A - Imagem Original mostrando um ponto semente; Fig 3.2B - Estágio primário de crescimento de uma região; Fig 3.2C - Estágio intermediário de crescimento; Fig 3.2D - Região final [2].	30
3.3	Imagem particionada.	32
3.4	Quadtree correspondente a imagem particionada.	32
3.5	Dinâmica da coleta de configurações [3].	33
3.6	Representação de aglomerados em um espaço de atributos [4].	34
4.1	Histogramas de níveis de cinzas com um único limiar.	37
4.2	Histogramas de níveis de cinzas com múltiplos limiares.	37
4.3	Exemplo de uma limiarização com um único limiar de separação (binarização)	38

5.1	Figura 5.1a mostra uma imagem de satélite antes da operação de abertura e Figura 5.1b mostra a imagem após a operação de abertura.	46
6.1	Foto tirada da área de cerrado, para observação da cor da pastagem (http://www.cnpma.embrapa.br/).	50
6.2	Fazenda Rio do Sangue.	52
6.3	Fazenda Agrotep.	53
6.4	Fazenda Atiaia.	54
6.5	Imagem de entrada	55
6.6	Imagem saturada (S)	55
6.7	Pasto Bom	56
6.8	Floresta	56
6.9	Resultante da Floresta com o Pasto Bom	57
6.10	Imagem Segmentada	57
A.1	Análise da Fazenda Rio do Sangue, Guairova e Rio Pec.	60
A.2	Análise da Fazenda Agrotep e Guinoza.	61

Lista de Tabelas

2.1	Principais aplicações para as Bandas espectrais do sensor TM [5]	22
3.1	Matriz de representação do conjunto de pixels	28
6.1	Tabela para avaliação do melhor limiar a ser utilizado para o algoritmo de segmentação desenvolvido.	51
6.2	Taxa de erro dos seis canais segmentados do corte feito da imagem de satélite da Fazenda Rio do Sangue, utilizando o algoritmo desenvolvido, em relação à mesma imagem segmentada manualmente, em que o canal de saturação obteve o menor erro na segmentação.	52
6.3	Taxa de erro dos seis canais segmentados do corte feito da imagem de satélite da Fazenda Agrotep, utilizando o algoritmo desenvolvido, em relação à mesma imagem segmentada manualmente, em que o canal de saturação obteve o menor erro na segmentação.	53
6.4	Taxa de erro dos seis canais segmentados do corte feito da imagem de satélite da Fazenda Atiaia, utilizando o algoritmo desenvolvido, em relação à mesma imagem segmentada manualmente, em que o canal de saturação obteve o menor erro na segmentação.	54

Lista de Algoritmos

5.1	Otsu (imagem_gray)	43
5.2	Segmentação_de_Pastagem (Imagem_Satelite)	45
5.3	Erosão (imagem_binarizada)	47
5.4	Dilatação (imagem_binarizada)	47
5.5	Abertura (imagem_binarizada)	47

Capítulo 1

Introdução

Com o baixo valor da terra, a oferta de créditos, o surgimento de espécies forrageiras com alta capacidade de adaptação ao clima e a baixa fertilidade de solo, o Brasil teve, na década de 70, um grande crescimento na produção pecuária [6]. A atividade de pecuária bovina ocupa cerca de 44% do rebanho nacional, que tem como principal fonte de alimentação as pastagens. O uso abusivo de carga animal e a falta de atenção às necessidades de correção e fertilização do solo, ocasionam a perda da capacidade produtiva do solo, causando assim a degradação [6].

O Brasil tem cerca de 105 milhões de hectares de pastagens cultivadas ¹. Desse total, calcula-se que pelo menos 50% estejam degradadas ou em processo de degradação. O problema também atinge áreas que ainda não foram ocupadas pela pecuária. Em várias regiões do país, grandes extensões de pastagens naturais ou naturalizadas, que poderiam contribuir para a ampliação da pecuária, não se prestam à atividade devido ao processo de degradação em que se encontram.

As pastagens em degradação, segundo Macedo [7], podem ser definidas como o processo evolutivo de perda de vigor, de produtividade e de capacidade de recuperação natural das pastagens para sustentar os níveis de produção e qualidade exigidas pelos animais. Em razão de manejos inadequados de animais está ocorrendo um processo de degradação avançado nos recursos naturais.

Este trabalho visa criar um módulo capaz de detectar a degradação do solo, utilizando técnicas de segmentação de imagens de satélite. Serão utilizadas imagens do satélite CBERS-2, na escala 1:500.000, em virtude da realidade do mercado brasileiro, da escassez de recursos financeiros e da necessidade de uma base de dados confiável tanto em qualidade quanto em

¹<http://www.ibge.gov.br/home/estatística/economia/agropecuaria>

quantidade. A escolha destas imagens deve-se também à facilidade de obtenção, pois no site do INPE (<http://www.dgi.inpe.br>) encontram-se à disposição da sociedade brasileira gratuitamente as imagens de todo o território nacional.

Com a segmentação de imagens de satélites, podemos verificar onde está localizado o maior índice de degradação das pastagens. Fazendeiros e órgãos competentes poderiam utilizar esta ferramenta para realizar planejamentos ambientais com maior eficiência, demonstrando a situação das pastagens [8]. O módulo a ser criado poderá também ser integrado a um Sistema de Informação Geográfica [9].

A segmentação consiste em dividir imagens de entrada ou em identificar regiões homogêneas, para uma melhor diferenciação das regiões de interesse [10]. O resultado da segmentação constitui-se de dados agrupados em sub-regiões, sendo que umas das abordagens é a agregação de pixels ², que começa com um conjunto de pontos, com o nome de “semente” e a partir desta semente, há uma aglomeração das regiões que possuem propriedades em comum, como cor ou textura [2].

Para a realização deste projeto, determinou-se através de leituras e pesquisas a seleção das técnicas que seriam utilizadas, que tornaria a implementação do módulo fácil e eficiente. Foram pesquisadas técnicas de segmentação de imagens voltadas para outras aplicações da visão computacional e não somente técnicas para detecção de pastagens degradadas.

As imagens digitais de satélites foram fornecidas pela proprietária da “*FLORAMAP - Projetos, Consultorias e Mapeamentos Ltda.*”, situada em Cuiabá-MT e a análise manual das pastagens degradadas pela empresa “*Neves & Baganha - Projetos de manejo, reflorestamento e georrefenciamento por imagens de satélite*”, situada em Juara-MT. Com isso foi produzido um plugin utilizando como recurso o programa multiplataforma ImageJ [11]. Além disto, foi produzido material bibliográfico relacionado ao estudo das técnicas de segmentação de imagens para detecção de pastagens degradadas baseadas em visão computacional.

Para análise do funcionamento do plugin de segmentação de imagens de satélite, foi desenvolvido um sistema de análise para fazer comparações do valor dos pixels da imagem analisada manualmente com os da imagem analisada automaticamente, tendo como resultado uma taxa de erro.

Este relatório está organizado da seguinte maneira. No Capítulo 2 é apresentada a fundamentação teórica utilizada para o desenvolvimento do trabalho de pesquisa. No Capítulo 3 são relacionadas as técnicas de seg-

²Pixel é o menor elemento em um dispositivo de exibição, ao qual é possível atribuir uma cor.

mentação. No Capítulo 4 é apresentada a técnica de limiarização desenvolvida. No Capítulo 5 encontra-se o desenvolvimento do projeto de pesquisa. No Capítulo 6 são apresentados os experimentos e a análise dos resultados obtidos. E por último, no Capítulo 7 são apresentadas as considerações finais sobre o projeto de graduação e os trabalhos futuros.

Capítulo 2

Fundamentação Teórica

Neste capítulo, será feita uma introdução sobre degradação de pastagem, segmentação de imagens, imagem de satélite e modelos de cores, para melhor compreensão das técnicas de segmentação que serão citadas no capítulo 3.

2.1 Degradação de Pastagens

A pastagem é identificada como certas espécies de plantas utilizadas para alimentação de animais no campo [12]. Na Figura 2.1, 2.2 e 2.3 podemos observar, consecutivamente, exemplos de pastagem recém formada, pastagem degradada e pastagem recuperada.

A criação de animais no Brasil é realizada principalmente sob manejo direto em pastagens tropicais cultivadas, que ocupava em 1996 aproximadamente 180 milhões de hectares (unidade de medida de área de superfície, usada na agricultura). Desse total, a região dos cerrados ocupava cerca de 35 milhões de pastagens cultivadas (IBGE-1996). Atualmente, estima-se que a região dos cerrados abrigue 45 a 50 milhões de hectares com pastagens cultivadas, das quais aproximadamente 50% encontra-se com algum grau de degradação [13].

Os solos ocupados por pastagens são geralmente disformes quando comparados com àqueles usados para agricultura de grãos. Esses solos apresentam problemas de fertilidade natural, acidez, topografia, pedregosidade ou limitações de drenagens, sendo de se esperar que essas áreas sejam destinadas à produção e sustentabilidade de bovinos de corte [14].

A reabilitação das áreas degradadas pode apresentar uma contribuição significativa para o desenvolvimento sócio-econômico de uma região, ao mesmo tempo em que pode ter reflexos positivos sobre a preservação ambiental. A degradação das pastagens pode ser explicada como um processo



Figura 2.1: Pastagem recém formada (<http://www.manejo.com.br/>)



Figura 2.2: Pastagem degradada (<http://www.manejo.com.br/>)

dinâmico de degeneração ou de queda relativa da produtividade, e pode ser interpretada de diferentes formas pelos produtores [15].

Podemos ilustrar esse processo contínuo de alterações das pastagens, através das etapas mostradas na escada de degradação (Figura 2.4), em cujo



Figura 2.3: Pastagem recuperada (<http://www.manejo.com.br/>)

topo estariam as regiões com maior produtividade, ricas em N (Nitrogênio) e P (Potássio), entre outras substâncias, e à medida que se vai descendo os degraus, com a utilização de pastagens, avança-se o processo de degradação.

Até um determinado degrau das etapas, há condições de se conter a queda de produção e manter a produtividade através de ações mais simples, diretas e com menores custos operacionais. A partir daí ocorre o processo de degradação de pastagem propriamente dito, em que apenas ações de recuperação ou de renovação, muitas vezes mais drásticas e com alto custo, apresentariam respostas adequadas. Ao final desse processo, o solo apresentará degradação com alterações em sua estrutura, ocorrendo compactação e conseqüentemente diminuição das taxas de infiltração e retenção de água, causando erosão e assoreamento [7].

O entendimento do processo de degradação para antecipação de suas etapas e a utilização de indicadores são elementos importantes para evitar situações de quebra da sustentabilidade da produção. Alternativas de recuperação e renovação das pastagens degradadas de forma direta, com métodos mecânicos e químicos ou de forma indireta, com a utilização de culturas de grãos e pastos anuais, já estão disponíveis, mas devem ser adequadas a cada sistema de produção, para maximizar as inter-relações biológicas, econômicas e sociais.



Figura 2.4: Representação gráfica simplificada do processo de degradação de pastagens cultivadas em suas diferentes etapas de tempo.

2.2 Segmentação de Imagens

O termo segmentação foi inserido no início do século XX por alguns psicólogos alemães (Köhler, Wertheimer e Koffka) [16]. Eles descobriram que o sistema de visão humana realiza agrupamentos baseados na proximidade, similaridade e continuidade das imagens captadas. Tais agrupamentos são utilizados na classificação e análise dos objetos percebidos. Esta ideia foi estendida para o contexto computacional e deu origem aos primeiros algoritmos de segmentação de imagens.

O processo de decompor uma imagem nas suas partes constituintes designa-se por segmentação. A segmentação pode ser considerada como um *processo de classificação de pixels*. Se as classes e as suas probabilidades de definição por classes, bem como as propriedades (por exemplo, brilho) forem conhecidas *a priori*, a segmentação reduz-se a um problema clássico de decisão estatística (Decisão para qual classe o pixel se aglomera). Quando as classes não são conhecidas pode recorrer-se a técnicas de agrupamento (*clustering*).

Segundo Haralick [17], a segmentação torna-se um processo complicado porque tenta traduzir para o computador um processo cognitivo extremamente sofisticado realizado através da visão humana.

Os algoritmos de segmentação para imagens são, na maioria das vezes, baseados em uma das seguintes propriedades básicas de valores de níveis de cinza: a descontinuidade ou a similaridade. Na descontinuidade, a abordagem é particionar a imagem baseada em mudanças bruscas nos níveis de

cinza ou textura. As principais abordagens da similaridade baseiam-se em limiarização, crescimento, divisão e fusão de regiões [18].

Em uma etapa crítica na segmentação procura-se distinguir os fragmentos uns dos outros e do fundo. Esta particularidade permitirá ao programa computacional interpretar pixels contíguos e agrupá-los em regiões. Esta etapa é a mais difícil do processo e também a mais delicada porque todas as medidas serão realizadas sobre as regiões identificadas.

Antes de realizar a segmentação é adquirida a imagem e definida a forma de como será apresentada e armazenada, e também é executada toda uma gama de operações e algoritmos de acordo com a necessidade, como por exemplo, um filtro para eliminar alguns ruídos ou um algoritmo de limiarização para definir uma classe ou eliminar o fundo (*background*) de uma imagem.

Na Figura 2.5, é mostrado um exemplo de uma segmentação em 5 conjuntos: o céu, o arbusto, o fundo da imagem, a neve e o lobo.

