



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21c/2019/03.20.17.49-TDI

**SEGMENTADOR CONTEXTUAL DE IMAGENS
ÓTICAS BASEADO NA TEORIA DE CAMPOS
ALEATÓRIOS CONDICIONAIS**

Anderson Reis Soares

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelos Drs. Leila Maria Garcia Fonseca, e Thales Sehn Körting, aprovada em 22 de março de 2019.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3SUF3QH>>

INPE
São José dos Campos
2019

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GBDIR)

Serviço de Informação e Documentação (SESID)

CEP 12.227-010

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/7348

E-mail: pubtc@inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELECTUAL DO INPE - CEPPII (PORTARIA N° 176/2018/SEI-INPE):**Presidente:**

Dr. Marley Cavalcante de Lima Moscati - Centro de Previsão de Tempo e Estudos Climáticos (CGCPT)

Membros:

Dra. Carina Barros Mello - Coordenação de Laboratórios Associados (COCTE)

Dr. Alisson Dal Lago - Coordenação-Geral de Ciências Espaciais e Atmosféricas (CGCEA)

Dr. Evandro Albiach Branco - Centro de Ciência do Sistema Terrestre (COCST)

Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia e Tecnologia Espacial (CGETE)

Dr. Hermann Johann Heinrich Kux - Coordenação-Geral de Observação da Terra (CGOBT)

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação - (CPG)

Silvia Castro Marcelino - Serviço de Informação e Documentação (SESID)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon

Clayton Martins Pereira - Serviço de Informação e Documentação (SESID)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Ducca Barbedo - Serviço de Informação e Documentação (SESID)

André Luis Dias Fernandes - Serviço de Informação e Documentação (SESID)

EDITORAÇÃO ELETRÔNICA:

Ivone Martins - Serviço de Informação e Documentação (SESID)

Cauê Silva Fróes - Serviço de Informação e Documentação (SESID)



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21c/2019/03.20.17.49-TDI

**SEGMENTADOR CONTEXTUAL DE IMAGENS
ÓTICAS BASEADO NA TEORIA DE CAMPOS
ALEATÓRIOS CONDICIONAIS**

Anderson Reis Soares

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelos Drs. Leila Maria Garcia Fonseca, e Thales Sehn Körting, aprovada em 22 de março de 2019.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3SUF3QH>>

INPE
São José dos Campos
2019

Dados Internacionais de Catalogação na Publicação (CIP)

Soares, Anderson Reis.

So11s Segmentador contextual de imagens óticas baseado na teoria de campos aleatórios condicionais / Anderson Reis Soares. – São José dos Campos : INPE, 2019.
xxiv + 155 p. ; (sid.inpe.br/mtc-m21c/2019/03.20.17.49-TDI)

Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2019.

Orientadores : Drs. Leila Maria Garcia Fonseca, e Thales Sehn Körting.

1. Segmentação de imagens. 2. Processamento de imagens.
3. Sensoriamento remoto. I.Título.

CDU 528.8:621.376.5



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

Aluno (a): **Anderson Reis Soares**

Título: "SEGMENTADOR CONTEXTUAL DE IMAGENS ÓTICAS BASEADO NA TEORIA DE CAMPOS ALEATÓRIOS CONDICIONAIS"

Aprovado (a) pela Banca Examinadora
em cumprimento ao requisito exigido para
obtenção do Título de **Doutor(a)** em
Sensoriamento Remoto

Dra. Evelyne Márcia Leão de Moraes Novo


Presidente / INPE / SJCampos - SP

() Participação por Vídeo - Conferência

Aprovado () Reprovado

Dra. Leila Maria Garcia Fonseca


Orientador(a) / INPE / SJCampos - SP

() Participação por Vídeo - Conferência

Aprovado () Reprovado

Dr. Thales Sehn Körting


Orientador(a) / INPE / São José dos Campos - SP

() Participação por Vídeo - Conferência

Aprovado () Reprovado

Dr. Sidnei João Siqueira Sant'Anna


Membro da Banca / INPE / São José dos Campos - SP

() Participação por Vídeo - Conferência

Aprovado () Reprovado

Dr. Raul Queiroz Feitosa


Convidado(a) / PUC- RIO / Rio de Janeiro - RJ

Participação por Vídeo - Conferência

Aprovado () Reprovado

Dr. Rogerio Galante Negri


Convidado(a) / UNESP / São José dos Campos - SP

() Participação por Vídeo - Conferência

Aprovado () Reprovado

Este trabalho foi aprovado por:

() maioria simples

unanimidade

São José dos Campos, 22 de março de 2019

“Science is the process that takes us from confusion to understanding...”

BRIAN GREENES

A meus pais, Luciene e Adalberto.

AGRADECIMENTOS

A minha família em especial: meus pais, Luciene e Adalberto, minha irmã Elane e meu tio David pelo incentivo e apoio incondicional.

Meus orientadores: Dra. Leila Fonseca e o Dr. Thales Körting por acreditarem no meu trabalho e me darem liberdade para seguir minhas ideias.

Aos amigos que fiz aqui, em especial: José Fronza, Filipe Temporim, Jean Farhat e Alana Kasahara pela ajuda nos momentos difíceis e pelos bons momentos que vivemos juntos.

Aos professores que desde a graduação me incentivaram e acreditaram no meu potencial: Msc. Marconi Antão, Dr. Homero Carvalho e a Dra. Ana Lúcia Candeias.

Ao INPE e a todos os professores e colaboradores, com os quais tive o prazer de compartilhar alguns momentos, sempre de grande aprendizado.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro.

RESUMO

A segmentação de imagens é um problema fundamental no processamento de imagens e uma operação comum em Sensoriamento Remoto que tem sido amplamente utilizada, especialmente na Análise Geográfica de Imagens Baseadas em Objetos. Neste trabalho, é proposto um novo método de segmentação não supervisionado, baseado em campos aleatórios condicionais. O método utiliza três níveis de informação para a segmentação contextual: (1) obtido com uma classificação de pixel não supervisionada com o algoritmo Fuzzy C-Médias, em que o número de grupos é obtido usando uma abordagem baseada na morfologia matemática; (2) a vizinhança 8-conectada do pixel; e (3) de informações contextuais através de superpixel. O método foi testado com 4 conjuntos de dados, uma imagem multiespectral do WorldView-2, com 2 m de resolução espacial, uma imagem Quickbird com 60 cm de resolução espacial, uma imagem do sensor OLI/Landsat-8, com 30 m de resolução espacial e uma imagem do sensor MUX/CBERS-4, com 20 m de resolução espacial. Os resultados foram avaliados com 6 medidas de qualidade e seu desempenho foi comparado com outros algoritmos de segmentação de imagem que são usualmente aplicados pela comunidade de Sensoriamento Remoto. Os resultados indicam bom desempenho geral do algoritmo, alcançando resultados similares aos de outros métodos tradicionais aplicados pela comunidade de sensoriamento remoto.

Palavras-chave: Segmentação de imagens. Processamento de Imagens. Sensoriamento Remoto.

CONTEXTUAL SEGMENTATION METHOD FOR OPTICAL REMOTE SENSING IMAGERY BASED ON THE THEORY OF CONDITIONAL RANDOM FIELDS

ABSTRACT

Image segmentation is a fundamental problem in image processing and a common operation in Remote Sensing that has been widely used especially on Geographic Object-Based Image Analysis. In this paper, we propose a new unsupervised segmentation algorithm, that is based on Conditional Random Fields. The method use three levels of information: (1) obtained with an unsupervised pixel classification with Fuzzy *C*-Means algorithm, in which the number of groups is obtained using a straightforward approach; (2) the 8-connected neighborhood of a pixel; and (3) provision of context information granted by a priori segmentation. The algorithm was tested with 4 datasets, a WorldView-2 multispectral image, with 2 m of spatial resolution, a Quickbird image with 60cm of spatial resolution, an image of OLI/Landsat-8 sensor, with 30 m of spatial resolution and an image of MUX/CBERS-4 sensor, with 20 m of spatial resolution. The results were evaluated with 6 quality measures, and the method performance was compared with other image segmentation algorithms that are usually applied by the Remote Sensing community. Results indicate a good overall performance of the proposed method, reaching similar results to traditional methods applied by the remote sensing community.

Keywords: Image segmentation. Image processing. Remote Sensing.