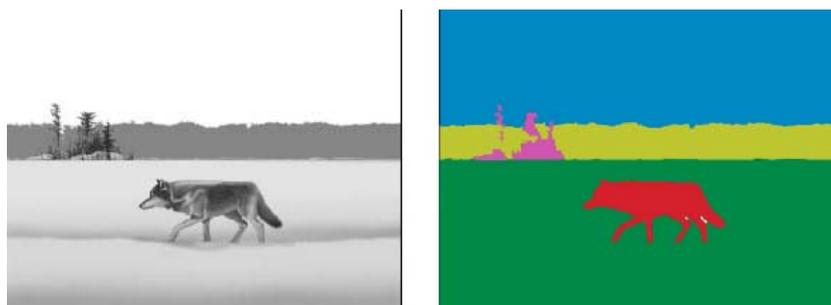


Figura 2.5: Exemplo de uma segmentação de 5 conjuntos (<http://www.lps.usp.br/>)

2.3 Imagem de Satélite Multi-espectral

Imagens de satélites são ferramentas cada vez mais usadas nas diversas áreas de conhecimento, como por exemplo: agricultura, engenharia florestal, arquitetura, urbanismo, geologia e hidrogeologia. A utilização de imagens de satélite na caracterização ambiental torna-se cada vez mais relevante, uma vez que estas podem gerar dados com alta frequência de atualização, assim não há a necessidade de ir aos locais para averiguação da situação ambiental, sendo que alguns lugares são de difícil acesso. O monitoramento do uso e ocupação da superfície terrestre através de imagens de satélites permite registrar as alterações no padrão de ocupação do solo ou identificar mudanças de caráter natural na cobertura vegetal [19].

As imagens de satélites são denotadas imagens multi-espectrais, pois são a coleções de imagens de uma mesma cena, obtidas por sensores com respostas espectrais diferentes. Esses sensores podem ser classificados de diversas formas, porém tendo uma diferença básica que permite a classificação em duas classes: ativos e passivos. Essa classificação refere-se à capacidade do sensor emitir energia que irá interagir com o objeto, se esse não emitir energia é passivo, se não é ativo [19]. A maioria dos satélites são passivos, pois necessitam de energia externa nos seus sensores. A principal fonte de energia externa em nosso planeta é o sol, que só é captada pelo sistema de sensor depois de interagir com a superfície e a atmosfera, podendo ser observado na Figura 2.6.

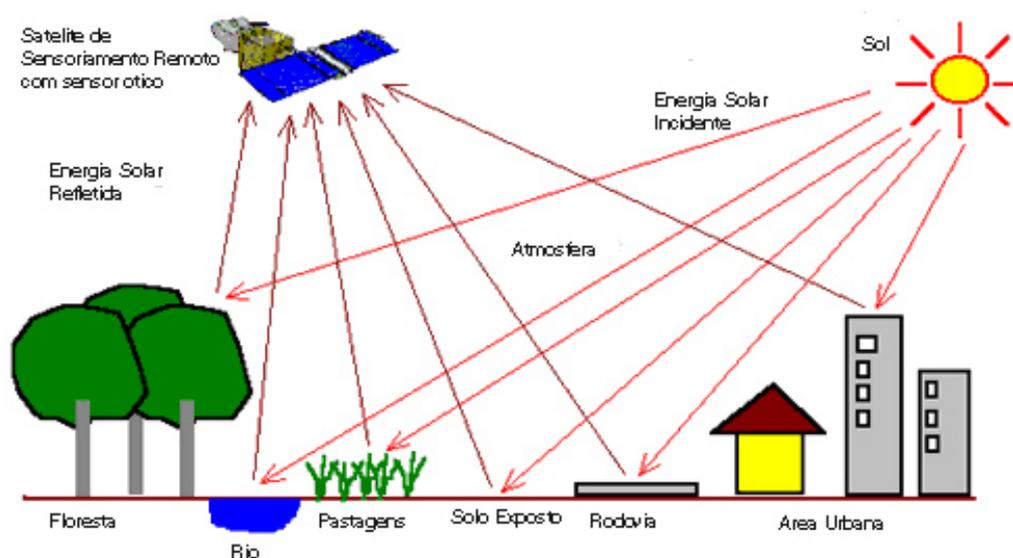


Figura 2.6: Exemplo de funcionamento dos satélites classificados como passivo (<http://www.intersat.com.br/>)

A resolução espectral de uma imagem está relacionada com a largura das bandas espectrais e o número de canais usado. Uma imagem colorida é, na realidade, um conjunto de três imagens obtidas por sensores com respostas espectrais diferentes. A Figura 2.7 mostra três bandas (3, 4 e 5) de uma imagem CBERS-II de uma área da cidade de Brasília e a imagem colorida obtida pela composição das bandas 5, 4 e 3 nos canais R (vermelho), G (verde) e B(azul), respectivamente [20].

A interpretação de imagens multi-espectrais possibilita a geração de mapas atualizados com excelente precisão. Utilizando uma única banda ou composição de diversas bandas ou, ainda, bandas transformadas, de épocas ou

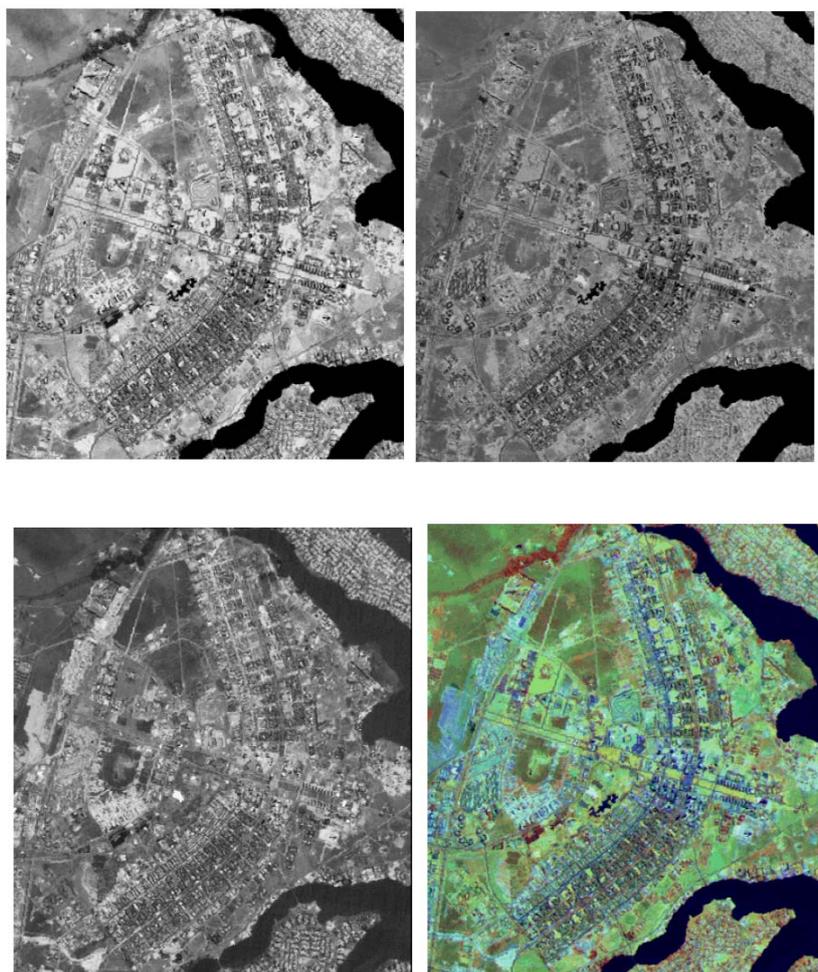


Figura 2.7: Imagem da cidade de Brasília (a) Banda 3, (b) banda 4, (c) banda 5, (d) composição colorida (<http://www.dgi.inpe.br/>)

anos diferentes, é possível realizar uma boa análise ocupacional. As bandas podem ser identificadas visualizando a Tabela 2.1.

Fazendo a evolução ocupacional de uma determinada área, pode-se comparar a cobertura vegetal e o uso da terra entre os diversos períodos analisados. Para tal, é necessário estabelecer o padrão de fotointerpretação e cada classe é classificada dentre uma legenda com itens que refletem a dinâmica do uso, como por exemplo: supressão de vegetação nativa, pastagem abandonada, áreas com vegetação nativas ou áreas intactas, etc [20].

O satélite CBERS-2 que foi lançado no dia 21 de outubro de 2003 faz parte da continuação do programa CBERS (Satélite Sino-Brasileiro de Recursos Terrestre), uma cooperação entre Brasil e China. Desde o seu lançamento

Banda	Comprimento de Onda	Localização da Faixa	Principais Aplicações
1	0.45-0.52	Azul	-Mapeamento de águas costeiras -Identificação de feições culturais
2	0.52-0.60	Verde	-Medidas dos picos de reflectância da vegetação -Estimativa do vigor da vegetação
3	0.63-0.69	Vermelho	-Diferenciação de espécies vegetais -Identificação de feições culturais
4	0.76-0.90	Infravermelho próximo	-Tipos, vigor e biomassa da vegetação -Identificação de corpos d'água -Umidade dos solos
5	1.55-1.75	Infravermelho médio	-Mapeamento de vegetação -Umidade dos solos -Diferenciação entre nuvem e neve
6	10.4-12.5	Infravermelho termal	-Análises do "stres" da vegetação -Mapeamento térmico
7	2.08-2.35	Infravermelho médio	-Discriminação de minerais e rochas

Tabela 2.1: Principais aplicações para as Bandas espectrais do sensor TM [5]

o CBERS-2 vem operando normalmente. Ele está integrado no Instituto Nacional de Pesquisas Espaciais (INPE), que desenvolveu o sistema de processamento das imagens. As imagens são recebidas em Cuiabá, passando em seguida para São José dos Campos, onde são processadas para distribuição aos usuários ¹.

O satélite demora em torno de 26 dias para retornar ao mesmo ponto de cobertura da Terra. Este é o tempo necessário para se ter imagens de todo o globo terrestre com suas câmeras CCD e IRMSS que possuem campos de visada (distância que a lente observa no globo terrestre) de 113 Km a 120

¹<http://www.inpe.br/>

Km, respectivamente ². Podemos observar um exemplo de imagem de satélite do CBER-2 na Figura 2.8.



Figura 2.8: Exemplos de imagens de satélites do CBER-2 (<http://www.dgi.inpe.br/>)

2.4 Modelos de Cores

Modelos de cores, também conhecidos como espaço de cor ou sistema de coordenadas de cor, é uma especificação de um sistema de coordenadas, geralmente 3-D, onde cada cor é representada por um simples ponto [2]. Os modelos de cores são usados para representar cores com atributos, como matiz (H), saturação (S), cromaticidade (formada pela junção da cor e da saturação) e brilho [21]. Dentre os vários modelos de cores existentes, existem os direcionados ao *hardware* e os direcionados ao *software*. Para o *hardware*, os mais comumente usados são o RGB (Red, Green, Blue), para monitores

²<http://www.dgi.inpe.br/>

coloridos e para uma ampla variedade de câmeras de vídeo a cores; o CMY para impressoras coloridas (Cyan, Magenta, Yellow); o YIQ, que é o padrão para transmissão de sinal (analógico) de vídeo colorido para televisores, o Y corresponde a luminância, I e Q correspondem a cor da imagem; e o YCrCb, que é um modelo de cor inicialmente utilizado em televisão digital e que independe do sistema de codificação de sinal de TV. Devido ao desacoplamento da luminância com as informações de cores da imagem, este modelo de cor pode ser utilizado tanto em televisores coloridos como também em monocromáticos. Os modelos de *software* mais freqüentemente utilizados são o RGB, HSI (matiz, saturação, intensidade).

Os modelos de cores apresentados a seguir, são o RGB e HSI devido ao seu uso no sistema proposto.

2.4.1 Modelo de Cor RGB

O modelo de cor RGB trata a imagem colorida como um conjunto de três imagens independentes em nível de cinza, cada qual representa o componente de cor vermelho, verde e azul [22]. Também é definido em [2] como sendo formado por um conjunto de componentes espectrais primários de vermelho, verde e azul. Este modelo é representado por um cubo num plano de coordenadas cartesianas, conforme Figura 2.9. Os valores de vermelho, verde e azul estão nos três cantos e nos outros três cantos estão os valores de ciano, magenta e amarelo. O canto localizado na origem é o preto e o mais distante da origem é o branco. Ao longo da reta que liga o preto e o branco estende-se os níveis de cinza, já as outras cores são pontos que não se encontram nesta reta e sim em qualquer lugar dentro ou sobre o cubo. Atualmente o RGB é muito utilizado, tanto na reprodução de imagens (monitores) como na captura das mesmas (câmeras coloridas RGB), apesar do grande uso, este modelo de cor não é sempre indicado para processamento de imagem [2], pois grande parte das operações devem ser feitas em cada plano de cores de forma independente, ocorrendo com isso, grande perda de informação, além do mais ele não produz componetes de cor que refletem com fidelidade o sistema visual de cor.

No modelo de cor RGB tem-se a intensidade de cada cor primária variada no espaço de um byte (0..255), no qual são possíveis 256 valores diferentes para cada uma das componentes básicas, tendo-se assim 256 x 256 x 256 combinações, logo temos o valor de 16.777.216 variações possíveis de cores [1].

Seja g uma imagem multi-espectral de 3 bandas, cada pixel desta imagem é representado numericamente por uma tripla de nível de cinzas correspondentes a cada uma das 3 bandas, isto é:

$$g_k = (g_1, g_2, g_3) \quad (2.1)$$

Definimos que g_k , onde $k = 1, 2, 3$ são os valores dos níveis de cinza do elemento de imagem da banda k de uma imagem multi-espectral de 3 bandas, em uma dada posição (i, j) na imagem.

Um elemento de uma imagem colorida pode, então, ser representado por esta tripla, onde g_1 , g_2 e g_3 indicam a proporção das cores vermelho, verde e azul, respectivamente. A cada ponto na imagem colorida corresponde uma só cor, que é caracterizada pelos níveis de cinza das três bandas escolhidas e associadas às cores R, G, B do sistema de cores, que é observado por um cubo unitário [1], como mostra a Figura 2.9.