LISTA DE FIGURAS

	<u>Pág.</u>
2.1 Técnica de limiarização.	7
2.2 Técnica de divisão e fusão de regiões.	10
2.3 Ilustração do processo de segmentação do algoritmo Watershed.	11
2.4 Exemplo de um grafo.	14
2.5 Adjacências Euclidianas em espaços $2D$ e $3D$. a) Vizinhança 4-conectada, b) Vizinhança 8-conectada, c) Vizinhança 20-conectada, d) Vizinhança 6-conectada representada em $3D$	15
2.6 Resultado de diferentes abordagens para divisão de imagem em <i>tiles</i> . . .	18
2.7 Área de amortização definida pelo método de Lassalle et al. (2015). a) Representa as regiões estáveis dentro do <i>tile</i> . b) Os segmentos em vermelho destacam os segmentos localizados na borda do <i>tile</i> . c) Representa a margem de estabilidade após uma iteração, que corresponde aos novos segmentos adicionados.	19
3.1 Comportamento das funções potenciais P^n Potts e P^n Potts Robusto. . .	28
4.1 Estrutura do algoritmo de segmentação proposto.	31
4.2 Estrutura do método <i>Divide and Segment</i>	32
4.3 Imagem de bordas antes e após a aplicação do filtro de mediana.	34
4.4 Relações de adjacência utilizadas para construção da matriz de adjacência.	35
4.5 Etapas realizadas pelo algoritmo de segmentação proposto.	37
4.6 Elementos estruturantes utilizados.	38
4.7 Definição dos mínimos regionais.	39
4.8 Resultados da etapa de união das sementes. a) Imagem original, b) sementes obtidas no processo de detecção dos mínimos Regionais (12 padrões) e c) sementes após a etapa de união (re-rotulação) (8 padrões). . .	40
5.1 Polígonos de Referência dos <i>datasets</i> OLI e MUX.	51
5.2 Gráfico Precisão-Revocação.	53
5.3 Processo de geração do <i>dataset</i> WorldView-2	55
5.4 Resultado do <i>Divide and Segment</i> na imagem Quickbird (Composição Colorida: R3G2B1).	57
5.5 Telhados cortados pela imagem gerada pelo <i>Divide and Segment</i> sobre composição colorida: R3G2B1.	58
5.6 Linhas de corte para divisão dos <i>tiles</i>	59

5.7	Classificação obtida para imagem WorldView-2 utilizando estratégia não supervisionada. Linhas pretas delimitam as referências utilizadas.	60
5.8	Classificação obtida para imagem Quickbird utilizando estratégia não supervisionada. Linhas pretas delimitam as referências utilizadas e linhas pretas pontilhadas, o limite do tile gerado através do Dividir e Segmentar.	61
5.9	Classificação obtida para imagem OLI utilizando estratégia não supervisionada. Linhas pretas delimitam as referências utilizadas.	62
5.10	Classificação obtida para imagem MUX utilizando estratégia não supervisionada.	63
5.11	Histograma da diferença espectral entre as mínimos regionais da imagem MUX.	63
5.12	Da esquerda para direita: Imagem original com a referência sobreposta, segmentação com MRS, segmentação com Meanshift, segmentação com o algoritmo de Bins e a segmentação com o algoritmo proposto.	65
5.13	Boxplot da métrica Precisão no <i>dataset WorldView-2</i>	67
5.14	Boxplot da métrica Revocação no <i>dataset WorldView-2</i>	68
5.15	Boxplot da métrica F-Measure no <i>dataset WorldView-2</i>	68
5.16	Boxplot da métrica <i>FITXY</i> no <i>dataset WorldView-2</i>	69
5.17	Boxplot da métrica <i>FITN</i> no <i>dataset WorldView-2</i>	70
5.18	Boxplot da métrica G_{shape} no <i>dataset WorldView-2</i>	70
5.19	Gráfico de dispersão - Precisão e Revocação.	72
5.20	Resultados da segmentação do <i>dataset Quickbird</i> . Polígonos amarelos são as referências delineadas por um especialista e os polígonos com bordas vermelhas são os resultados produzidos por cada algoritmo.	74
5.21	Boxplot da métrica Precisão no <i>dataset Quickbird</i>	75
5.22	Boxplot da métrica Revocação no <i>dataset Quickbird</i>	76
5.23	Boxplot da métrica F-Measure no <i>dataset Quickbird</i>	77
5.24	Boxplot da métrica <i>FITXY</i> no <i>dataset Quickbird</i>	77
5.25	Boxplot da métrica <i>FITN</i> no <i>dataset Quickbird</i>	78
5.26	Boxplot da métrica G_{shape} no <i>dataset Quickbird</i>	79
5.27	Total de segmentos gerados por cada algoritmo de segmentação no <i>dataset Quickbird</i>	80
5.28	Segmentação da imagem Quickbird antes e depois do processo de agregação. Os segmentos pretos foram gerados sem a área mínima, os vermelhos foram obtidos após a agregação dos polígonos menores que $20m^2$	82
5.29	Resultados da segmentação do <i>dataset OLI/Landsat-8</i> . Polígonos amarelos são as referências delineadas por um especialista e os polígonos com bordas vermelhas são os resultados produzidos por cada algoritmo.	84
5.30	Boxplot da métrica Precisão no <i>dataset OLI/Landsat-8</i>	86

5.31	Boxplot da métrica Revocação no <i>dataset</i> OLI/Landsat-8.	86
5.32	Boxplot da métrica F–Measure no <i>dataset</i> OLI/Landsat-8.	87
5.33	Boxplot da métrica <i>FITXY</i> no <i>dataset</i> OLI/Landsat-8.	88
5.34	Boxplot da métrica <i>FITN</i> no <i>dataset</i> OLI/Landsat-8.	89
5.35	Boxplot da métrica G_{shape} no <i>dataset</i> OLI/Landsat-8.	90
5.36	Total de segmentos gerados por cada algoritmo de segmentação.	92
5.37	Resultados da classificação do <i>dataset</i> OLI/Landsat-8 sobrepostos pelos segmentos gerados pelo algoritmo proposto.	93
5.38	Resultados da segmentação do <i>dataset</i> MUX/CBERS-4. Polígonos ama- relos são as referências delimitadas por um especialista e os polígonos com bordas vermelhas são os resultados produzidos por cada algoritmo.	95
5.39	Total de segmentos gerados por cada algoritmo de segmentação para o <i>dataset</i> MUX/CBERS-4.	96
5.40	Boxplot da métrica Precisão no <i>dataset</i> MUX/CBERS-4.	97
5.41	Boxplot da métrica Revocação no <i>dataset</i> MUX/CBERS-4.	98
5.42	Boxplot da métrica F–Measure no <i>dataset</i> MUX/CBERS-4.	98
5.43	Boxplot da métrica <i>FITXY</i> no <i>dataset</i> MUX/CBERS-4.	99
5.44	Boxplot da métrica <i>FITN</i> no <i>dataset</i> MUX/CBERS-4.	100
5.45	Boxplot da métrica G_{shape} no <i>dataset</i> MUX/CBERS-4.	101

LISTA DE TABELAS

	<u>Pág.</u>	
5.1	Informações das imagens de alta resolução.	49
5.2	Informações das imagens de média resolução.	49
5.3	Resultados obtidos por cada algoritmo.	66
5.4	Precisão - WorldView-2	71
5.5	Revocação - WorldView-2	71
5.6	F-Measure - WorldView-2	71
5.7	<i>FITXY</i> - WorldView-2	71
5.8	<i>FITN</i> - WorldView-2	71
5.9	G_{shape} - WorldView-2	71
5.10	Resultados obtidos por cada algoritmo para o <i>dataset</i> Quickbird.	75
5.11	Precisão - Quickbird	80
5.12	Revocação - Quickbird	80
5.13	F-Measure - Quickbird	80
5.14	<i>FITXY</i> - Quickbird	80
5.15	<i>FITN</i> - Quickbird	80
5.16	G_{shape} - Quickbird	80
5.17	Resultados obtidos pelo algoritmo UCS antes e após a agregação dos polígonos menores que $20m^2$	81
5.18	Resultados obtidos por cada algoritmo para o <i>dataset</i> OLI/Landsat-8.	85
5.19	Precisão - OLI/Landsat-8	91
5.20	Revocação - OLI/Landsat-8	91
5.21	F-Measure - OLI/Landsat-8	91
5.22	<i>FITXY</i> - OLI/Landsat-8	91
5.23	<i>FITN</i> - OLI/Landsat-8	91
5.24	G_{shape} - OLI/Landsat-8	91
5.25	Resultados obtidos por cada algoritmo para o <i>dataset</i> MUX/CBERS-4.	96
5.26	Precisão - MUX/CBERS-4	102
5.27	Revocação - MUX/CBERS-4	102
5.28	F-Measure - MUX/CBERS-4	102
5.29	<i>FITXY</i> - MUX/CBERS-4	102
5.30	<i>FITN</i> - MUX/CBERS-4	102
5.31	G_{shape} - MUX/CBERS-4	102
5.32	Valores da estatística <i>Plus/Minus</i>	103
A.1	Polígonos de Referência do <i>dataset</i> WorldView-2.	129

A.2 Polígonos de Referência do *dataset* Quickbird. 131

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
1.1 Objetivo e hipótese	2
1.2 Contribuições do trabalho	3
1.3 Organização do trabalho	3
2 SEGMENTAÇÃO DE IMAGENS	5
2.1 Detecção de descontinuidades	6
2.2 Segmentação Baseada em Similaridade	6
2.2.1 Segmentação Baseada em Regiões	7
2.2.1.1 Crescimento de regiões	8
2.2.1.2 Divisão e Fusão	9
2.2.2 Transformada <i>Watershed</i>	10
2.2.3 Segmentação no Espaço de Atributos	11
2.3 Segmentação de Imagem por Grafos	13
2.3.1 Definições e Notações	14
2.3.2 Particionamento do Grafo	15
2.4 Segmentação em Paralelo	17
3 SEGMENTAÇÃO DE IMAGENS VIA ABORDAGEM BAYE- SIANA	21
3.1 Campos Aleatórios de Markov - (<i>Markov Random Fields</i>)	21
3.1.1 Campo de Markov	22
3.2 Campo Aleatório Condicional - (<i>Conditional Random Field</i>)	24
3.3 Função de Energia	25
3.4 Segmentação Baseada em Campos Aleatórios	29
4 UNSUPERVISED CONTEXTUAL SEGMENTATION	31
4.1 <i>Divide and Segment</i>	32
4.1.1 Detecção de bordas	33
4.1.2 Definição dos pontos iniciais	33
4.1.3 Definição da linha de corte	34
4.2 Segmentação	35
4.2.1 Extração de marcadores para identificação de padrões	37

4.2.2	Rotulação Inicial	40
4.2.3	Modelo de Energia	41
4.2.3.1	Componente Unária	42
4.2.3.2	Componente de Iteração Espacial	42
4.2.3.3	Componente de Alta-Ordem	44
4.2.4	Minimização de energia	44
4.3	Funcionamento	45
5	RESULTADOS E AVALIAÇÃO	49
5.1	Construção dos <i>Datasets</i>	49
5.2	Avaliação dos Resultados	50
5.2.1	Precisão-Revocação	51
5.2.2	Medidas de Sucesso	52
5.2.3	Teste de Hipótese	56
5.3	Desempenho do Algoritmo	56
5.3.1	Tempo de Execução	56
5.3.2	<i>Divide and Segment</i>	57
5.3.3	<i>Fuzzy C-Means</i> - Componente Unária	59
5.4	Testes de Segmentação	64
5.4.1	Worldview-2	64
5.4.2	Quickbird	72
5.4.3	Landsat-8/OLI	82
5.4.4	MUX/CBERS-4	93
5.5	Discussão	102
6	CONCLUSÕES	105
	REFERÊNCIAS BIBLIOGRÁFICAS	109
	APÊNDICE A - REFERÊNCIAS UTILIZADAS PARA AVALIAÇÃO DOS DATASETS WORLDVIEW-2 E QUICKBIRD.	127
	APÊNDICE B - INFORMAÇÕES SOBRE OS BOXPLOTS APRESENTADOS NO CAPÍTULO 7.	133
B.1	WorldView-2	133
B.2	Quickbird	135
B.3	OLI	137
B.4	MUX	139

APÊNDICE C - MAPAS DE SEGMENTAÇÃO 143

1 INTRODUÇÃO

O desenvolvimento de sistemas autônomos que reproduzam as capacidades do sistema visual humano, é alvo de interesse em diversas áreas do conhecimento, como por exemplo, Visão Computacional. De acordo com [Ballard e Brown \(1982\)](#), a Visão Computacional é dedicada à construção de descritores que atribuem significado aos objetos presentes em uma imagem digital. Para o desenvolvimento destes sistemas, diversas etapas precisam ser realizadas nas imagens, sendo a segmentação uma das principais.

Segundo [Soille \(1999\)](#), a segmentação é definida como o processo que divide uma imagem digital em regiões uniformes, cujos pixels possuem características semelhantes de acordo com algum critério de similaridade. A segmentação de imagens faz parte da cadeia de processos para extração de informação no Sensoriamento Remoto, sendo essencial para a Análise de Imagens Baseada em Objetos Geográficos (*Geographic Object-Based Image Analysis - GEOBIA*). Devido à sua importância, vários métodos de segmentação têm sido desenvolvidos para melhorar o processo de particionamento da imagem e a identificação de objetos ([BAATZ; SCHÄPE, 2000](#); [HAY et al., 2005](#); [KÖRTING et al., 2011](#); [SALDANHA, 2013](#); [HU et al., 2016](#); [GONZALO-MARTÍN et al., 2016](#)). Mas para que o processo de segmentação seja eficiente, os algoritmos devem ser capazes de identificar as relações entre os pixels, ou seja, o contexto em que um determinado pixel está inserido ([FELZENSZWALB; HUTTENLOCHER, 2004](#); [GURNEY; TOWNSHEND, 1983](#)).

Para segmentar uma imagem, os métodos desenvolvidos na Visão Computacional fundamentam-se em teorias sobre a percepção visual, onde o processo de definição de um objeto não ocorre a partir de elementos isolados, mas sim, pela compreensão do todo. Segundo [Wertheimer \(1938\)](#), o processo de identificação de um objeto utiliza características de similaridade tais como a cor, um determinado padrão ou a proximidade entre os objetos.

Nos métodos clássicos de segmentação de imagens aplicados na área de Sensoriamento Remoto, em especial na GEOBIA, a informação contextual não é utilizada de forma direta. Usualmente é utilizada a abordagem de segmentação multiescala, na qual são realizadas diversas segmentações. Cada uma delas é realizada com diferentes parâmetros, com o objetivo de criar áreas menores ou maiores, englobando mais ou menos objetos. Isso faz com que essa abordagem possua um grande custo computacional, além do tempo gasto na definição dos parâmetros.

Uma forma direta de integrar a informação contextual no processo de segmentação, é através da Teoria Bayesiana. Essa abordagem tem atraído interesse devido ao sólido arcabouço matemático e por ser fundamentada em inferência estatística e em informações *a priori*. Os métodos de segmentação baseados nesta teoria favorecem o particionamento de imagens com conteúdo não determinístico, como diferentes texturas e ruídos, que são um desafio para os métodos tradicionais (VANTARAM; SABER, 2012). Esses métodos maximizam a informação *a posteriori*, ou seja, a imagem é segmentada por meio da solução de um problema de estimação do *maximum a posteriori* (MAP), que pode ser resolvido utilizando diversos métodos (BESAG, 1986; BOYKOV et al., 2001; FELZENSZWALB; HUTTENLOCHER, 2006; KOLMOGOROV, 2006). Nesta abordagem podem ser utilizados diferentes tipos de modelos, como os tradicionais Campos Aleatórios de Markov (*Markov Random Fields* – MRF), que são capazes de expressar relações globais em termos de estatísticas locais da imagem (BARKER; RAYNER, 2000), ou como os Campos Aleatórios Condicionais (*Conditional Random Fields* – CRF).

O CRF tem sido utilizado para o delineamento de objetos e cenas urbanas (YANG et al., 2015; PERCIANO et al., 2016; ZHU et al., 2016; GAO et al., 2016; ZHANG et al., 2016), sendo combinados inclusive com técnicas de *Deep-Learning* (DO; ARTIERES, 2010; ZHENG et al., 2015; CELIKYILMAZ et al., 2016). No Sensoriamento Remoto, o ele vem sendo especialmente aplicados em análises de detecção de mudanças em imagens de alta resolução espacial (HOBERG et al., 2015; ZHOU et al., 2016; LV et al., 2016; CAO et al., 2016; LV et al., 2018) e de classificação de imagens (TUIA et al., 2018; PAN; ZHAO, 2018; ZEGGADA et al., 2018; YANG et al., 2018). Uma vantagem desse método em relação aos tradicionais MRF é que este tipo de modelo Bayesiano, é globalmente condicionado aos dados de entrada, diferente do MRF, o que permite uma modelagem da imagem de forma mais direta.

Apesar dos recentes avanços, a segmentação de imagens ainda é um processo custoso computacionalmente e difícil, que depende muito do tipo de dado e da aplicação. Algoritmos de segmentação não supervisionados capazes de lidar com a informação contextual, e que sejam intuitivos ao usuário, ainda representa uma lacuna na área de Sensoriamento Remoto.

1.1 Objetivo e hipótese

Como destacado por Weinman et al. (2004) a informação contextual é importante no processo de segmentação. Se pixels vizinhos possuem incorretamente o mesmo rótulo, pode-se penalizar essa condição através da descontinuidade entre esses pixels para

alterar um dos rótulos. Entretanto, modelos que consideram a vizinhança imediata de um pixel permitem a incorporação de relações apenas entre pares de pixels, sendo incapazes de impor dependência em níveis regionais (MÁRQUEZ-NEILA et al., 2014).

Para modelar relações de interdependência em nível regional, ou seja, no contexto não imediato de um pixel, podem ser utilizados, por exemplo, grafos completamente conectados (KRÄHENBÜHL; KOLTUN, 2012), que possuem um alto custo computacional. Uma alternativa mais simples, consiste na utilização de uma função de energia de alta-ordem para incentivar a consistência dos rótulos em nível regional. Modelos desse tipo levam em consideração tanto informação espectral do pixel de forma isolada, como também suas relações de vizinhança em nível local e regional na imagem.

Combinando esta estrutura com CRF, pode-se obter um modelo capaz de detectar relações de vizinhança de forma robusta por meio da modelagem direta da probabilidade condicional. Dessa forma o objetivo central deste trabalho é desenvolver um método de segmentação contextual e não supervisionado baseado na Teoria de CRF.

Diante do exposto, propõe-se a hipótese de que *um método de segmentação não supervisionado baseado em Campos Aleatórios Condicionais de alta-ordem é capaz de obter melhores resultados em comparação aos métodos tradicionais de segmentação de imagens de Sensoriamento Remoto?*

1.2 Contribuições do trabalho

A principal contribuição desta tese é o desenvolvimento de um algoritmo não supervisionado para a segmentação de imagens baseado na teoria de Campos Aleatórios Condicionais de alta-ordem.

1.3 Organização do trabalho

Primeiramente fundamentos sobre segmentação de imagens são introduzidos no Capítulo 2, seguido de uma revisão sobre métodos de segmentação baseados na Teoria Bayesiana no Capítulo 3.

No Capítulo 4 é apresentado o algoritmo de segmentação proposto baseado na informação contextual obtida *a priori* de forma não supervisionada para realizar a segmentação de imagens.

No Capítulo 5 são apresentados os resultados da segmentação comparando-os com outros métodos. Finalmente, as conclusões e sugestões de trabalhos futuros são apre-

sentados no Capítulo 6.

2 SEGMENTAÇÃO DE IMAGENS

O princípio da segmentação de imagens foi introduzido no início do século XX por psicólogos alemães, que demonstraram que o sistema visual humano realiza agrupamentos baseados na proximidade, similaridade e continuidade dos objetos observados (FACON, 1993). Este princípio foi estendido para o contexto computacional e deu origem aos primeiros algoritmos de segmentação.