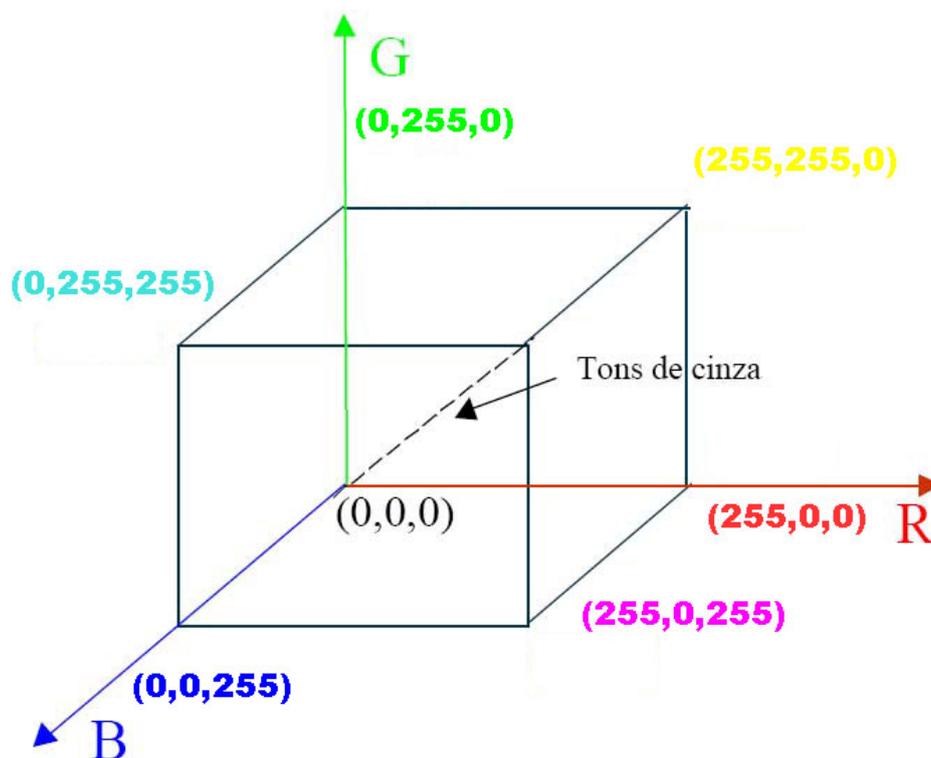


Figura 2.9: Sistema de Cor RGB [1]

2.4.2 Modelo de Cor HSI

O modelo de cor HSI representa a cor em termos de matiz (H), saturação (S) e intensidade (I). Matiz é um atributo que descreve uma cor pura, saturação

a medida do grau de diluição de uma cor pura com o branco e a intensidade é o nível de luminância da imagem [23]. O modelo de cor HSI é baseado no triângulo de cores de Maxwell, derivado do cubo de cores RGB mostrado na Figura 2.9. A Figura 2.10 mostra o triângulo de Maxwell como um plano que intercepta o r_0 , g_0 e b_0 nas coordenadas $(1,0,0)$, $(0,0,1)$ e $(0,1,0)$. O triângulo que representa o HSI está localizado dentro do cubo de cores RGB, sendo o triângulo bidimensional e o cubo tridimensional. No centro do triângulo cruza uma reta conectando as cores branca e preta, representando todos os tons de cinza de uma cor, correspondendo a 0% de saturação. Localizado nos vértices estão as três cores primárias. A saturação da cor (S) é medida pelo comprimento do vetor de uma dada cor r , g e b (ponto P da Figura 2.10) até o centro do triângulo. Qualquer cor localizada na borda do triângulo está 100% saturada. O valor da matiz (H) define a posição angular de uma dada cor, podendo estar entre 0 e 359 graus em relação à linha de referência que sai do centro do triângulo para o vértice de cor vermelha.

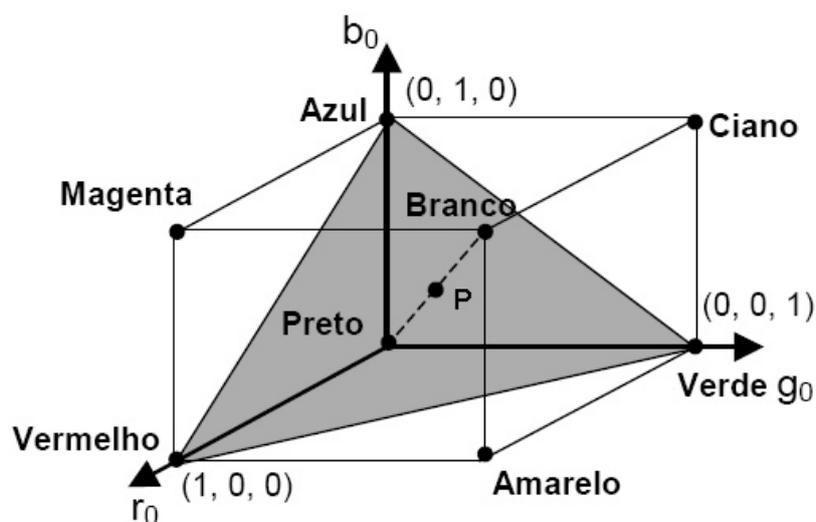


Figura 2.10: Triângulo HSI no cubo de cor RGB (<http://www.profc.udec.cl/gabriel>)

Capítulo 3

Técnicas de Segmentação

Na segmentação é ideal que cada região obtida no resultado esteja diretamente relacionada com um objeto real contido na imagem, como por exemplo, um automóvel ou uma pessoa e que também se possa fazer distinção do plano de fundo (*background*) da mesma .

Existem na literatura diversas taxonomias para classificação dos métodos de segmentação de imagem. Neste estudo será considerada a mesma taxonomia adotada por Gonzales [2] que classifica os métodos de segmentação em quatro categorias básicas baseadas em similaridades: limiarização (*Thresholding*), crescimento de regiões (*Region Growing*), junção e separação (*Split & Merge*) e aglomeração (*Clustering*). Estas técnicas serão discutidas a seguir, mas a técnica de limiarização em particular será discutida no Capítulo 4, pois trata-se da técnica que foi adotada.

3.1 Crescimento de regiões (*Region Growing*)

Uma região é definida como um conjunto conexo de pontos com uma propriedade em comum. A imagem é a soma de todas as regiões. Este conjunto de “pixels” contíguo se espalha bidirecionalmente e apresenta uniformidade.

A técnica por crescimento de regiões é um processo iterativo em que as regiões espacialmente adjacentes são agrupadas segundo algum critério de similaridade. Para Gonzalez [2], o crescimento de regiões é um processo que agrupa pixels ou sub-regiões em regiões maiores.

A mais simples das abordagens é a agregação de pixels, a qual começa com um conjunto de pontos “sementes”, e desses crescem regiões pela junção de cada ponto semente aqueles pixels vizinhos que têm propriedades similares (tais como nível de cinza, textura, cor).

Inicialmente, esse processo de segmentação rotula cada pixel como sendo

uma região distinta. A partir daí são agrupados os pixels com valores de similaridade inferiores ao limiar definido pelo usuário, baseados em um teste de hipótese estatística realizada com as médias entre as regiões. Com isto a imagem é fragmentada em sub-imagens, as quais são reagrupadas a seguir, segundo um limiar de agregação (tamanho mínimo aceitável para uma sub-região), definido também pelo usuário [5].

O algoritmo de crescimento de regiões gera, a partir de um pixel (i, j) , uma região contendo (i, j) e possuindo um valor médio de nível de cinza próximo ao de (i, j) . O grau de similaridade é determinado por um parâmetro de tolerância t , representado pela distância euclidiana entre os vetores associados a cada segmento. Segundo Liporace [24], tomando-se uma distância (R_i, R_j) como medida de similaridade entre regiões R_i e R_j , e sendo “A”, uma constante determinando o tamanho mínimo em pixel, aceitável para uma região, o algoritmo de crescimento de regiões considera inicialmente cada pixel sendo uma região $(R_1, R_2, R_3, R_4, R_5, R_6, R_7, R_8$ e $R_9)$, conforme mostrado na Tabela 3.1.

Tabela 3.1: Matriz de representação do conjunto de pixels

R_6	R_3	R_7
R_2	R_1	R_4
R_9	R_5	R_8

Sejam R_i e R_j duas regiões, onde R_i é vizinho de R_j . Uma região R_i é a vizinha mais próxima de R_j , quando a distância $(R_i, R_j) \leq$ a distância (R_j, R_k) para todo R_k vizinhos de R_j . Se a distância $(R_j, R_i) < t$, uma região $R_1 = R_j \cup R_i$ é criada e retorna-se ao passo onde se compara a distância dos vizinhos [5]. Pode-se esclarecer melhor visualizando a Figura 3.1.

Para cada região R_j , cujo o tamanho em pixel for menor ao estabelecido por “A”, cria-se um segmento $R_k = R_j \cup R_i$, onde R_i é o vizinho mais próximo de R_j . Esse processo se repete até não haver mais nenhuma região ou união de duas regiões multipixel, e em seguida é feita uma redefinição das características desta como média, variância, área e perímetro [5].

Apesar do método de Crescimento de Região ser bem simples, dois problemas surgem de imediato. Primeiro, como selecionar “sementes” que devidamente representem as regiões de interesse e segundo, qual critério de agregação melhor se adapta ao tipo de imagem que está se utilizando. O primeiro problema está freqüentemente ligado à natureza da imagem. Em uma aplicação que utilize, por exemplo, imagens geradas por dispositivos infravermelhos é comum que os objetos de interesse sejam mais aparentes que os demais, sendo assim o conjunto de sementes seria um conjunto de pixels cuja tonalidade se aproxime mais da cor branca [25].

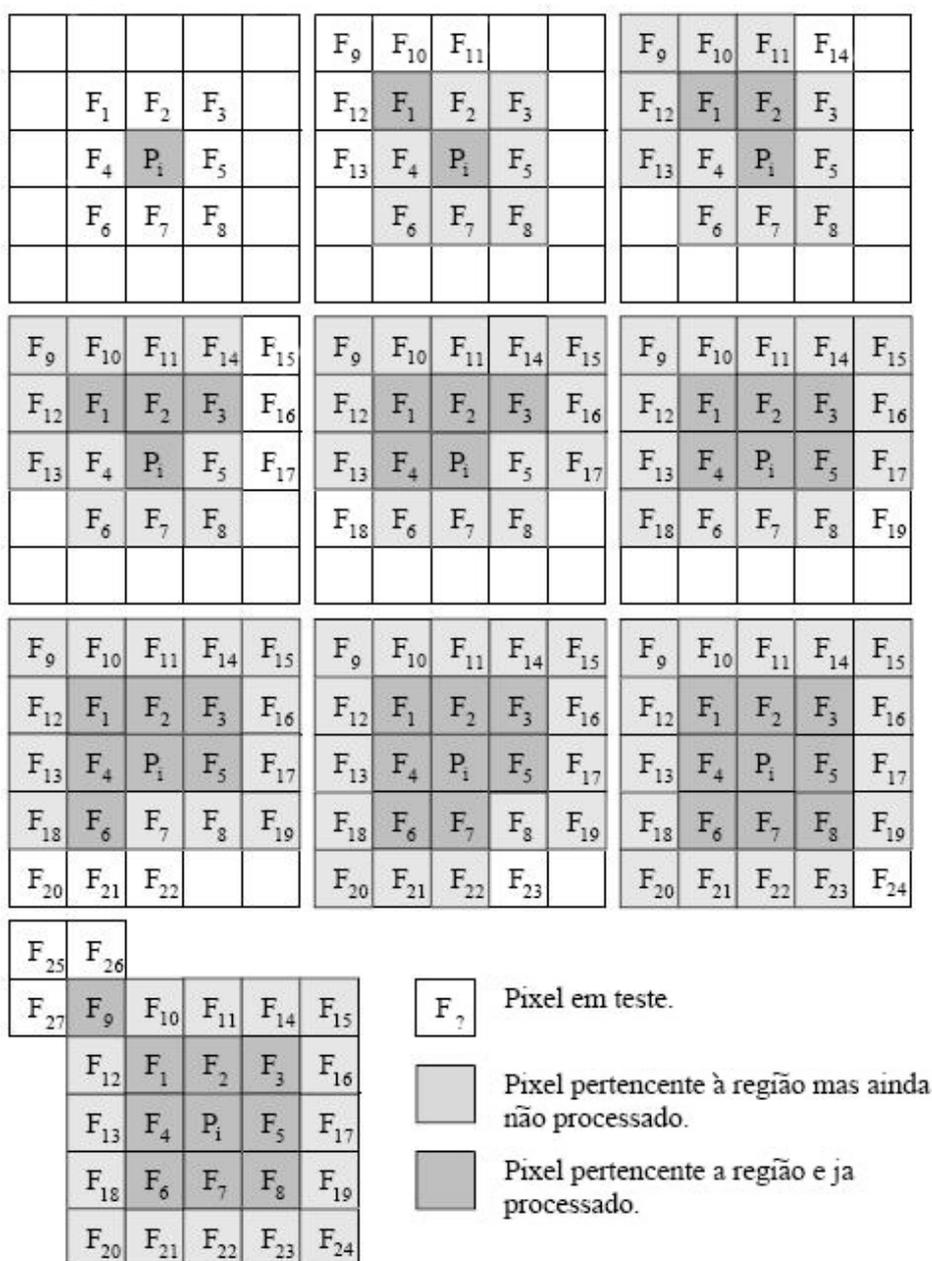


Figura 3.1: Crescimento de Regiões em todas as direções [2].

Crítérios adicionais que agilizam a conversão e melhoram o resultado obtido por este método são: o conceito de tamanho médio das regiões criadas, a semelhança dos pixels candidatos à agregação, não só com as sementes mas também com os outros pixels já dentro da região e o formato das regiões.

Porém, a utilização deste tipo de descritores só é possível quando a natureza do resultado a ser obtido já estiver, pelo menos, parcialmente modelado.

Um exemplo da aplicação de crescimento de região pode ser mostrado na Figura 3.2.