O objetivo da segmentação é particionar uma imagem em diferentes regiões de forma que os pixels contidos em uma mesma região sejam similares de acordo com as propriedades do pixel e critérios de similaridade. O nível de particionamento da imagem depende do problema a ser resolvido, sendo crítico para o sucesso ou fracasso na análise de imagens digitais (GONZALEZ; WOODS, 2010). O processo é essencialmente empírico e único para cada imagem, em função, sobretudo, das características da imagem, dos objetos contidos nela e das características do sensor.

Diversos trabalhos de revisão sobre segmentação foram desenvolvidos ao longo dos anos (FU; MUI, 1981; HARALICK; SHAPIRO, 1985; PAL; PAL, 1993; KHAN, 2014; ZAITOUN; AQEL, 2015). Gonzalez e Woods (2010) classificam os métodos de segmentação segundo duas propriedades básicas, relacionadas ao nível de cinza da imagem: a descontinuidade e a similaridade.

Vantaram e Saber (2012), propõem a divisão dos métodos de segmentação de forma mais detalhada, seguindo uma estrutura hierárquica em dois níveis. O primeiro grupo, o de alto nível, agrupa os métodos de acordo com o tipo da imagem, o nível de iteração do analista, da representação da imagem, de seus atributos e do princípio do método. O segundo nível, subdivide essas classes de forma mais direta, baseando-se em suas características, como por exemplo, a utilização da informação espacial.

Outra forma de agrupar os métodos de segmentação é em função da sua abordagem, que pode ser baseada na imagem ou orientada por modelos. A abordagem baseada em imagem, extrai o objeto com base nas propriedades estatísticas da imagem, e inclui a maioria das técnicas de segmentação baseadas em borda (DEY et al., 2010). Já a abordagem baseada em modelos pressupõe que os objetos em uma imagem são representados por um determinado padrão.

A maioria destes modelos é fundamentada na Teoria Bayesiana, portanto, eles dependem fortemente da inferência estatística e da informação *a priori* sobre os dados.

Nesta abordagem, o objetivo é rotular cada pixel com um rótulo ideal, que é aquele cujo pixel possui a maior probabilidade de pertencimento, definida em função da similaridade do pixel ao rótulo. Geralmente os métodos Bayesianos, empregam algoritmos de minimização para encontrar o particionamento ideal e são estruturados em um grafo (KOLTUN, 2011; CAMPBELL et al., 2013).

Por questão de organização e facilidade de leitura, nesse capítulo são apresentados os métodos baseados em imagem, que são os mais aplicados no Sensoriamento Remoto. No capítulo a seguir, a abordagem Bayesiana será apresentada.

2.1 Detecção de descontinuidades

Os métodos de segmentação baseados em descontinuidades buscam particionar a imagem por meio da detecção desses elementos, que pode ser realizada por operadores baseados em derivadas locais, usualmente implementados por meio de filtros de tamanhos variados, que calculam as diferenças ponderadas entre o ponto central e os seus vizinhos (PRATT, 2002). Essas descontinuidades ocorrem devido a variação abrupta dos tons de cinza, sob forma de pontos isolados, linhas ou bordas (GONZALEZ; WOODS, 2010).


Os métodos de detecção de pontos e linhas baseiam-se nos conceitos matemáticos de Gradiente e Laplaciano e são implementados por meio de máscaras de convolução, que são aplicadas sobre os pixels da imagem. Outra forma de obter o gradiente de uma imagem é com base na morfologia matemática, por meio do gradiente morfológico. Segundo Bins et al. (1996), a presença de pequenas lacunas nos limites das bordas, ocasionados pela sensibilidade a variações locais de intensidade, geram falhas que permitem que regiões que possuem baixa similaridade sejam unidas na segmentação, o que faz com que um único segmento represente mais de um objeto.

2.2 Segmentação Baseada em Similaridade

Esse grupo de métodos pode ser dividido em três subgrupos: (1) limiarização; (2) de região; e (3) *Watersheds*. O mais simples deles é a limiarização, cujo objetivo é separar os objetos a partir do histograma da imagem (GONZALEZ; WOODS, 2002). Os métodos de limiarização tomam como informação apenas as propriedades espectrais dos pixels, sem considerar seu contexto no momento do particionamento. Esses métodos são separados em dois tipos: globais e locais (Figura 2.1). Os métodos globais utilizam um único limiar, T , para toda imagem. Eles têm como premissa básica que o histograma da imagem é bimodal, de forma que com um único limiar é possível

separar o objeto do fundo.

Figura 2.1 - Técnica de limiarização.



(a) Limiarização global.

(b) Limiarização local.

Fonte: Körting (2016)

Por outro lado, os métodos baseados em região extraem regiões e não as bordas que delimitam os objetos. O *Watershed*, segue a abordagem por regiões, mas usa a informação de borda na definição dos segmentos.

2.2.1 Segmentação Baseada em Regiões

Segundo Facon (2002), regiões são conjuntos de pixels espacialmente conectados, onde de qualquer ponto de uma região pode-se chegar a outro ponto, por um caminho inteiramente contido nessa região, ou seja, todos os pixels de uma região são conectados. Os métodos baseados em regiões particionam o domínio da imagem, R , em N sub-regiões, R_1, R_2, \dots, R_N , segundo algumas condições (GONZALEZ; WOODS, 2002):

(a) $\bigcup_{i=1}^N R_i = R$;

(b) R_i é um conjunto conexo, $i = 1, 2, \dots, N$;

(c) $R_i \cap R_j = \emptyset \forall i \text{ e } j, i \neq j$;

(d) $P(R_i) = \text{VERDADEIRO}$ para $i = 1, 2, \dots, N$;

(e) $P(R_i \cup R_j) = \text{FALSO}$ para quaisquer regiões adjacentes R_i e R_j .

A primeira condição indica que a segmentação deve ser completa, ou seja, todos os pixels devem pertencer a uma região. A condição (b) define que os pixels de uma

determinada região R_i devem ser conexos. A terceira condição (c) indica que as regiões devem ser disjuntas. A condição (d) determina que todos os pixels em uma região segmentada devem satisfazer as propriedades impostas pelo critério de similaridade R . Finalmente a condição (e) define que duas regiões R_i e R_j adjacentes devem apresentar respostas diferentes em relação ao critério de similaridade. Estas restrições devem ser atendidas por todos os métodos de segmentação, para que seu resultado seja considerado correto.

Os segmentadores que seguem o conceito de regiões podem partir de níveis distintos: o nível local que utiliza pixels como sementes ou a imagem na totalidade. Em função da estratégia escolhida, técnicas de segmentação baseadas em regiões podem ser de crescimento de regiões ou por divisão e fusão (*Split-And-Merge*).

2.2.1.1 Crescimento de regiões

A abordagem de crescimento de regiões, é um procedimento onde geralmente alguns pixels são selecionados como sementes e a partir deles regiões são formadas com base em critérios de similaridade pré-definidos.

Apesar da sua robustez, essa abordagem apresenta alguns problemas, como por exemplo, a sensibilidade a ruídos presentes na imagem e a obtenção de diferentes resultados em função da escolha das sementes. A principal diferença entre as técnicas propostas que seguem essa abordagem é a forma como é realizado o agrupamento entre as regiões e nas medidas de similaridade usadas para definir as regiões.

Bins et al. (1996) propuseram uma técnica baseada na abordagem de crescimento de regiões, que resolve parcialmente o problema de ordenamento no momento da união dos segmentos, problema esse intrínseco a essa abordagem. Nessa técnica, inicialmente cada pixel é rotulado como uma região distinta, em seguida o algoritmo compara pixels vizinhos, unindo-os em regiões caso eles sejam semelhantes. Se duas regiões são adjacentes e mutuamente as mais semelhantes, dentre seus vizinhos, elas serão unidas, formando uma única região. Ao fim do processo, as regiões que foram menores que o limiar definido pelo analista, são unidas à região vizinha mais semelhante.

Outra técnica baseada na abordagem de crescimento de regiões amplamente utilizada é a Multirresolução (MRS) proposta por Baatz e Schäpe (2000) e implementada no software *eCognition*. O MRS minimiza a heterogeneidade das regiões, de forma que, além da definição de um limiar pelo analista, cada pixel recebe um peso asso-

ciado à heterogeneidade da região a qual ele pertence. Para que uma possível união ocorra, essa característica é avaliada por um fator de fusão, que considera além da heterogeneidade espectral dos pixels, também sua heterogeneidade espacial, que é função da compactação do segmento e da suavidade de sua borda. Caso o valor do fator de fusão seja menor que o quadrado do valor de escala definido pelo usuário, as duas regiões serão unidas.

Um dos pontos negativos do algoritmo MRS é a quantidade de parâmetros que devem ser ajustados para obter uma segmentação satisfatória. Para automatizar a seleção desses parâmetros, várias estratégias têm sido propostas. Drăguț et al. (2010), propuseram uma ferramenta para a estimativa do parâmetro de escala (*Estimation of Scale Parameter* (ESP)) que realiza múltiplas segmentações, com diferentes níveis de escala, em uma abordagem *bottom-up*. O método parte do princípio de que à medida que o tamanho do objeto na imagem aumenta, sua variância local também aumenta. Como o algoritmo MRS utiliza o parâmetro de escala para controlar o tamanho máximo do objeto, é possível estimar um valor ótimo para a escala por meio da análise da variância local. No entanto, esta abordagem funciona em uma única camada, o que dificulta aplicações em dados multiespectrais. Para contornar essa limitação, Drăguț et al. (2014) propuseram uma metodologia automatizada para a definição do parâmetro de escala considerando múltiplas camadas e uma abordagem hierárquica com três níveis.