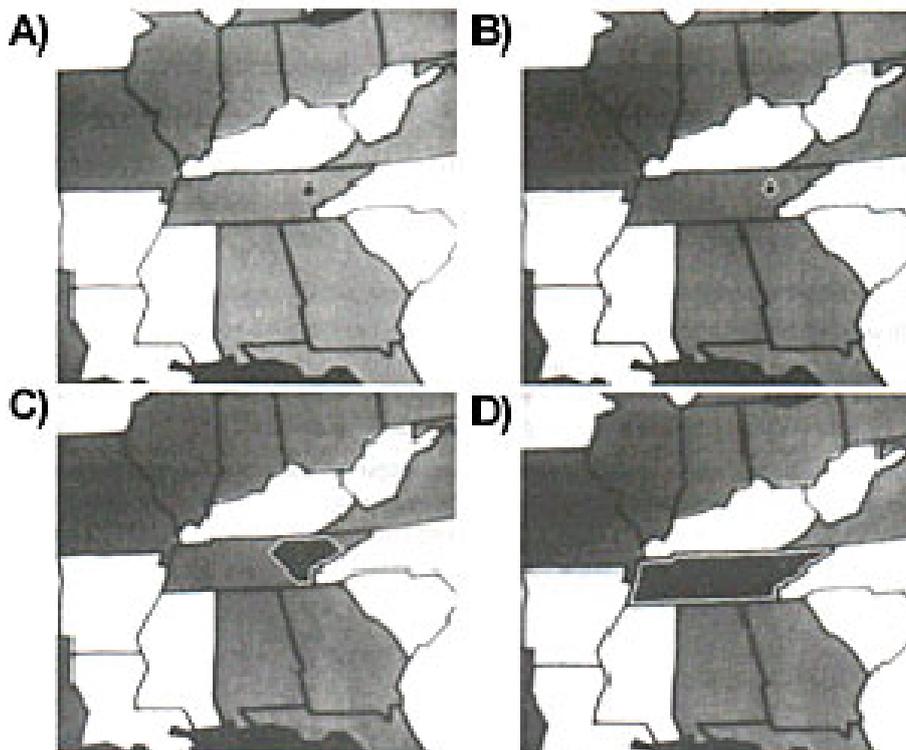


Figura 3.2: Fig 3.2A - Imagem Original mostrando um ponto semente; Fig 3.2B - Estágio primário de crescimento de uma região; Fig 3.2C - Estágio intermediário de crescimento; Fig 3.2D - Região final [2].

3.2 Junção e Separação (*Split & Merge*)

A técnica Junção e Separação é uma alternativa de segmentação baseada em região, que não se utiliza de um conjunto inicial de pontos (sementes) para a resolução do problema [2]. Ela constitui uma combinação de outros dois métodos já conhecidos: a Junção (*Split*) e a Separação (*Merge*).

No esquema de Junção e Separação a imagem original é particionada recursivamente a partir de seu todo, e as novas partições criadas podem ser ocasionalmente fundidas. O objetivo principal é efetuar uma partição da

imagem em regiões homogêneas, começando com uma partição arbitrária, e melhorando sucessivamente a partição por meio de subdivisões e fusões alternadas.

Matematicamente, a técnica de Junção e Separação pode ser descrita como uma técnica de processamento de imagens na qual uma imagem de entrada P representa a região da imagem inteira. O processo de segmentação pode ser visto como um processo que particiona P em 4 sub-regiões, R_1 , R_2 , R_3 , R_4 (quadrantes) se, e somente se, a proposição $P(R_i)$ for falsa (se todos os pixels em R_i não tiverem a mesma intensidade) em algum quadrante, subdivide-se aquele quadrante em um subquadrante, e assim por diante e, por outro lado, duas regiões R_1 e R_2 são fundidas quando $P(R_1 \cup R_2)$ for verdadeira. Por exemplo, a proposição $P(R)$ pode ser verdadeira quando todos os pixels de R tiverem intensidades iguais. Ou, algo mais flexível, quando a variância entre as intensidades deste pixels estiver abaixo de um limite pré-estabelecido T (vale lembrar que se a variância é zero, todos os pixels tem intensidades iguais). Concluindo, o algoritmo se resume nos seguintes passos:

- Primeiramente, irá dividir em quadrantes qualquer região R da imagem P , que satisfaça $P(R_i) = \text{falso}$, isto é se todos os pixels em R_i não tiverem a mesma intensidade;
- Depois irá fundir quaisquer regiões adjacentes R_1 e R_2 da imagem P , que satisfaçam $P(R_1 \cup R_2) = \text{verdadeiro}$;
- Parando quando não mais houver regiões na imagem P que possam ser feita a junção ou separação;

As técnicas em particular de “Separação” tem uma conveniente representação na forma “quadtrees”, nota-se que a raiz da árvore corresponde à imagem inteira e que cada nó corresponde a uma subdivisão. Neste caso, somente R_4 foi subdividida posteriormente, e por sua natureza, possui quatro descendentes para cada nó, como ilustrado na Figura 3.3 e Figura 3.4.

A técnica de Junção e Separação são consideradas computacionalmente “pesadas” se o processo de “separação” for iniciado pela imagem inteira. Por outro lado, se o processo começar com a árvore excessivamente separada (ramificada), onde suas folhas ou ramos são os pontos da imagem, conforme ilustrado na Figura 3.4, podem ocorrer erros devido às medidas da uniformidade de uma região estarem baseadas, inicialmente, apenas em pontos vizinhos. Assim, a técnica de Junção e Separação inicia, normalmente, num estágio intermediário entre estes dois extremos [25].

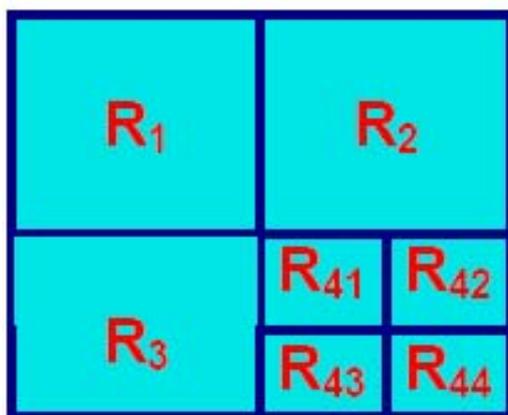


Figura 3.3: Imagem particionada.

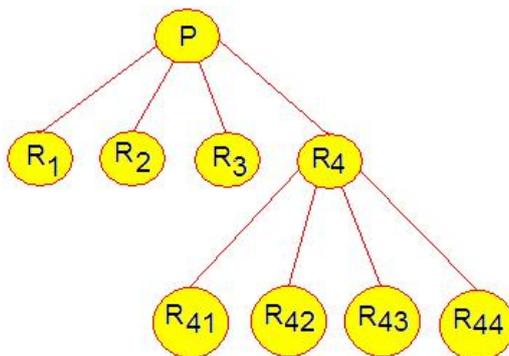


Figura 3.4: Quadtree correspondente a imagem particionada.

3.3 Aglomeração (*Clustering*)

Uma técnica semelhante à de crescimento de regiões é o “clustering”, ou aglomeração [26], [3] e [27]. A diferença principal entre essas técnicas é que a técnica de aglomeração atua sobre o espaço de pontos da imagem, conhecido com espaço de atributos.

Atributo é o nome que se costuma dar a uma medida feita sobre uma imagem. Normalmente, ele é relativo às propriedades ou às medidas de determinados conjuntos de padrões. Essas medidas podem ser relativas a tamanho de objetos na imagem, desvio padrão ou média dos níveis de cinza da imagem ou de regiões da imagem, número de objetos em uma certa região, níveis de cinza de vários espectros de luz, componentes de um sistema de cores (RGB, HSB, etc) e etc.

A imagem da Figura 3.5 mostra um exemplo de como coletar um atributo

usando uma janela de tamanho 1 x 3 pontos com centro no ponto do meio. Se p for o ponto do centro da janela, um exemplo de atributo no ponto p é a média dos níveis de cinza dos pontos vistos pela janela.

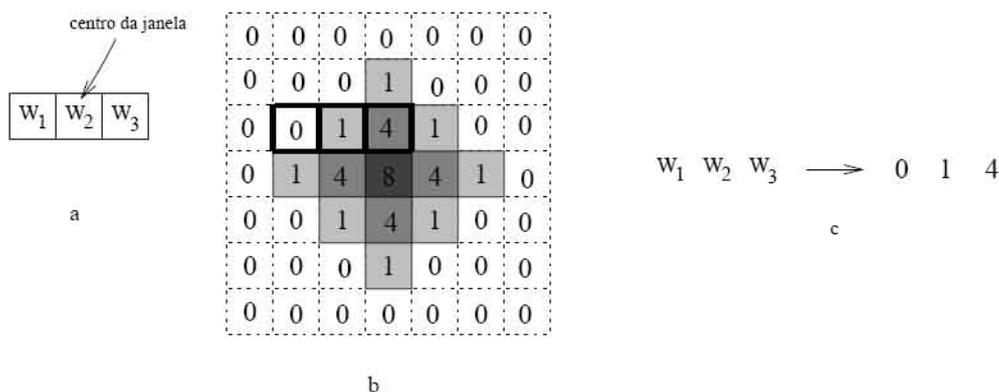


Figura 3.5: Dinâmica da coleta de configurações [3].

Um outro exemplo de atributos que podem ser tomados de maneira semelhante são os níveis de cinza dos pontos da imagem vistos por uma janela quando centrada no ponto p . No caso da Figura 3.5a, para cada ponto p da imagem teremos 3 atributos (W_1 , W_2 , W_3), cujos valores são os níveis de cinza dos pontos da janela.

Um espaço de atributos é um sistema cartesiano em que cada eixo representa um atributo diferente. Dada uma imagem, toma-se um vetor de atributos $u = (u_1; u_2; u_3; \dots; u_n)$ para cada ponto da imagem.

No espaço dos atributos vão estar representados N pontos, $X_1; X_2; \dots; X_N$. O problema de aglomeração é um problema de particionamento do espaço de atributos em um número K de subconjuntos disjuntos. A idéia dessa técnica é que os pontos de um certo objeto ou padrão da imagem devem ter características semelhantes e o conjunto desses pontos formariam, então, um aglomerado (“cluster”), como mostrado na Figura 3.6. Há várias formas de fazer esta aglomeração dos pontos [26], a mais usada parte de um número pequeno de “clusters” (cujos centros tidos são escolhidos dentre os pontos da imagem) e a cada etapa o número de centros vai aumentando com o objetivo de diminuir as distâncias¹ entre os pontos do aglomerado e os novos centros de aglomeração.

Um dos principais problemas do método é saber o número certo de “clusters” para que o resultado da segmentação inicialmente, seja bom. Apresentamos a seguir uma técnica de dois estágios, desenvolvida por Coleman

¹A distância neste caso pode ser a distância usual do espaço cartesiano.

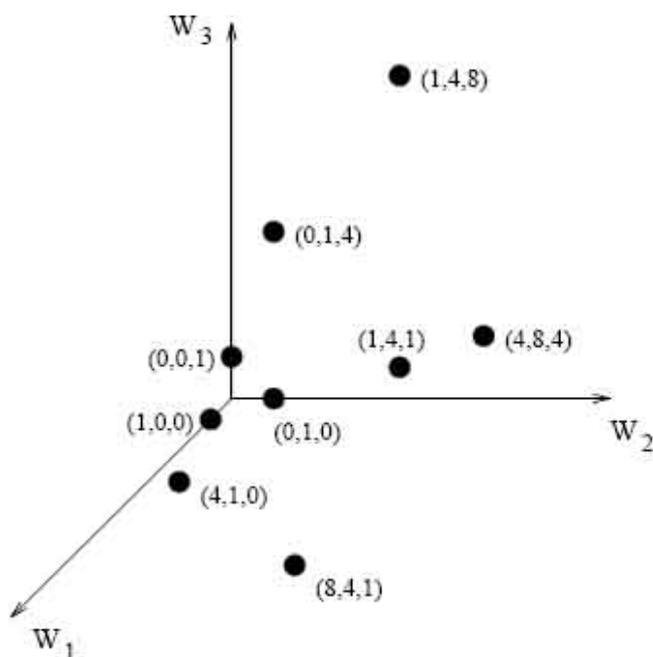


Figura 3.6: Representação de aglomerados em um espaço de atributos [4].

e Andrews [28], que resolve esse problema. No primeiro estágio são computados os vetores de atributos. No segundo estágio, é determinado o número ótimo de núcleos, seus centros e os pontos que os compõem, segundo um critério de proximidade dos centros de aglomeração.

O algoritmo usado para isso tenta, primeiramente, aglomerar todos os N vetores em torno de 2 centros (que podem ser escolhidos ao acaso dentre os N vetores), segundo a distância do vetor ao centro mais próximo dele. Após isso, o número de centros vai aumentando de 1 e um fator de qualidade β vai sendo computado a cada iteração até que ele atinja um valor máximo (que será o número ótimo de aglomerados). A cada próxima etapa, o centro do novo aglomerado a ser criado será o ponto que possui a maior distância ao centro do aglomerado, dentre os aglomerados atuais.

O cálculo do fator de qualidade β é feito da seguinte forma. Sejam

- M o número de pontos a serem aglomerados;
- K o número de aglomerados atual;
- M_k o número de pontos do aglomerado A_k (k -ésimo aglomerado);
- u_i um vetor de características, $1 \leq i \leq N$;

- u_0 o vetor médio de todos os vetores, dado por:

$$u_0 = \frac{1}{M} \sum_{i=1}^M a_i$$

- u_k a média dos vetores de A_k ;
- S_k o conjunto dos elementos de A_k ;
- S_B e S_W , duas matrizes esparsas (intra-grupo(W) *Within* e inter-grupos(B) *Between*, respectivamente) dadas por:

$$S_W = \frac{1}{K} \sum_{k=1}^K \frac{1}{M_k} \sum_{x_i \in S_k} [u_i - u_k][u_i - u_k]^T$$

$$S_B = \frac{1}{K} \sum_{k=1}^K [u_k - u_0][u_k - u_0]^T,$$

onde u^T é o vetor transposto de u . Finalmente,

$$\beta = tr[S_W]tr[S_B],$$

onde tr é o traço da matriz.

Após aglomerados, os diversos “clusters” formam segmentos da imagem. A aglomeração é uma conhecida técnica de reconhecimento de padrões, mais especificamente uma técnica de “aprendizado” não supervisionado [26] que é usada para a solução de diversos problemas em Processamento de Imagens. A parte heurística de um processo de segmentação por aglomeração consiste na escolha das medidas que serão feitas na imagem. O restante do processo é, geralmente, estatístico.

Capítulo 4

Limiarização (*Thresholding*)

A limiarização é o método mais simples, rápidos, intuitivo e possuem uma literatura extensa na segmentação de imagens. Segundo [29], a imagem de um objeto pode ser compreendida como uma região formada por pixels contíguos que tenham a faixa de intensidades em comum. Basicamente todos os pixels que estão dentro de uma faixa de intensidade são classificados como pertencentes à mesma região.

Matematicamente, a operação de limiarização é descrita como uma técnica de processamento de imagens na qual uma imagem de entrada $f(x, y)$ de N níveis de cinza produz como saída uma imagem $g(x, y)$, chamada de imagem limiarizada, cujo número de níveis de cinza é menor que N . Normalmente, $g(x, y)$ apresenta 2 (dois) níveis de cinza que podem ser calculados, por exemplo, utilizando a Equação 4.1.

$$g(x, y) = \begin{cases} 0, & f(x, y) \geq T \\ 1, & f(x, y) < T \end{cases} \quad (4.1)$$

Os pixels rotulados com 1 correspondem aos objetos, os pixels rotulados com 0 correspondem ao fundo e T é um valor predefinido de tom de cinza denominado limiar. Neste caso temos a limiarização simples. Caso se tenha dois limiares ou mais, temos a limiarização múltipla [25], uma limiarização múltipla, que aceita dois limiares T_1 e T_2 , pode ser definida, por exemplo, pela Equação 4.2.

$$g(x, y) = \begin{cases} 0 & T_1 \leq f(x, y) \leq T_2 \\ 1 & \text{Restante} \end{cases} \quad (4.2)$$

O processo baseia-se na análise do histograma da imagem, que pode ser definido por um gráfico que mostra o número de pontos de uma imagem que

possui o mesmo tom de cinza [30]. Na abscissa temos os níveis de cinza enquanto na ordenada temos a quantidade de pontos. Uma imagem digitalizada pode ser representada por uma matriz. Cada ponto da matriz representa um ponto da imagem e contém o valor do tom de cinza desse ponto, ou seja, a intensidade luminosa do ponto.

Quando o histograma possui um vale, como na figura 4.1, é possível escolher o limiar como sendo o valor mínimo da curva do histograma. Caso haja mais de um vale tem-se o que a literatura chama de múltiplos limiares, ilustrado na Figura 4.2. Uma limiarização com um único limiar de separação (binarização), pode ser ilustrado pela Figura 4.3.

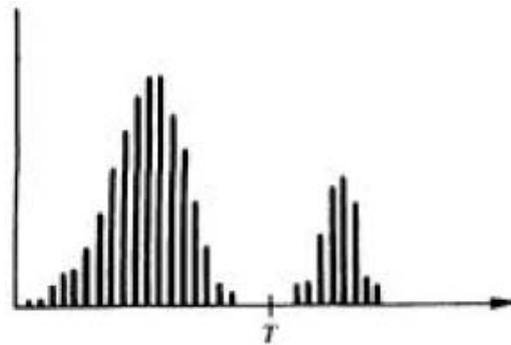


Figura 4.1: Histogramas de níveis de cinzas com um único limiar.

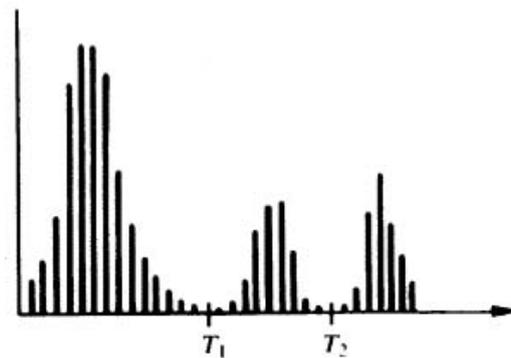


Figura 4.2: Histogramas de níveis de cinzas com múltiplos limiares.

A limiarização pode ser aplicada a imagens que geralmente possuam áreas homogêneas sob um plano de fundo uniforme. Um exemplo de aplicação para a limiarização binária seria a extração de texto da imagem digitalizada de uma página.

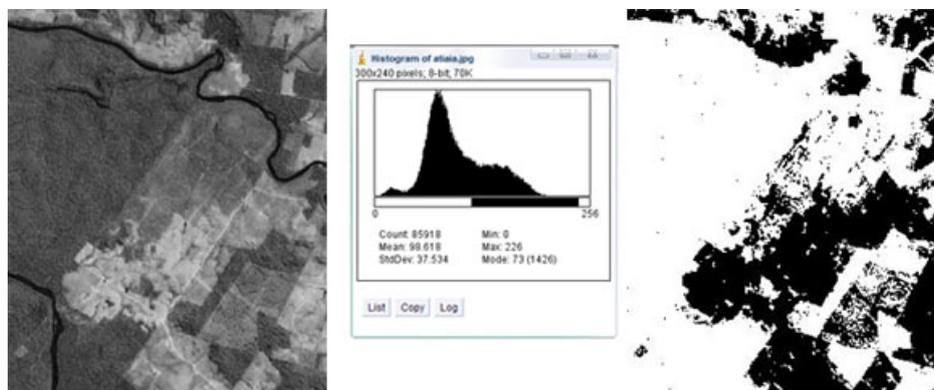


Figura 4.3: Exemplo de uma limiarização com um único limiar de separação (binarização) .

Existem varias técnicas para se determinar os valores de corte no histograma. Uma delas é a própria seleção manual, baseada no melhor resultado obtido após o teste com vários valores por parte do usuário. Dentre as técnicas automáticas, a mais tradicional, e também a mais intuitiva, baseia-se na detecção dos pontos de mínimo do histograma da imagem (vales) [31].

A desvantagem dessa técnica, que trabalha o histograma com a limiarização, é que a mesma não soluciona todos os problemas de segmentação, pois não leva em consideração, por exemplo, a forma dos objetos na imagem, isto é, dois objetos de formatos diferentes não podem ser diferenciados usando-se esta técnica, que também não funciona perfeitamente em imagens com iluminação não uniforme e com baixo contraste entre as diversas regiões. Outro fator desfavorável encontra-se no fato de que muitas vezes os vales são longos e planos, tornando a escolha do limiar uma busca aleatória. Também, é possível que os vales assumam valores muito baixos, o que proporciona ao método uma sensibilidade maior aos ruídos.

A técnica de Otsu [2], por exemplo, é conhecida como a mais confiável das técnicas automáticas para escolhas dos níveis de corte, baseado no histograma, dentre outras, como o método de Entropia Máxima. Esses dois métodos serão apresentados na seção a seguir, pois foram utilizados para a escolha do melhor limiar no software desenvolvido.

4.1 Métodos de Limiarização

A forma mais comum de passar uma imagem em níveis de cinza a uma imagem binária (2 tons) é selecionar um limiar. Todos os pixels cujos níveis de cinza estejam ao fundo (*background*) se classificarão como se fossem pixels

preto (0) e os que estejam à frente (*objeto*), brancos (1).

As técnicas utilizadas para selecionar este limiar costumam ser de tipo estatístico e podem aplicar-se a outro tipo de problemas (como subdividir um conjunto dado de valores numéricos em dois intervalos). Todas as técnicas aqui descritas utilizam o histograma para selecionar o valor do limiar.

4.1.1 Método de Otsu

O método de Otsu elege o limiar ótimo maximizando a variância entre classes (between - class variance) mediante uma busca exaustiva. Há diferentes métodos para achar o limiar, a maioria deles não dão bons resultados quando se trabalha com imagens do mundo real devido à presença de ruído, histogramas planos ou uma iluminação inadequada [32]. Pelo contrário, o método de Otsu foi um dos melhores métodos de seleção do limiar para imagens do mundo real. No entanto, este método usa uma busca exaustiva para avaliar o critério para maximizar a variância entre classes. À medida que o número de classes de uma imagem aumenta, o método de Otsu precisa bem mais tempo para selecionar o limiar multi-nível adequado [2].

A importância do método de Otsu está na forma automática de encontrar o limiar, isto é, não precisa supervisão humana nem informação prévia da imagem antes de seu processamento.

O método Otsu, como foi dito, se baseia na escolha do valor de corte que maximize a medida de variância entre duas partes do histograma separados por um mínimo local, ou seja, encontrar T que minimize a função:

$$f(T) = q_1(T)\delta_1^2(T) + q_2(T)\delta_2^2(T) \quad (4.3)$$

onde:

- $q_1(T)$ é o número de pixels cuja intensidade é menor que T ;
- $q_2(T)$ o número de pixels com intensidade superior a T ;
- $\delta_1^2(T)$ variância dos pixels cuja intensidade é menor que T ;
- $\delta_2^2(T)$ variância dos pixels cuja intensidade é maior que T ;

O método de Otsu é extremamente custoso do ponto de vista computacional, tornando-se praticamente inviável para imagens cujo histograma possua mais que quatro mínimos locais. Uma outra opção é denominada Otsu recursivo. Nesta técnica, o método de Otsu simples (para duas partes apenas do histograma, separados por um mínimo local) é aplicado continuamente à imagem, sendo que a cada iteração parte da imagem já segmentada é desconsiderada, aplicando-se novamente o método para os pixels restantes [2].

4.1.2 Método de Entropia Máxima

O conceito de entropia foi introduzido há mais de 150 anos na ciência, mas somente a partir do século XX é que se difundiram suas aplicações por diversas áreas do conhecimento áreas, como termodinâmica, estatística, probabilidade, reconhecimento de padrões, economia, marketing, planejamento urbano e de transportes, dentre outras [33]. Foi originária do estudo da termodinâmica, em que foi introduzida para distinguir o grau de desordem de um sistema. Na teoria da informação a entropia corresponde à *dúvida probabilística* junto a uma distribuição de probabilidade. Cada distribuição reflete um certo grau de dúvida e diferentes graus de dúvida estão associados a diferentes distribuições [34].

A interpretação empírica da entropia é baseada nas propriedades de longas seqüências geradas pela repetição de um acontecimento aleatório. Este fato conduz à noção de seqüência típica e oferece, a nosso entender, a melhor justificação do método da entropia máxima.

Numa experiência registram-se N acontecimentos distintos $A_i, i = 1...N$, com probabilidade p_i , respectivamente. Vamos construir uma partição $A = A_1, \dots, A_N$ formada pelos N acontecimentos A_i e definimos a seguinte soma

$$H(A) = - \sum_{i=1}^N p_i \log p_i, p_i = P(A) \quad (4.4)$$

A esta soma chamamos *entropia* da partição A . A entropia é um numero associado a uma partição tal como a probabilidade é um numero associado a um acontecimento. É usado para completar a especificação de um modelo parcialmente conhecido não em termos das observações mas de um *princípio*.

O método da máxima entropia nos permite selecionar a solução que dá a maior entropia, o que significa determinar a distribuição de probabilidade que represente o máximo de incerteza, dadas certas restrições, ou seja, determinar a distribuição com maior grau de similaridade entre suas probabilidades, ou que seja mais parecida com a uniforme e diferindo dela apenas devido às restrições. O método da máxima entropia é usado numa grande variedade de problemas físicos e em muitos casos os resultados estão de acordo com as observações.

Capítulo 5

Desenvolvimento

No desenvolvimento, um dos primeiros passos do processo de análise de uma imagem de satélite consiste em particioná-la em seus elementos constituintes. A segmentação é o processo em subdividir a imagem em objetos constituintes [2]. Neste trabalho a segmentação é utilizada com a finalidade de separar a região da imagem referente à pastagens degradadas das demais áreas.

Entretanto, o processo de segmentação de imagens de satélite para detecção de pastagens degradadas, não se constitui uma tarefa tão simples. Vários fatores, característicos dessas imagens, tornam tal tarefa difícil de ser realizada com sucesso em todas as imagens. Dentre esses fatores, pode-se citar a dificuldade que há em distinguir a região de pastagens degradadas, das regiões de pastagens em processo de regeneração ou em processo de degradação ao seu redor. Em muitas imagens de satélite analisadas, as regiões em processo de regeneração ou em processo de degradação, próximas às regiões de pastagens degradadas, misturam-se gradativamente com o interior das regiões em processo de regeneração ou em processo de degradação, sendo que nesses casos, torna-se difícil determinar com precisão a sua área.

Para o desenvolvimento da pesquisa foram adquiridas as imagens de satélites e efetuada a segmentação, para isso foram utilizados dois algoritmos de limiarização para determinar o melhor limiar, também foi utilizado o algoritmo de abertura no processo de segmentação para melhorar a imagem.

Os modelos de segmentação que foram analisados neste trabalho baseiam-se em algoritmos que operam sobre imagens em tons de cinza, ou intensidade. Os algoritmos para segmentação de imagens em tons de cinza são bem mais simples, rápidos e possuem uma literatura extensa, motivos pelos quais foram adotados neste trabalho. Embora as imagens de satélite utilizadas sejam coloridas, os algoritmos não serão aplicados diretamente sobre elas, mas em determinados canais que as compõem. Foi constatado, que para esta pesquisa o canal de níveis de cinza ideal para segmentar as imagens de satélite foi

o canal de saturação do modelo HSI, pois neste foi observado, através de experimentos com 3 cortes de imagens de satélite, uma grande diferenciação no valor dos pixels nas regiões de interesse. Essa variação é decorrente das características da própria superfície das pastagens degradadas. Dependendo do aspecto de cada objeto em cena, sua superfície pode apresentar uma aparência mais brilhante ou mais opaca; que é o caso do pasto bom.

Este capítulo, será mostrado os algoritmos de segmentação utilizados para fazer a análise do melhor limiar, mostrado o desenvolvimento do *software* e o algoritmo de abertura, que foi utilizado para melhorar a imagem após a binarização.

5.1 Algoritmos de Segmentação

Foram avaliados neste trabalho dois algoritmos de limiarização: método de otsu e método da máxima entropia, para a determinação do limiar a ser utilizado.

5.1.1 Método de Otsu

No método de otsu, a segmentação de uma imagem em tons de cinza para uma imagem binária é considerada como um problema de classificação, em que as classes são geradas a partir do conjunto de pontos contidos na imagem [2]. As classes foram formadas por níveis de cinza iguais, menores ou maiores que o limiar encontrado pelo método.