Achancaray et al. (2014) propuseram o *Segmentation Parameter Tuner* (SPT), que assim como o ESP foi projetado para realizar o ajuste ótimo dos parâmetros de segmentação do algoritmo MRS. Para isso, o SPT usa diversos algoritmos de otimização, para encontrar uma solução ótima para um conjunto determinado de métricas de avaliação, utilizando regiões de referência fornecidas *a priori*.

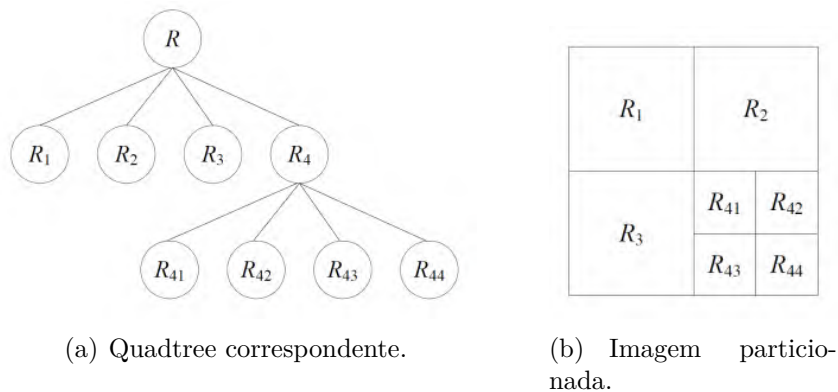
2.2.1.2 Divisão e Fusão

Uma abordagem similar a abordagem de crescimento de regiões é de Divisão e Fusão (*Split-and-Merge*). Nessa abordagem a segmentação da imagem é realizada através de operações de divisão e fusão de regiões (HOROWITZ; PAVLIDIS, 1974). Entretanto, o particionamento da imagem é realizado de forma recursiva e regular, de modo que para qualquer região R_i onde $i \in \{1, 2, \dots, N\}$, $P(R_i) = \text{Verdade}$, ou seja, todos os pixels são similares dado um critério de similaridade.

Esse processo pode ser iniciado de duas formas, *top-down* ou *bottom-up*. Na abordagem *top-down* a imagem é tratada inicialmente como uma única região, de modo que

a cada iteração a imagem é subdividida em regiões que não satisfazem as condições de homogeneidade. A estratégia *bottom-up* é executada de forma inversa, a imagem é inicialmente quebrada em blocos, geralmente representados por meio de *Quadtrees* ou através de *Region Adjacency Graph* (RAG) (Figura 2.2), que é uma estrutura em que cada região na imagem é representada por um nó, e através de cortes no grafo é realizada a fusão das regiões (TRÉMEAU; COLANTONI, 2000).

Figura 2.2 - Técnica de divisão e fusão de regiões.



Fonte: Gonzalez e Woods (2010)

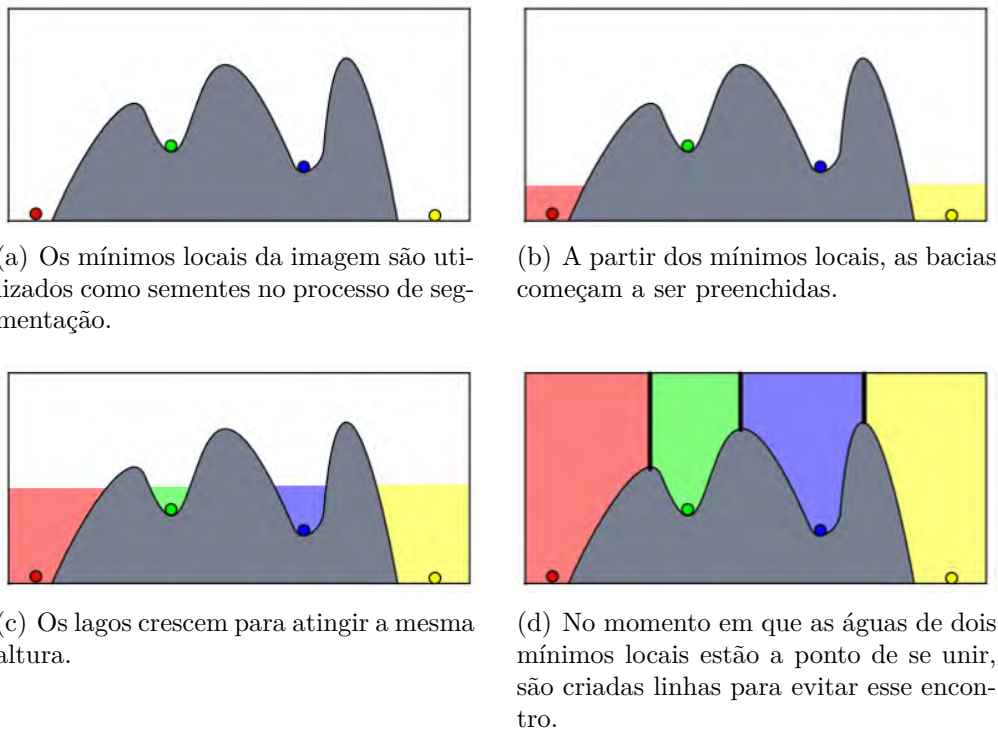
2.2.2 Transformada *Watershed*

A Transformada *Watershed*, ou simplesmente *Watershed*, proposta por Beucher e Lantuéjoul (1979), possui um custo computacional baixo e é bastante eficiente em certos casos. A imagem é considerada como uma superfície topográfica, na qual o nível de cinza é relacionado à elevação de uma superfície. Os mínimos regionais, que são pixels ou zonas planas que não possuem vizinhos de menor intensidade, são considerados como vales, enquanto bordas entre objetos são entendidos como divisores de água (*watershed*).

Esse método possui diversas variações, a mais tradicional (BEUCHER, 1992) segue um processo de imersão, como mostra a Figura 2.3. O relevo (imagem) é inundado progressivamente a partir de fontes de água posicionadas nos vales (mínimos regionais). Dessa forma, a água vai sendo acumulada nas partes mais baixas do relevo, formando bacias hidrográficas ao longo da imagem, até chegarem a níveis mais altos, onde a água de várias bacias se juntam. Cada vez que uma região chega à iminência de se fundir com outra, uma linha divisória é criada para evitar que as águas de regiões diferentes acabem se tocando. No final do processo, cada região é formada

por um segmento, cujas linhas divisórias definem o seu contorno.

Figura 2.3 - Ilustração do processo de segmentação do algoritmo Watershed.



Fonte: Mendonça (2016)

Apesar dos resultados robustos e da capacidade de gerar fronteiras conectadas, a segmentação por *Watershed* tem como principal problema a super-segmentação da imagem (ROERDINK; MEIJSTER, 2000). Para resolver esta questão, é comum a utilização de marcadores na imagem (MEYER; BEUCHER, 1990; LOTUFO et al., 2002; XIAO et al., 2007; TARABALKA et al., 2012; GAETANO et al., 2015). Diversas versões desse método têm sido propostas. Algumas utilizam estruturas flexíveis como o grafo e métodos de implementação em paralelo (MEIJSTER; ROERDINK, 1996; FALCÃO et al., 2004; MANSILLA, 2014; MOYA, 2013; GAETANO et al., 2015; BEJAR, 2016).

2.2.3 Segmentação no Espaço de Atributos

Os métodos baseados no conceito de agrupamento, de acordo com Acharya e Ray (2005), utilizam o princípio de que padrões pertencentes a um dado grupo devem ser mais similares entre si do que em relação a padrões pertencentes a outros grupos. Dado um conjunto Q com N elementos $Q = \{Q_1, Q_2, \dots, Q_N\}$, o problema de agru-

pamento consiste na obtenção de um conjunto de k grupos, $R = \{R_1, R_2, \dots, R_k\}$, tal que a similaridade entre os elementos contidos em um grupo, seja a maior do que em qualquer outro.

Entre os métodos que segue essa abordagem, destacam-se o Meanshift (FUKUNAGA; HOSTETLER, 1975) e os métodos dedicados a geração de *Superpixels*, que de acordo com Ren e Malik (2003), são um grupo de pixels conectados com cores ou níveis de cinza semelhantes.

O método Meanshift proposto por Fukunaga e Hostetler (1975), é um método não paramétrico que foi posteriormente adaptado por Cheng (1995) para aplicações na Visão Computacional e estendido para ser aplicado na segmentação de imagens por Comaniciu e Meer (1997). Esse método tem por princípio não fazer suposições sobre a forma da distribuição nem sobre o número de grupos em uma imagem. Desse modo, os grupos no espaço de atributos n -dimensional podem ser modelados através de uma função de densidade de probabilidade (*f.d.p.*), na qual regiões densas neste espaço correspondem aos máximos ou modas locais de uma distribuição (DERPANIS, 2005).

A segmentação final, segundo Derpanis (2005), é formada pelo agrupamento de pixels que convergem para uma determinada moda no domínio espacial e no espaço de atributos, de forma que o pixel receberá o rótulo de um grupo de acordo com sua proximidade, considerando esses dois domínios. Os raios que delimitam a influência das modas, no domínio espacial e no espaço de atributos, são parâmetros ajustados pelo analista (ZHU et al., 2016).

Outro método de segmentação que atua no espaço de atributos é o "*Simple Linear Iterative Clustering*" (SLIC), proposto por Achanta et al. (2012). Esse método calcula a distância de cada centro de grupo k para os pixels que estão dentro de um raio de busca (Ra) pré-definido.