O método de otsu foi empregado para realização dos testes para saber qual limiar seria utilizado para a criação das classes. O algoritmo de Otsu utilizado nesta pesquisa foi de autoria de Christopher Mei, Anthony Joshua e Tony Collins, que foi adquirido da página oficial do ImageJ (<http://rsb.info.nih.gov/ij/>) no link *Plugins*. O algoritmo é apresentado no Algoritmo 5.1. Este método foi o que apresentou o limiar mais semelhante com o limiar escolhido manualmente, para a formação da classe da floresta, que será discutida na 5.2.

5.1.2 Método da Máxima Entropia

O método de máxima entropia é muito popular no caso de uma limiarização de dois níveis. Mas é computacionalmente caros quando estendidos à limiarização de vários níveis, pois a busca é exaustiva.

O método da máxima entropia é um técnica de limiarização automática baseada na entropia máxima do histograma [35]. O método foi empregado

Algorithm 5.1 Otsu (imagem_gray)

```
1: hist  $\leftarrow$  histograma(imagem_gray);
2: para  $k = 1$  to 255 faça
3:    $p1 \leftarrow Px(0, k)$ ;
4:    $p2 \leftarrow Px(k + 1, 255)$ ;
5:    $p12 \leftarrow p1 * p2$ ;
6:   se  $p12 == 0$  então
7:      $p12 = 1$ ;
8:   fim se
9:    $vet[k] \leftarrow pow((Mx(0, k) * p2) - (Mx(k + 1, 255) * p1), 2) / p12$ ;
10:  se  $p1 == 0$  então
11:     $p1 = 1$ ;
12:  fim se
13:   $a[k] \leftarrow Mx(0, k) / p1$ ;
14:  se  $p2 == 0$  então
15:     $p2 = 1$ ;
16:  fim se
17:   $b[k] \leftarrow Mx(k, 255) / p2$ ;
18: fim para
19:
20:
21: threshold  $\leftarrow$  maior(vet);
22: t  $\leftarrow$  threshold;
23:
24:
25: para  $y = 0$  to Image.altura faça
26:    $pt[x] \leftarrow$  Image_linha (y);
27:   para  $x = 0$  to Image.largura faça
28:     se  $pt[x] < threshold$  então
29:        $pt[x] \leftarrow 0$ ;
30:     senão
31:        $pt[x] \leftarrow 255$ ;
32:     fim se
33:   fim para
34: fim para
```

para realização dos experimentos para saber qual limiar seria utilizado para a criação das classes. O algoritmo da máxima entropia utilizado nesta pesquisa é de autoria dos próprios desenvolvedores do ImageJ e foi adquirido da página do sourceforge.net (<http://ij-plugins.sourceforge.net/>).

5.2 Software Desenvolvido

Foi desenvolvido um software em java para um plugin no ImageJ (*Image Processing and Analysis in Java*), em que a finalidade é fazer a segmentação de imagens de satélite para detecção de degradação de pastagens. Optou-se em fazer um plugin para o ImageJ, por ser um bom manipulador de imagens, com a facilidade de implementações de novas funções, porque ele é disponibilizado gratuitamente pela internet e seu código fonte é totalmente aberto, além de possuir várias ferramentas implementadas para processamento de imagens. O acesso às imagens é feito diretamente por uma camada intermediária, que cria um acesso de alto nível aos pixels e demais informações da imagem [11]. Na implementação utilizou-se a ferramenta de desenvolvimento Net Beans 4.1 ¹, com o Java Development Kits 1.5.05 ².

Na implementação do software de segmentação foi utilizada a técnica de limiarização, e para isso foi ideal que cada região obtida no resultado estivesse diretamente relacionada com um objeto real contido na imagem, por isso, as imagens de satélites foram transformadas para o modelo de cor HSI. Na transformação do modelo de cor RGB para HSI, não foram utilizados métodos de conversão que resultariam em uma única imagem, isto é, uma imagem contendo os 3 (três) canais, mas um método que resultou em 3 (três) imagens em tons de cinza, uma imagem com a matiz (H), outra com saturação (S) e a última com intensidade (I). Para a determinação das classes foi utilizada a imagem de saturação (S).

Foram implementadas 2 (duas) funções, em que são definidas as classes. A classe de pasto bom é a classe em que está contida as pastagens sem degradação, que são as pastagens desenvolvidas e a classe da floresta é a classe em que está contida a floresta amazônica. A classe do pasto bom foi definida com um limiar menor que 125, que foi definida manualmente a partir de observações feita utilizando o ImageJ e a classe floresta com o limiar maior que 182, foi definida pela média da análise do método de Otsu, utilizando 3 (três) cortes de imagens de satélite. Essas funções retornam imagens binarizadas. As imagens binarizadas passam pelo algoritmo de abertura, a partir daí, é feita uma subtração de imagens da classe do pasto bom com a imagem da

¹<http://www.netbeans.org/>

²<http://www.java.com/>

classe da floresta, o resultando é uma imagem binarizada resultando a pastagem degradada. A imagem binarizada resultante é enviada para uma função implementada, cuja função é marcar a pastagem degradada na imagem de satélite com o sistema de cor RGB em azul (0,0,255). A implementação é mostrada no Algoritmo 5.2.

Algorithm 5.2 Segmentação_de_Pastagem (Imagem_Satelite)

```

1: largura  $\leftarrow$  Pega_largura (Image_Recebida);
2: comprimento  $\leftarrow$  Pega_comprimento (Image_Recebida);
3: Image_Saturação  $\leftarrow$  Função_Img_Saturação(largura,comprimento);
4: Image_Bin_Pasto_BOM  $\leftarrow$  Função_Img_Pastobom (Image_Saturação);
5: Abertura (Image_Bin_Pasto_BOM);
6: Image_Bin_Floresta  $\leftarrow$  Função_Img_Floresta (Image_Saturação);
7: Abertura (Image_Bin_Floresta);
8: Image_Bin_Degradação = Image_Bin_Pasto_BOM - Image_Bin_Floresta;
9: Image_Resultante  $\leftarrow$  Função_Marca_Degradação
   (Image_Recebida,Image_Bin_Degradação);

```

O código implementado está disponibilizado na página da subversion do grupo de pesquisa GPEC da Universidade Católica Dom Bosco (UCDB).

5.3 Algoritmo de Abertura (*Opening*)

Após a limiarização, determinados objetos da imagem resultante, os quais geralmente situam-se em regiões próximas as pastagens degradadas, se sobreponham sobre sua área. Essa sobreposição deve-se a pequenas regiões de pixels, ao redor das pastagens degradadas, que possuem intensidade, ou níveis de cinza, próximos ao da pastagem degradada. Essa sobreposição de objetos deve ser eliminada, uma vez que apenas as áreas de pastagens degradadas são de interesse. Para fazer a eliminação total, ou parcial de tal sobreposição, é utilizado o algoritmo de abertura (*Opening*) [36], [37], [38] e [39] que é uma combinação dos algoritmos de erosão e dilatação, aplicados nessa seqüência. Os algoritmos de erosão e dilatação são considerados duas operações básicas da morfologia matemática. A morfologia matemática é a ciência da estrutura e da forma [36]. Em visão computacional, o algoritmo de abertura está relacionado com regiões e formas, de como elas podem ser modificadas e contadas, e como suas áreas podem ser avaliadas. A morfologia matemática pode ser consultada de uma forma mais profunda em [40].

O Algoritmo de erosão tem a função de remover pixels das regiões que se localizam nas bordas dos objetos. Assim a área das regiões do primeiro

plano diminuem de tamanho e as falhas ou “buracos” dentro desta região aumentam.

As operações de erosão e dilatação foram realizadas utilizando um elemento estruturado com uma dimensão 3 x 3. Os valores destes elementos são fatores também importantes para realização da operação. Neste caso os valores representam as intensidades que terão os objetos na imagem. O valor para o fundo (*background*), é representado por 0.

Na operação de erosão é comparado cada elemento da estrutura com os pontos coincidentes da imagem. Assim, se pelo menos um dos pontos não coincidir, o ponto comparado é substituído pelo valor 0. Na operação de dilatação ocorre o contrário: se pelo menos um dos pontos coincidir com o valor do elemento da estrutura, o ponto comparado é substituído pelo valor 255, que representa o valor na imagem limiarizada. A operação de abertura é ilustrada na Figura 5.1, em que na Figura 5.1a mostra-se uma imagem de satélite antes da operação de abertura e na Figura 5.1b mostra-se a imagem após a operação de abertura.

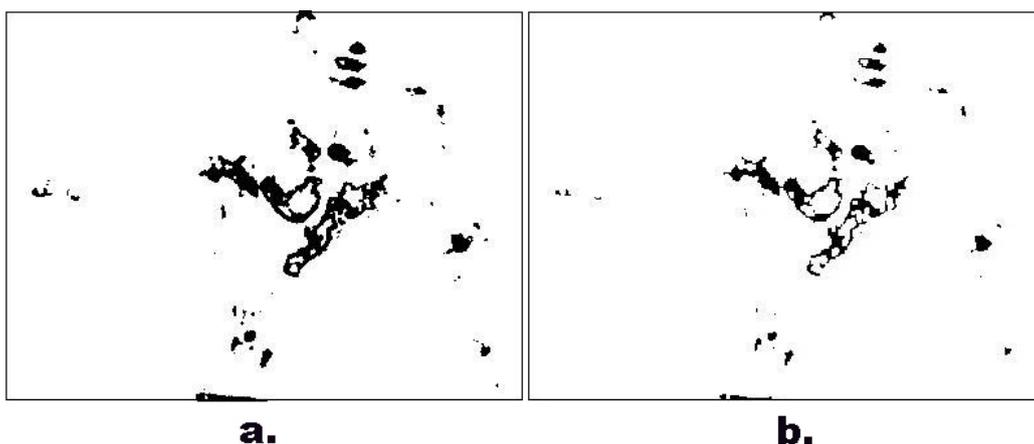


Figura 5.1: Figura 5.1a mostra uma imagem de satélite antes da operação de abertura e Figura 5.1b mostra a imagem após a operação de abertura.

Os algoritmos de erosão e dilatação foram utilizados do próprio ImageJ, e são ilustrados abaixo pelo Algoritmo 5.3 e Algoritmo 5.4, respectivamente e o algoritmo de abertura é ilustrado pelo Algoritmo 5.5.

Algorithm 5.3 Erosão (imagem_binarizada)

```
1:  $n \leftarrow$  numero de pixels em imagem_binarizada;  
2: para todos  $y$  faça  
3:   para todos  $x$  faça  
4:     Pixels da contagem na interseção da imagem_binarizada (  $x$  ,  $y$  );  
5:     se esse número é mais grande do que  $n$  então  
6:       Ponha o pixel preto;  
7:     senão  
8:       Ponha o pixel branco;  
9:     fim se  
10:  fim para  
11: fim para
```

Algorithm 5.4 Dilatação (imagem_binarizada)

```
1: para todos  $y$  faça  
2:   para todos  $x$  faça  
3:     Pixels da contagem na interseção da imagem_binarizada (  $x$  ,  $y$  );  
4:     se esse número é mais grande do que 1 então  
5:       Ponha o pixel preto;  
6:     senão  
7:       Ponha o pixel branco;  
8:     fim se  
9:   fim para  
10: fim para
```

Algorithm 5.5 Abertura (imagem_binarizada)

```
1: Erosão (imagem_binarizada);  
2: Dilatação (imagem_binarizada);
```

Capítulo 6

Experimentos e Análise de Resultados

Neste capítulo serão mostrados os experimentos realizados e serão avaliados os algoritmos de limiarização abordados no capítulo 5. A avaliação é obtida comparando-se as imagens segmentadas, com as mesmas imagens segmentadas manualmente [41] e [42]. É avaliado o desempenho dos algoritmos de limiarização, para saber qual o limiar seria utilizado para formação das classes. É também avaliado o índice de desempenho para a realização da escolha do canal de intensidade utilizado na segmentação. Essa medição é realizada segmentando-se os seis canais, RGB e HSI, de uma mesma imagem, utilizando o algoritmo de segmentação desenvolvido, e comparando cada canal segmentado com a mesma imagem segmentada manualmente.

6.1 Experimentos Realizados

Para a realização dos experimentos foram utilizadas imagens de satélite que serão mostrados na Seção 6.1.1, na Seção 6.2.1 os algoritmos de limiarização foram avaliados e para a escolha do melhor canal a ser utilizado na segmentação foi verificada a taxa de menor erro entre os seis canais dos sistemas de cor RGB e HSI, utilizando a métrica que será tratada na Seção 6.1.2.

Na realização dos experimentos também foram utilizados uma estação de trabalho Athlon 64 com CPU de 3400+, memória RAM de 1 Giga bytes, disco rígido de 80 G bytes e sistema operacional Windows XP SP2 e os softwares utilizados foram o ImageJ, o NetBeans 4.1 com o pacote Java ¹ JDK 1.5.0.05, para desenvolvimento do algoritmo e PhotoShop 7.0² para modificação das

¹Linguagem de programação orientada a objetos

²<http://www.adobe.com/products/photoshop/>

imagens para fazer a comparação entre a manual e a automática.

6.1.1 Aquisição das Imagens de Satélites e Amostras Utilizadas

As aquisições das imagens de satélite utilizadas nesta pesquisa foram feitas do satélite CBERS-2, na escala 1:500.000, em virtude da realidade do mercado brasileiro, da escassez de recursos financeiros e da necessidade de uma base de dados confiável tanto em qualidade quanto em quantidade. A escolha destas imagens foi pela facilidade de obtenção, pois no site do INPE (<http://www.dgi.inpe.br>) encontram-se à disposição da sociedade brasileira gratuitamente as imagens de todo o território nacional, bastando fazer um breve cadastro.

A empresa FLORAMAP - Projetos, Consultorias e Mapeamentos Ltda., situada em Cuiabá/MT, tratou as imagens e as referenciou, pois as imagens disponibilizadas no INPE são divididas em bandas e de forma bruta. As imagens de satélites não foram utilizadas no seu tamanho integral, pelo seu imenso tamanho tornando-se extensa sua análise e além do mais precisaria de máquinas mais potentes que as disponibilizadas no mercado para usuários padrão, que são o alvo principal do futuro desta pesquisa. Foram então utilizados pequenos cortes das imagens de satélite, destacando as regiões da floresta amazônica, sendo que cada corte representa uma fazenda da região.

Para realizar os experimentos foram utilizados 5 (cinco) cortes de imagens de satélite, como foi dito anteriormente, de regiões da floresta amazônica, pois assim não é possível existir áreas de cerrado, que são definidas como extensos chapadões cobertos por uma vegetação de pequenas árvores retorcidas, no meio a um tapete de pastagens, que durante a maior parte do tempo são amareladas e secas ³. Essas áreas não foram utilizadas nesta pesquisa, pois quando observadas nas imagens de satélite, utilizando os sistemas de cores, não é possível diferenciar as pastagens degradadas das pastagens do cerrado. A pastagem de cerrado pode ser observada na Figura 6.1.

6.1.2 Métrica Utilizada para a Avaliação da Segmentação

Para a determinação do sucesso do algoritmo de segmentação, foi utilizada uma métrica que mede o acerto da segmentação em relação à área que deveria ser segmentada na imagem. A área que deveria ser segmentada na imagem foi determinada manualmente por um engenheiro especializado.

³<http://www.cnpma.embrapa.br/>



Figura 6.1: Foto tirada da área de cerrado, para observação da cor da pastagem (<http://www.cnpma.embrapa.br/>).

Considere A_{ij} a imagem contendo a pastagem degradada segmentada manualmente, e B_{ij} a imagem segmentada pelo algoritmo desenvolvido. A_{ij} e B_{ij} são ambas imagens binárias onde 0 = fundo e 1 = pastagem degradada (na prática a pastagem degradada é representada por 255). A Equação 6.1 é utilizada para calcular o erro da segmentação. Na Equação 6.1 o símbolo \otimes refere-se ao operador **OU Exclusivo** [42].

$$Erro = \frac{area(A_{ij} \otimes B_{ij})}{area(A_{ij})} \quad (6.1)$$

Utilizando essa definição, o resultado da Equação 6.1 será 0, se as imagens forem exatamente iguais, ou 1 no caso da imagem segmentada ser totalmente diferente.

6.2 Resultados Obtidos e Análise

Nesta seção estão descritos os resultados e discussões obtidos da avaliação dos algoritmos de limiarização, e os resultados e discussão da escolha do melhor canal a ser utilizado e do algoritmo desenvolvido.

6.2.1 Avaliação dos Algoritmos de Limiarização

Para determinar as classes para o algoritmo de segmentação desenvolvido, foi avaliado qual obteria o melhor limiar entre os algoritmos de limiarização apresentados - método de otsu e método da máxima entropia. A avaliação foi realizada a partir da observação visual do engenheiro especializado, na imagem de satélite resultante do algoritmo desenvolvido para segmentação. Entre os algoritmos avaliados o que apresentou o melhor limiar foi o algoritmo de Otsu.

Para avaliação das técnicas, foram utilizados 3 (três) cortes de imagens de satélite. Na Tabela 6.1 são ilustrados os valores resultantes dos experimentos efetuados para cada corte processado. O limiar escolhido foi 182, que se refere a média entre os 3 (três) cortes.

Técnicas	Fazenda Rio do Sangue	Fazenda Agrotep	Fazenda Atiaia	Média do Tempo/ms
Método de Otsu	187	179	182	2,51
Método da Máxima Entropia	174	169	171	1,95

Tabela 6.1: Tabela para avaliação do melhor limiar a ser utilizado para o algoritmo de segmentação desenvolvido.

6.2.2 Resultados e Discussão da Escolha do Melhor Canal e do Algoritmo Desenvolvido

Para verificar o desempenho do canal a ser utilizado, 3 (três) cortes de imagens de satélite foram processadas e o canal sugerido para segmentação foi o canal de saturação do sistema de cor HSI, pois esse obteve o menor erro de segmentação. Além deste canal a imagem foi segmentada pelos demais cinco canais restantes. A taxa de erro referente a cada canal segmentado em relação à imagem segmentada manualmente, foi calculada com o objetivo de mostrar com clareza porque foi escolhido o canal de saturação. As Tabelas 6.2, 6.3 e 6.4, correspondente respectivamente a fazenda Rio do sangue, Figura 6.2, a fazenda Agrotep, Figura 6.5, e a fazenda Atiaia, Figura 6.4, que ilustram os valores resultantes dos cálculos efetuados para cada canal processado, destacando o canal escolhido, feito a comparação dos resultados da segmentação de cada canal em relação à imagem segmentada manualmente. Os resultados demonstram que o canal selecionado é o que obteve menor erro de segmentação nas imagens utilizadas.

Canal	Erro Medido	Tempo/ms
R	0,96653205156326	1,52
G	0,81487192677094	1,42
B	0,56572593596724	1,51
H	0,79821286732807	1,53
S	0,12908873498439	1,62
I	0,83807439565757	1,53

Tabela 6.2: Taxa de erro dos seis canais segmentados do corte feito da imagem de satélite da Fazenda Rio do Sangue, utilizando o algoritmo desenvolvido, em relação à mesma imagem segmentada manualmente, em que o canal de saturação obteve o menor erro na segmentação.

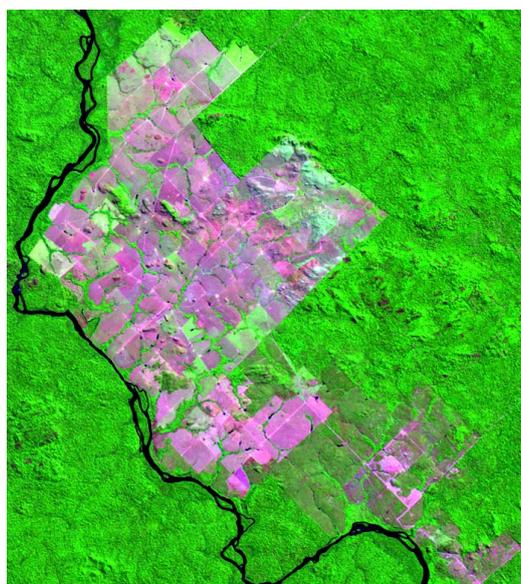


Figura 6.2: Fazenda Rio do Sangue.

Os resultados obtidos com o algoritmo desenvolvido podem ser observados nas fases que serão descritas abaixo, conforme o desenvolvimento do algoritmo.

1. Primeiro obtemos a imagem de entrada, conforme o exemplo da Figura 6.5.
2. A imagem é transformada em HSI, escolhendo apenas a imagem saturada (S), conforme o exemplo da Figura 6.6.

Canal	Erro Medido	Tempo/ms
R	0,999999999999999	1,47
G	0,65960396869446	1,51
B	0,56601046694024	1,44
H	0,999999999999999	1,33
S	0,22093104362488	1,22
I	0,77812742233276	1,61

Tabela 6.3: Taxa de erro dos seis canais segmentados do corte feito da imagem de satélite da Fazenda Agrotep, utilizando o algoritmo desenvolvido, em relação à mesma imagem segmentada manualmente, em que o canal de saturação obteve o menor erro na segmentação.



Figura 6.3: Fazenda Agrotep.

3. Utilizando a técnica de limiarização, obtemos a imagem binarizada do pasto bom com o limiar menor que 125 na Figura 6.7 e a imagem binarizada da floresta com o limiar maior que 180 na Figura 6.8.
4. Após obtermos a imagem binarizada do pasto bom e da floresta foi aplicado o algoritmo de abertura, para uma melhor definição de cada classe.
5. As pastagens degradadas foram resultantes da subtração da imagem binarizada da floresta com a imagem binarizada do pasto bom, conforme a Figura 6.9.
6. E por último obtivemos a imagem de entrada com a apresentação das pastagens degradadas, conforme a Figura 6.10.

Canal	Erro Medido	Tempo/ms
R	0,47302181482331	1,47
G	0,70069575309753	1,43
B	0,20788191197204	1,25
H	0,79821286732807	1,33
S	0,08078003675755	1,50
I	0,16786373867987	1,44

Tabela 6.4: Taxa de erro dos seis canais segmentados do corte feito da imagem de satélite da Fazenda Atiaia, utilizando o algoritmo desenvolvido, em relação à mesma imagem segmentada manualmente, em que o canal de saturação obteve o menor erro na segmentação.



Figura 6.4: Fazenda Atiaia.

Em uma análise visual realizada a partir da comparação de imagens, entre as feitas manualmente por um engenheiro, com o resultado da imagem final do algoritmo desenvolvido, o engenheiro pôde observar um bom desempenho. Para a realização automática da análise dos resultados foi desenvolvido um algoritmo que utiliza uma métrica relatada na Seção 6.1.2 que mede o acerto da segmentação em relação à área segmentada na imagem manualmente pelo engenheiro especializado. Os resultados obtidos na análise automática po-



Figura 6.5: Imagem de entrada

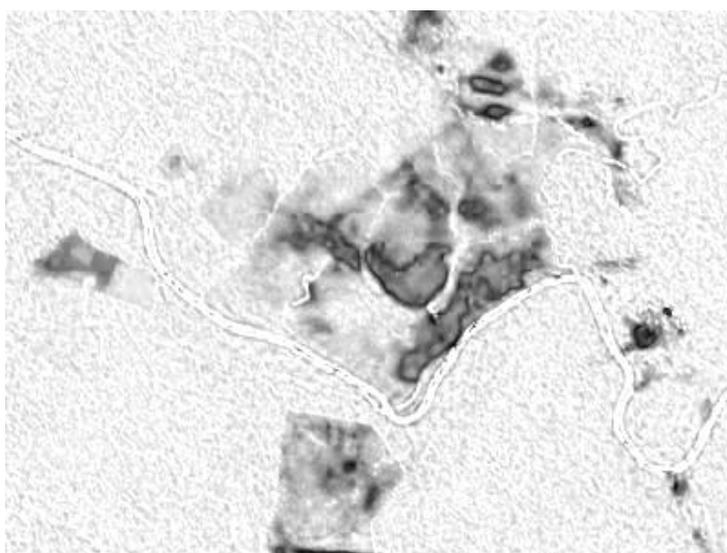


Figura 6.6: Imagem saturada (S)

dem ser observados na escolha do melhor canal. Além do algoritmo de análise ser útil para escolha do melhor canal, também foi necessário na comparação entre a análise manual e automática, pois visualmente foram constatados falsos positivos, em que algumas áreas em degradação quando analisadas automaticamente, aparentemente não se apresentavam totalmente demarcadas, mas foram identificadas na análise manual. Já outras áreas na imagem de



Figura 6.7: Pasto Bom



Figura 6.8: Floresta

satélite foram marcadas como sendo áreas degradadas na análise automática e não foram demarcadas na análise manual.

Para a análise utilizando o algoritmo de análise criado foi necessário que as imagens analisadas manualmente passassem por uma modificação no Photoshop 7.0, para assim tornar possível a comparação com as imagens de saída do algoritmo desenvolvido para realizar a comparação.

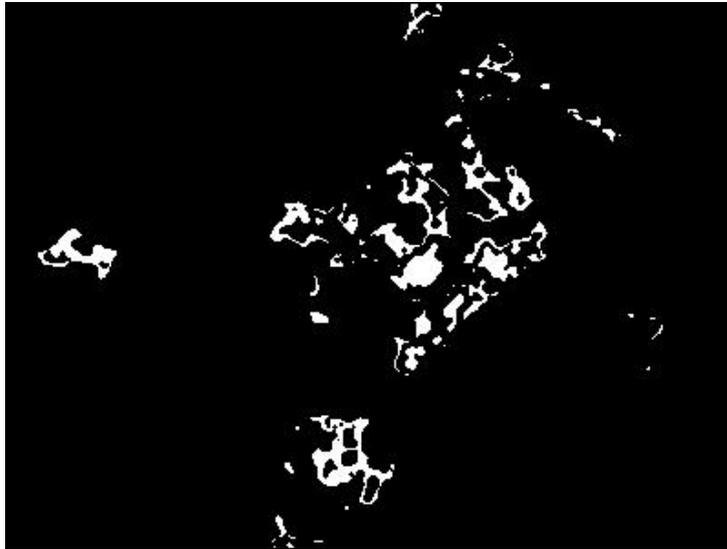


Figura 6.9: Resultante da Floresta com o Pasto Bom

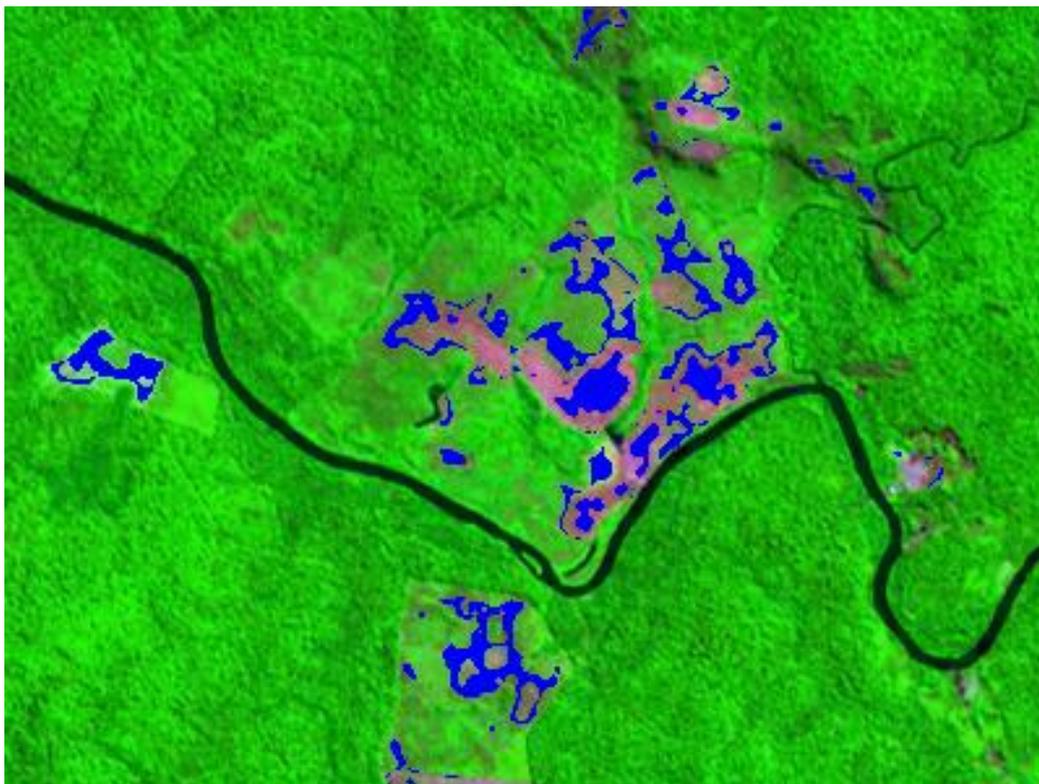


Figura 6.10: Imagem Segmentada

Pôde-se observar na comparação um acerto de 80% das áreas degradadas. Foram constatados pelo engenheiro especializado que as áreas que não foram segmentadas como pastagens degradadas, são áreas em regeneração ou em início de degradação e as áreas em que o algoritmo marcou a mais como sendo degradadas, na verdade, são áreas muito pequenas que manualmente seria difícil de identificar, mas são áreas degradadas dentro das áreas de preservação permanente (margens de córregos). Algumas análises manuais encontram-se disponível no anexo para uma melhor identificação.