O SLIC cria uma grade regular controlada pelo número aproximado de Superpixels desejados pelo analista. Depois disso, cada pixel i sobreposto pelo raio de busca é associado ao centro do grupo mais próximo. Em seguida os centros dos grupos são ajustados e esse procedimento é repetido até a convergência. Segundo Achanta et al. (2012) a distância $D_{i,k}$ entre um grupo k e um elemento i , é uma combinação da distância espacial e no espaço de cores CIELAB. No domínio espacial a distância é definida por:

$$ds_{i,k} = \|s_i - s_k\| \quad (2.1)$$

onde, s_k é posição média de um grupo e s_i é a posição do pixel i . Já a distância no espaço de cores CIELAB é definida por:

$$dc_{i,k} = \|I_i - I_k\| \quad (2.2)$$

onde, I_k é vetor médio de cores de um grupo k e I_i é o vetor do pixel i no espaço de cor CIELAB.

Ao se normalizar a distância espacial $ds_{i,k}$ entre centroide e o pixel por uma constante N_s , que é a dimensão da região de atuação dos centroides, e inserindo um fator de peso m , determinado pelo analista, para definir o grau de importância para a distância espacial em relação a distância no espaço de cores, é possível controlar a compacidade dos segmentos gerados. De forma que quanto menor o valor do fator de peso m , mais aderentes os superpixels serão as bordas dos objetos. Dessa forma a distância $D_{i,k}$ é definida como:

$$D_{i,k} = \sqrt{dc_{i,k}^2 + \left(\frac{ds_{i,k}}{N_s}\right)^2 m^2} \quad (2.3)$$

Derivações desta técnica foram propostas, como o *Simple Linear Iterative Clustering - Zero* (SLIC0), que é uma versão na qual o fator de peso m é calculado para cada região a cada iteração, e o *Simple Non-linear Iterative Clustering - (SNIC)* (ACHANTA; SÜSTRUNK, 2017) que tem como principal diferença a capacidade de forçar a conectividade dos pixel explicitamente desde o início.


2.3 Segmentação de Imagem por Grafos

A abordagem de segmentação baseada em grafos tem ganhando popularidade principalmente devido à sua capacidade de refletir as propriedades globais da imagem (WANG, 2015). A seguir serão apresentados alguns conceitos básicos sobre grafos e alguns métodos baseados nessa estrutura.

2.3.1 Definições e Notações

Segundo Goldberg (2012) um grafo (Figura 2.4), é uma estrutura abstrata que representa um conjunto de elementos denominados vértices e suas relações de interdependência definidas por arestas.

Figura 2.4 - Exemplo de um grafo.



Grafo: É uma estrutura de dados, $G = \{V, B\}$, sendo representada por um conjunto de vértices $u \in V$, e por um conjunto de arestas $\{u, v\} \in B$, em que u e $v \in V$.

Adjacência: Dois vértices são tidos como adjacentes, $u \sim v$, se eles forem conectados por uma aresta, ou seja, $\exists \{u, v\} \in B$ (CHIBA, 2014).

Grafo Ponderado: Um grafo é ponderado se existem pesos associados às suas arestas ou vértices, de forma que, $G = \{V, B, W\}$, onde W representa o conjunto de pesos.


Árvore: É um grafo não orientado onde existe um caminho entre quaisquer dois de seus vértices e que não possui ciclos.

Subgrafo: Dado um grafo $G = \{V, B\}$, o grafo $G' = \{V', B'\}$ é chamado de subgrafo de G , se e somente se, $V' \in V$ e $B' \in B$.

Uma imagem pode ser interpretada como um grafo ponderado $G = \{V, B, W\}$ cujos vértices V são os pixels da imagem e cujas arestas são os pares ordenados de pixels $\{u, v\} \in B$, que são definidos por uma relação de adjacência $\tilde{\theta}$, e que depende de suas posições relativas e opcionalmente de outras propriedades locais da imagem, como o gradiente (MANSILLA, 2014; BEJAR, 2016). Essas relações de adjacência são chamadas de adjacências euclidianas e correspondem a uma relação simétrica e

invariante a translação (BEJAR, 2016). A Figura 2.5 mostra exemplos dessas relações de vizinhança.

Figura 2.5 - Adjacências Euclidianas em espaços $2D$ e $3D$. a) Vizinhança 4-conectada, b) Vizinhança 8-conectada, c) Vizinhança 20-conectada, d) Vizinhança 6-conectada representada em $3D$.



Fonte: Mansilla (2014)

2.3.2 Particionamento do Grafo

O processo de segmentação baseado na Teoria dos Grafos, comumente, é interpretado como um problema de otimização do particionamento de um grafo que, frequentemente, é resolvido por processos de minimização de energia (KOLTUN, 2011; CAMPBELL et al., 2013). Segundo Wang (2015), os métodos baseados em grafos podem ser categorizados em: Árvores Geradoras Mínimas (*Minimum Spanning Tree - MST*), Caminho mais curto (*Shortest Path*) e Cortes (*Graph cuts*).

Os métodos baseados em MST realizam a segmentação da imagem através de um processo de agrupamento, de modo que ao final são geradas MST. Segundo Goldberg (2012), uma MST é uma árvore na qual a soma dos pesos de suas arestas não é maior que o peso de qualquer outra árvore. Os métodos baseados nessa abordagem tradicionalmente realizam o particionamento do grafo através da remoção das arestas de maior peso, seguindo uma abordagem hierárquica (PENG et al., 2013). Um método importante que foi desenvolvido seguindo essa abordagem foi proposto por Felzenszwalb e Huttenlocher (2004).

Este método, baseado no algoritmo de Kruskal (KRUSKAL, 1956), particiona um grafo com o intuito de minimizar a dissimilaridade interna de uma região e maximizar a dissimilaridade entre regiões. Para isso, é utilizado um critério de similaridade que infere a existência de bordas entre dois segmentos a partir da análise da magnitude

da dissimilaridade entre eles em comparação à dissimilaridade interna dentro de pelo menos um dos segmentos.

Diferente da abordagem por MST, na abordagem por *Shortest Path*, a segmentação é vista como um problema de caminho ótimo, em que o objetivo é encontrar o caminho de custo mínimo entre os dois vértices. Na prática, para utilização desse método é necessária a interação com o analista, para que o processo de segmentação se torne mais efetivo (PENG et al., 2013), o que limita sua utilização no Sensoriamento Remoto. Dentre esses métodos destaca-se o *Livewire* (FALCÃO et al., 1996) e o *Snakes* (KASS et al., 1988). Esses métodos buscam a curva que melhor separa os objetos em uma imagem por meio da minimização do grafo, aplicando geralmente o algoritmo de Dijkstra (DIJKSTRA, 1959).

A principal forma de particionamento do grafo é através da operação de cortes. Na abordagem por cortes, os vértices ou arestas são removidos utilizando um critério de similaridade, de forma que no final do processo são gerados conjuntos de subgrafos desconexos em que a energia do grafo seja mínima (SHI; MALIK, 2000).

Matematicamente, o corte é associado a remoção de arestas em um grafo G , de modo que sejam gerados dois subgrafos disjuntos, M e N . O grau de similaridade entre os subgrafos M e N é obtido através da soma das arestas removidas entre eles:

$$cut(M, N) = \sum_{i \in M, j \in N} w(i, j) \quad (2.4)$$

onde, $w(i, j)$ é o peso das arestas que conectam os vértices i da partição M e j é o peso da partição N .

Diversas técnicas foram propostas utilizando esse conceito, dentre elas destaca-se o *Minimal Cut* (WU; LEAHY, 1993), *Normalized-Cuts* - NCut (SHI; MALIK, 2000), *Ratio Cut* e *Average Cut*, sendo a NCut a principal. O Ncut é minimizado resolvendo um sistema de autovalores, $Lx = Dx$, onde L é a Matriz de Laplaciana e D a Matriz de Graus, que é obtida pela somatória dos pesos das arestas que incidem sobre o vértice. Essa técnica calcula o custo do corte como uma fração de todas as conexões entre as arestas para todos os nós do grafo (WANG, 2015). Apesar de ser robusta, ela tem como principal problema o alto custo computacional em grafos com grande número de vértices, devido aos cálculos dos autovalores da matriz Laplaciana.

2.4 Segmentação em Paralelo

O processo de segmentação é geralmente custoso computacionalmente, uma vez que algoritmos devem considerar o contexto, a escala, a vizinhança, o significado e os recursos computacionais (KÖRTING et al., 2013). Segundo Seinstra e Koelma (2004), o processamento em paralelo é uma solução que vem se tornando uma alternativa popular para a segmentação de imagens, sobretudo quando se trata de imagens de alta resolução espacial.

No processo de segmentação em paralelo, normalmente, a imagem é dividida em pequenos *tiles*, que são pequenas partes da imagem original, utilizando linhas rígidas. Entretanto, de acordo com Wassenberg et al. (2009), isso não é aceitável porque objetos de borda não seguem padrões regulares e, portanto, são criados segmentos inconsistentes, como pode ser observado na Figura 2.6(a).

Para resolver esse problema, diversas abordagens foram propostas. Körting et al. (2011) propuseram a criação de bordas não rígidas para divisão da imagem. Neste caso, a criação dos *tiles* segue a fronteira natural dos segmentos, evitando que objetos de interesse sejam cortados. Baseando-se na teoria dos grafos, as linhas de corte são definidas por um algoritmo de caminho ótimo, proposto por Dijkstra (1959). Desse modo, as linhas são criadas sobre as bordas de maior intensidade, detectadas através do gradiente da imagem. Dessa forma, é possível evitar que objetos presentes na imagem sejam cortados. Uma vez definidas as linhas de corte, a imagem é particionada em *tiles*, que podem ser segmentados de forma distribuída.