Capítulo 7

Considerações Finais e Trabalhos Futuros

Com a conclusão deste projeto foi criado um software que tornou possível a segmentação de imagens de satélite para detecção de degradação de pastagens, onde foram identificadas nas imagens de satélites as áreas em degradação apenas em regiões de fazendas e florestas.

Os resultados do software obtiveram um bom desempenho apesar das imagens de satélite serem do satélite CBERS-2. Essas imagens ainda que de boa qualidade acabam falhando na escala em que são disponibilizadas, por possuírem a escala muito alta e com isso não é possível saber com precisão as regiões de degradação, necessitando de imagens de satélites em escala menor para um melhor aproveitamento. Espera-se com o software criado fazer a análise da situação do solo sem auxílio de algum técnico com experiência.

Com os resultados alcançados, abrem-se novas perspectivas para trabalhos futuros, utilizando regiões e situações diferentes, contribuindo para o desenvolvimento do processamento digital de imagem. Dentre os trabalhos futuros podemos citar alguns tópicos que servirão de base:

- Utilizar outras técnicas de segmentação para fazer a identificação da pastagens degradadas;
- Utilizar modelos de classificadores, não só para identificar pastagens degradadas, mas para classificação de outros tipos de solo;
- Testar o método proposto em outras instâncias.

Anexo A

Análise Manual das Imagens

Seguem abaixo as análises feitas manualmente das imagens de satélites.

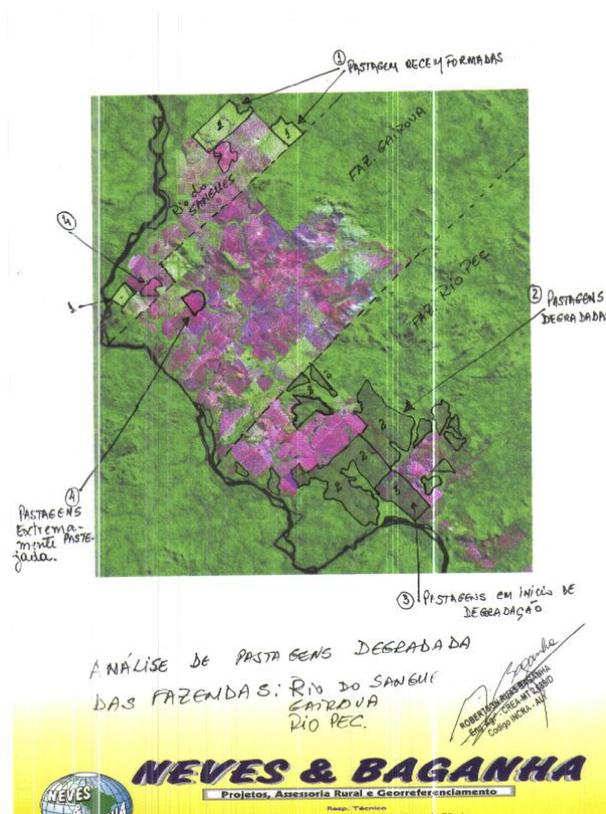


Figura A.1: Análise da Fazenda Rio do Sangue, Guairova e Rio Pec.



Figura A.2: Análise da Fazenda Agrotep e Guinoza.

Referências Bibliográficas

- [1] LEVKOWITZ, H. **Color Theory and Modeling for Computer Graphics, Visualization, and Multimedia Applications**. Norwell, MA, USA: Kluwer Academic Publishers, 1997. ISBN 0792399285.
- [2] GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**. Segunda ed. Reading, Massachusetts: Prentice Hall, 2002. ISBN 0201180758.
- [3] PRATT, W. K. **Digital image processing**. New York, NY, USA: John Wiley & Sons, Inc., 1978. ISBN 0-471-01888-0.
- [4] JAIN, A.; DUBES, R. **Algorithms for Clustering Data**. Englewood Cliffs, NJ: Prentice Hall, 1988.
- [5] INPE - DEPARTAMENTO DE PROCESSAMENTO DE IMAGENS. **Manual de operação do SPRING**. versão.2.0.1 ed. São Jose dos Campos, SP, outubro 1996.
- [6] MOREIRA, L.; ASSAD, E. D. **Segmentação e classificação supervisionada para identificar pastagens degradadas**. GEOINFO2000 - Simpósio Brasileiro de GeoInformática, Embrapa Cerrados, BR 020, Km 18. 73.301-970 - Planaltina - DF, Junho 2000.
- [7] MACEDO, M. C. M. **Degradação de pastagens; conceitos e métodos de recuperação**. Anais Sustentabilidade da Pecuária de Leite no Brasil., Juiz de Fora - MG, p. 137–150, Abril 1999.
- [8] SANTOS, R. F. dos; CARVALHAIS, H. B.; PIRES, F. **Planejamento ambiental e sistemas de informações geográficas**. CIG - Caderno de Informações Georreferenciadas, 1997. ISSN 1415-5869.
- [9] ASSAD, E. D. et al. **Sistema de Informações Geográficas**. Segunda ed. [S.l.]: Embrapa, Universidade de Brasília, da Unicamp e do INPE, 2003.

- [10] NETO, G. H.; RIBEIRO, G. C.; VALERI, F. V. **Processamento e segmentação de imagens colposcópicas digitais**. CBIS'2004 - IX Congresso Brasileiro de Informática em Saúde, Centro Universitário Moura Lacerda - Bacharelado em Ciência da Computação - Brasil and Instituto Victório Valeri de Diagnósticos Médicos - Brasil, Novembro 2004.
- [11] WERNER, B. **Writing imagej plugins - a tutorial**. In: . [S.l.]: Upper Austria University of Applied Sciences Dept. of Media Technology and Design Hagenberg - Austria, 2003.
- [12] JÚNIOR, D. N.; SANTOS, M. V. **Degradação das pastagens e critérios para avaliação**. SIMPÓSIO SOBRE MANEJO DE PASTAGEM, v. 11, n. 9, p. 325, Setembro 1994.
- [13] BRANCO, R. H. **Degradação de pastagens - diminuição da produtividade com o tempo e conceito de sustentabilidade**. Forragicultura - ZOO, Junho 2000.
- [14] MACEDO, M. C. M. **Recuperação de áreas degradadas: pastagens e cultivos intensivos**. ANAIS CONGRESSO BRASILEIRO DE CIÊNCIAS DO SOLO, Goiânia - GO, v. 7, p. 71-72, Abril 1993.
- [15] MACEDO, M. C. M.; ZIMMER, A. H. **Sistema pasto-lavoura e seus efeitos na produtividade agropecuária**. SIMPÓSIO SOBRE ECOSSISTEMAS DE PASTAGENS, UNESP - Universidade Estadual Paulista Jaboticabal - SP, v. 2, p. 216-245, 1993.
- [16] ROERDINK, J. B. T. M.; MEIJSTER, A. **The watershed transform: Definitions, algorithms and parallelization strategies**. Fundamenta Informaticae, v. 41, n. 1-2, p. 187-228, 2000.
- [17] HARALICK, R. M.; STERNBERG, S. R.; ZHUANG, X. **Image analysis using mathematical morphology**. IEEE Trans. Pattern Anal. Mach. Intell., Washington, DC, USA, v. 9, n. 4, p. 532-550, 1987. ISSN 0162-8828.
- [18] JAIN, A. K. **Fundamentals of digital image processing**. Upper Saddle River, NJ, USA: Prentice-Hall, Inc., 1989. ISBN 0-13-336165-9.
- [19] FERNANDEZ, G. A. V.; LIRA, A. **Dinâmica da paisagem - seleção de banda espectral do sensor tm - 5 para análise**

- multitemporal da cobertura vegetal.** IV Congresso Científico CEULP/ULBRA, Palmas, TO, Maio 2005.
- [20] LOCH, C. **A interpretação de imagens aéreas.** Florianópolis, SC: Editora da UFSC, 2001. ISBN 85.328.0204-4.
- [21] SWAIN, M. J.; BALLARD, D. H. **Color indexing.** Int. J. Comput. Vision Kluwer Academic Publishers, Hingham, MA, USA, v. 7, n. 1, p. 11–32, 1991. ISSN 0920-5691.
- [22] MEYER, G. W.; GREENBERG, D. P. **Perceptual color space for computer graphics.** In: Color and the Computer. [S.l.]: p-ap, 1987. p. 83–100.
- [23] JAIN, R.; KASTURI, R.; SCHUNCK, B. G. **Machine vision.** New York, NY, USA: McGraw-Hill, Inc., 1995. ISBN 0-07-032018-7.
- [24] LIPORACE, F. S. **Um sistema neural para monitoração do desflorestamento na região amazônica utilizando imagens do landsat.** Dissertação Mestrado em Engenharia Elétrica - Universidade Federal do Rio de Janeiro, Rio de Janeiro - RJ, p. 122, Janeiro 1994.
- [25] JUNIOR, R. H. **Segmentação de Imagens por Morfologia Matemática,** Tese – IME, Universidade de São Paulo, 1997.
- [26] DUDA, R. O.; HART, P. E. **Pattern Classification and Scene Analysis.** New York: JW, 1973.
- [27] MASCARENHAS, N. D. D.; VELASCO, F. R. D. **Processamento Digital de Imagens.** [S.l.]: Escola de Computação, IME-USP, 1984.
- [28] POINT, W. S. **Image segmentation using clustering.** Vision and Modeling Department, Siemens Corporate Research, Inc., 755 College Road East, Princeton, NJ 08540.
- [29] SEZGIN, M.; SANKUR, B. **Survey over image thresholding techniques and quantitative performance evaluation.** Journal of Electronic Imaging, v. 13, p. 146–165, jan. 2004.
- [30] FILHO, M.; NETO, H. V. **Processamento Digital de Imagens.** [S.l.]: Editora Brasport, 1999.

- [31] SAHOO, P. K. et al. **A survey of thresholding techniques.** Comput. Vision Graph. Image Process., San Diego, CA, USA, v. 41, n. 2, p. 233–260, 1988. ISSN 0734-189X.
- [32] WOLF, C.; JOLION, J.-M. **Model based text detection in images and videos: a learning approach.** Laboratoire d’InfoRmatique en Images et Systèmes d’information, Palmas, TO, Março 2004.
- [33] ZITNICK, C. **Computing Conditional Probabilities in Large Domains by Maximizing Renyis Quadratic Entropy,** Tese – Carnegie Mellon University, Pittsburgh, PA, Maio 2003.
- [34] PAVLO, D. **Sequence modeling with mixtures of conditional maximum entropy distributions.** Technical report, NEC Labs, Yahoo Inc. 701 First Avenue Sunnyvale, California 94089, 2003.
- [35] YIN, P.-Y. **Maximum entropy-based optimal threshold selection using deterministic reinforcement learning with controlled randomization.** Signal Process., Amsterdam, The Netherlands, The Netherlands, v. 82, n. 7, p. 993–1006, 2002. ISSN 0165-1684.
- [36] THIRAN, J. P.; MACQ, B.; MAIRESSE, J. **Morphological classification of cancerous cells.** In: Proceedings ICIP-94 (Cat. No. 94CH35708). Los Alamitos, CA, USA: IEEE Comput. Soc. Press, 1994. v. 3, p. 706–10.
- [37] RONSE, C. **Openings: Main properties, and how to construct them.** Mathematical Morphology: Theory and Applications, R.M. Haralick ed., LaBRI - Université Bordeaux-I, 351ccours de la Libération, F-33405 Talence, France, 2001.
- [38] JACKWAY, P. T.; DERICHE, M. **Scale-space properties of the multiscale morphological dilation-erosion.** IEEE Transactions on Pattern Analysis and Machine Intelligence, v. 18, n. 1, p. 38–51, 1996.
- [39] ZHANG, C.; MURAI, S.; BALTSAVIAS, E. **Road network detection by mathematical morphology.** Proc. of ISPRS Workshop - 3D Geospatial Data Production: Meeting Application Requirements, Institute of Geodesy and Photogrammetry, ETH-Hoenggerberg, 8093, Switzerland, v. 7, p. 185–200, 1999.

- [40] SERRAS, J. **Image analysis and Mathematical morphology.** [S.l.]: Academic Press, 1982.
- [41] PEREZ, A. A.; GONZAGA, A.; ALVES, J. M. **Monitoring the treatment of leg ulcers through computer vision algorithms applied in color images.** International Conference on Quality Control by Artificial Vision, EESC - ESCOLA DE ENGENHARIA DE SAO CARLOS, v. 2, p. 516–521, 2001.
- [42] BUSIN, L. et al. **Color space selection for unsupervised color image segmentation by analysis of connectedness properties.** International Conference on Complex Systems, Intelligence and Modern Technology, Cherbourg, France, p. 311–316, SEPTEMBRE 2004.