Soares et al. (2015) realizaram adaptações neste método, sendo a principal na obtenção da imagem de borda. O gradiente foi obtido utilizando os filtros direcionais de Prewit. Dessa forma, é possível obter bordas em diferentes direções e assim facilitar o processo de identificação das linhas de corte. As imagens gradientes também foram filtradas com um filtro de mediana para minimizar eventuais falhas nas bordas. Como pode ser observado na Figura 2.6(b), estas modificações no algoritmo melhoraram o resultado da segmentação quando comparado ao resultado da Figura 2.6(a).

Lassalle et al. (2015) propuseram uma abordagem diferente, em que o grafo não é usado para encontrar a melhor linha de corte, mas para criar uma estrutura baseada em *tiles*, sob os quais são realizadas as fusões dos segmentos. O processo de fusão utiliza o conceito de margem de estabilidade, no qual é criada uma região ao redor de cada segmento. Para garantir a estabilidade para a primeira iteração do algoritmo de fusão, regiões são adicionadas a cada *tile*, como ilustrado na Figura 2.7. Como

Figura 2.6 - Resultado de diferentes abordagens para divisão de imagem em *tiles*.



(a) Resultado da Segmentação utilizando linhas rígidas




(b) Resultado da Segmentação utilizando o método proposto por Soares et al. (2015)

Fonte: Produção do autor.

essa abordagem duplica os segmentos, uma fase de pós-processamento é realizada para eliminar polígonos duplicados. Devido a essa duplicação, o método proposto demanda um grande custo computacional, limitando assim seu uso.

Figura 2.7 - Área de amortização definida pelo método de Lassalle et al. (2015). a) Representa as regiões estáveis dentro do *tile*. b) Os segmentos em vermelho destacam os segmentos localizados na borda do *tile*. c) Representa a margem de estabilidade após uma iteração, que corresponde aos novos segmentos adicionados.



Fonte: Lassalle et al. (2015)

3 SEGMENTAÇÃO DE IMAGENS VIA ABORDAGEM BAYESIANA

As técnicas de segmentação apresentadas no capítulo anterior, além de serem baseadas em propriedades da imagem, têm em comum a incapacidade de lidar com a informação contextual de forma direta, algo fundamental em aplicações de Sensoriamento Remoto, como destacado por Blaschke (2010). Na Visão Computacional diversos métodos foram desenvolvidos com o intuito de utilizar tal informação, sendo que grande parte deles é fundamentado na modelagem estatística. Esta abordagem apresenta como uma de suas principais vantagens a possibilidade de utilizar a vizinhança de um pixel na tarefa de rotulação.

Estes métodos têm chamado a atenção, sobretudo, na última década, em virtude de seu sólido arcabouço matemático, que favorece tarefas como a segmentação de imagens nas quais conteúdos não determinísticos, como texturas e ruído estatístico, ainda desafiam os métodos tradicionais (VANTARAM; SABER, 2012). Além disso, os recentes avanços na área da computação permitiram que um dos principais gargalos dessa abordagem, o custo computacional, pudesse ser mitigado (KOHLI et al., 2008).

Na modelagem estatística, restrições contextuais podem ser expressas localmente através de probabilidades condicionais, ou de forma global, por meio da probabilidade conjunta (LI, 2003). Segundo Leite (2012), como as informações locais podem ser observadas diretamente sobre a imagem, é possível realizar a inferência global através de suas propriedades locais. Quando a informação contextual é considerada, há uma dependência mútua entre os rótulos, de modo que o problema da rotulação pode ser resolvido por meio da teoria dos MRF.

Na modelagem MRF, uma imagem é representada através de suas características locais, determinando para cada pixel a dependência de sua intensidade em relação a seus vizinhos. Esta dependência, é expressa em termos de uma distribuição de probabilidade condicional, definida em função da intensidade de cada pixel (BALAN, 2003). No Sensoriamento Remoto essa abordagem é bastante explorada, tanto para a segmentação (LI et al., 2012; ZHENG et al., 2016; DUAN et al., 2016) quanto para a classificação de imagens orbitais (D'ELIA et al., 2003; COSTA et al., 2009; MOSER et al., 2016; LIU et al., 2016).

3.1 Campos Aleatórios de Markov - (*Markov Random Fields*)

Segundo Blake et al. (2011), MRF são modelos probabilísticos que usualmente são construídos sobre um grafo não direcionado. Sua teoria baseia-se na relação local

entre os vértices $v \in V$ de um grafo G , onde cada vértice v pode possuir uma ou mais variáveis aleatórias. Para definir um MRF é preciso realizar uma modelagem probabilística da imagem, ou seja, a imagem deve ser tratada como uma realização de um campo aleatório, onde cada pixel da imagem é uma variável aleatória que assume valores em $Y = \{0, 1, \dots, S-1\}$, onde S é o número de regiões distintas na imagem. A informação contextual utilizada para a construção de MRF, é representada pelo conjunto de variáveis aleatórias $X = \{X_i = x_i, \dots, X_v = x_v\}$, onde x_v pertence ao conjunto Y . Dessa forma, para um conjunto de rótulos discreto Y , a probabilidade de que uma variável aleatória X_v possua o valor x_v é denotada por $P(X_v = x_v)$, assim a probabilidade conjunta é denotada por $P(X = x) = P(X_i = x_i; \dots; X_v = x_v)$ (LEITE, 2012).

3.1.1 Campo de Markov

Definição: X é um Campo de Markov modelado sobre um grafo G , dado um sistema de vizinhança δ_v se, e somente se as condições abaixo são satisfeitas:

- a) $P(X) > 0, v \in G$ (Positividade)
- b) $P(X_i | (X_v)_{q \neq s}) = P(X_i | \{X_v | q \in \delta_v\})$ (Propriedade Markoviana)

De acordo com Besag (1986), quando a probabilidade conjunta de qualquer campo aleatório é determinada unicamente por suas probabilidades condicionais locais, a condição de positividade é satisfeita. Dessa forma, X é um MRF se, e somente se, a probabilidade condicional local de um pixel, depender apenas da configuração da vizinhança deste pixel.

De acordo com Li (2003), as restrições contextuais podem ser expressas localmente através de probabilidades condicionais. Entretanto, existem alguns problemas relacionados a estrutura da probabilidade condicional, que impedem que ela seja calculada diretamente (BESAG, 1986). Para isso, é necessário a utilização do Teorema de Hammersley-Cliford, que trata sobre a equivalência entre MRF e distribuições de Gibbs (HAMMERSLEY; CLIFFORD, 1971).

Uma distribuição de Gibbs é uma distribuição de probabilidade para um sistema, que fornece a probabilidade deste sistema entrar em um determinado estado, dada uma função da energia desse estado e da temperatura do sistema (DUTTA, 1953).

Segundo o teorema, toda distribuição de Gibbs gera um MRF, que de acordo com Blake et al. (2011), satisfaz a condição de positividade e pode ser expressa

como o produto de funções potenciais, o que de acordo com Kato et al. (2012), facilita a definição de um MRF, além de possibilitar a incorporação de informações obtidas *a priori*. As distribuições de Gibbs são usualmente expressas em termos de uma função de energia E , e de suas funções potenciais.

Definição: X é um Campo Aleatório de Gibbs em G , dado um sistema de vizinhança δ_v se, e somente se, suas configurações seguem uma distribuição de Gibbs, a qual é definida por:

$$P(x) = \frac{1}{Z} \exp(-E(x)) \quad (3.1)$$

onde, $E(x)$ é a energia de configuração da imagem e Z é uma constante de normalização chamada de função de partição de Gibbs.

A função de energia $E(x)$ pode ser decomposta em um somatório de funções potenciais. Através da especificação desses potenciais, define-se a natureza do modelo, ou seja, a forma como a imagem será modelada. Modelos pareados realizam a análise entre pares de pixels, ou seja, apenas a informação da vizinhança imediata é considerada, desprezando assim a informação contextual em nível regional. Para utilizar essa informação, é necessária a utilização de modelos de alta-ordem que possuem funções potenciais específicas para incorporar a informação da vizinhança não imediata de um pixel.

A maneira mais utilizada para estimar os parâmetros de um MRF é por meio do *Maximum a Posteriori* (MAP), como proposto por Geman e Geman (1984), já que os rótulos não são diretamente observáveis na imagem. O processo de estimação é realizado a partir da maximização da probabilidade *a posteriori* $P(s|I, \omega)$. A partir da Regra de Bayes, a estimação do MAP é:

$$y^* = \arg \max_{x \in Y} P(Y|X, \omega)P(X|\omega) \quad (3.2)$$

Apesar da inserção de parâmetros aumentar a robustez do modelo, calcular a função de partição $Z(x)$ utilizando MRF, é um problema computacional intratável, que apesar de serem problemas difíceis, podem ser resolvidos por algoritmos mas não em tempo polinomial. Diversas técnicas de otimização têm sido propostas, como *Iterated Conditional Modes* (ICM) (BESAG, 1986), *Simulated Annealing* - (SA) (KIRKPATRICK et al., 1983), *Loopy Belief Propagation* (MURPHY et al., 1999), α - β *Swap* (BOYKOV

et al., 2001) e α -expansion proposta por (KOLMOGOROV; ROTHER, 2007).

O processo de estimativa de parâmetros e minimização da energia do modelo MRF são muito complexos. Além disso, os MRF não são capazes de condicionar todos os seus potenciais em relação as propriedades da imagem, de modo, que ele é capaz de utilizar apenas um dos tipos de contexto, o de rótulos. Uma forma de condicionar os potenciais às propriedades da imagem é utilizando modelos discriminativos, que permitem condicionar todos os seus potenciais aos dados de entrada, provendo ao método a possibilidade da incorporação da informação contextual de rótulos e de dados (LAFFERTY et al., 2001; BONADIO, 2013). Um modelo discriminativo que tem tido um grande destaque recentemente é o Campo Aleatório Condicional.

3.2 Campo Aleatório Condicional - (*Conditional Random Field*)

Campo Aleatório Condicional é uma variante discriminativa do MRF, de modo que ela modela diretamente a probabilidade condicional. Ela é utilizada para a predição estruturada de rótulos, pois considera amostras vizinhas e faz predições interdependentes. De acordo com McCallum (2012), ele especifica as probabilidades de sequências de rótulos possíveis dada uma sequência observada, sendo que a probabilidade condicional da sequência de rótulos pode incluir uma ampla variedade de recursos arbitrários e dependentes do dado de entrada.

Definição: *Seja X um conjunto de variáveis aleatórias modeladas sobre um grafo $G = \{V, B\}$ e desejamos prever um conjunto ótimo de rótulos Y dado um conjunto de vetores de características dos pixels de uma imagem I . Dessa forma o par (I, X) é um CRF quando ao condicionar Y , as variáveis aleatórias X obedecerem a propriedade da Markovianidade: $P(x_s | (x_q)_{q \neq s}) = P(x_s | \{x_q | q \in \delta_v\})$.*

Dessa forma, a imagem pode ser modelada como um CRF que é caracterizado pela distribuição de Gibbs da seguinte forma:

$$P(Y|X) = \frac{1}{Z} \exp(-E(x|I)) \quad (3.3)$$

onde, I é a imagem, Z é a função de partição e E é a energia da imagem.

De acordo com Lafferty et al. (2001), CRF é uma versão de um MRF onde todos os potenciais são condicionados aos dados de entrada. Segundo Ladický (2011), tanto CRF quanto MRF, seguem os mesmos princípios e sofrem com os mesmos problemas de otimização. Apesar da similaridade, a possibilidade dos potenciais do CRF serem

globalmente condicionados pelos dados de entrada, traz uma grande vantagem para esse tipo de modelo. No processamento de imagens, por exemplo, tornar o potencial pareado dependente das descontinuidades observadas na imagem, faz com que a super-suavização, um dos principais problemas da abordagem com MRF, possa ser mitigado.

A principal aplicação dos CRF tem sido para segmentação e rotulação de textos (XU et al., 2016; RAMESH et al., 2016). Contudo, nos últimos anos esse método está sendo cada vez mais aplicado na área de Visão Computacional a classificação de imagens (KOLTUN, 2011; MCCALLUM, 2012; DAI et al., 2015). No processamento de imagens de Sensoriamento Remoto orbital diversos trabalhos utilizaram esse modelo, contudo, em grande parte para classificação (LI, 2010; ZHONG; WANG, 2010; YANG et al., 2011; ZHAO et al., 2015; MIRKAMALI; NAGABHUSHAN, 2015; ZHAO et al., 2016) e detecção de mudanças (LV et al., 2015; CAO et al., 2016; ZHOU et al., 2016; LV et al., 2018).

3.3 Função de Energia

Como definido por Blake et al. (2011), toda distribuição de Gibbs gera um MRF, de modo que é possível expressar a probabilidade condicional local através de um função de energia E . Essa função pode ser decomposta em um somatório de funções potenciais. Através da especificação desses termos, define-se a natureza do modelo que irá representar a imagem.

A estrutura da função de energia mais comum na Visão Computacional e no processamento de imagens, é função de duas componentes: a unária e a de interação espacial. Esse tipo de modelo, utiliza relações de dependência entre pares de pixels, usualmente na vizinhança 4 ou 8-conectada. De modo que o modelo é definido como:

$$E(x) = \sum_{i \in V} \psi_u(x_i) + \sum_{i \in I, j \in \delta_i} \psi_p(x_i, x_j) \quad (3.4)$$

onde, E é função de energia, i, j são pixels, ψ_u é componente unária e ψ_p é a componente interação espacial, δ_i é a vizinhança do pixel i , I é a imagem e N é o número de pixels da imagem I .

A componente unária é responsável pela associação entre um pixel e um rótulo. Usualmente ela é definida por um classificador, que utiliza um vetor de informações sobre uma região ou pixel e retorna à probabilidade desse pixel receber um rótulo. Para isso diversas informações, além da espectral, podem ser utilizadas, como a

cor no espaço HSV, a localização no espaço ou a forma (HUANG et al., 2011). A componente interação espacial, segundo Yang et al. (2011), fornece a capacidade contextual ao algoritmo, por meio da avaliação da compatibilidade entre um pixel e seus vizinhos.

Existem diversas formas de modelar as relações de vizinhança de um pixel, mas a principal delas é por meio do modelo de Potts. De acordo com Grau et al. (2004), esse modelo é uma generalização do modelo de Ising, que favorece que elementos vizinhos possuam a mesma configuração. Apesar de ter sido criado com o intuito de modelar a interação de elementos ferromagnéticos, tem sido bastante utilizado na mecânica estatística.

Assim como o modelo de Ising, o modelo de Potts favorece que pixels vizinhos possuam o mesmo rótulo e penaliza aqueles que possuem rótulos diferentes. Dessa forma o modelo de Potts é definido por:

$$E(x) = - \sum_{ij}^N \beta \psi_p(x_i, x_j) \quad (3.5)$$

onde, β é um parâmetro maior que 1, de modo que quanto maior o seu valor maior será a penalização aplicada para a diferença entre rótulos na imagem a função de compatibilidade $\psi_p(x_i, x_j)$ é definida por:

$$\psi_p(x_i, x_j) = \begin{cases} 0, & y_i = y_j \\ 1, & y_i \neq y_j. \end{cases} \quad (3.6)$$

onde, y_i e y_j são os rótulos dos pixels i e j .

Apesar do modelo de Potts ser amplamente utilizado em problemas de processamento de imagens, ele falha na detecção de descontinuidades entre pixels vizinhos, o que causa uma suavização excessiva nas imagens (LV et al., 2018). Por isso, é necessário o uso de modelos potenciais que condicionem o processo de iteração espacial à diferença espectral entre os pixels vizinhos, de modo que seja possível mitigar o efeito de suavização. Modelos que permitem esse tipo de condicionamento são chamados de modelo *contrast sensitive Potts*, que tem sua estrutura apresentada na Equação 4.9.

$$\psi_p(x_i, x_j, I) = \begin{cases} 0, & \text{se } y_i = y_j \\ g(i, j), & \text{se } y_i \neq y_j \end{cases} \quad (3.7)$$

onde, y_i e y_j são os rótulos dos pixels i e j e I é a imagem de entrada. A função $g(i, j)$ modela a interação entre os pixels vizinhos i e j e mede a diferença espectral entre eles da seguinte forma:

$$g(i, j) = \theta_p + \theta_v \exp(-\theta_\beta \|x_i - x_j\|^2) \quad (3.8)$$

onde, θ_p , θ_v e θ_β são parâmetros do modelo que podem ser definidos *a priori* ou durante a fase de treinamento, x_i e x_j são os vetores de informações dos pixels i e j e $\|\cdot\|$ é a operação de norma. Em modelos não supervisionados, esses parâmetros podem ser definidos como 1 para simplificação, de modo que o modelo toma a seguinte forma:

$$g(i, j) = 1 + \exp(-\|x_i - x_j\|^2) \quad (3.9)$$

Mesmo utilizando uma componente de interação espacial sensível à variações espectrais, a imagem pode ficar super-suavizada de modo que os limites dos objetos podem ficar muito suavizadas. Além disso, esse tipo de função potencial é incapaz de impor dependências a nível regional entre os pixels, algo que é poderoso para problemas de rotulagem de imagens (KOHLI; ROTHER, 2012).

Portanto, o uso de modelos mais complexos, que usam a informação contextual em nível regional, é comum em algumas aplicações. No modelo de alta ordem, uma componente, que deriva a informação a partir de uma segmentação *a priori*, é adicionada. Essa componente influencia no processo de rotulação, de modo que todos os pixels pertencentes a um segmento, obtido *a priori*, possuam o mesmo rótulo. Este modelo é particularmente útil para a segmentação de objetos com limites bem definidos (KOHLI; ROTHER, 2012).

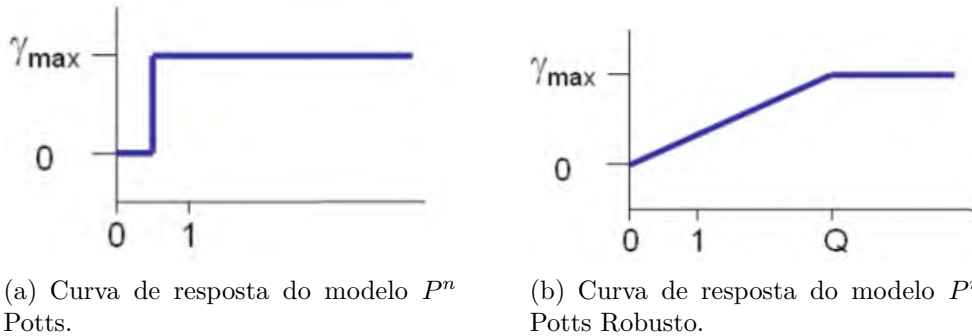
A função de alta-ordem mais simples pode ser derivada a partir do modelo de Potts. No modelo P^n Potts, Equação 3.10, a consistência dos rótulos é obtida por meio da aplicação de um custo ao rótulo que é diferente dos demais dentro de uma região obtida *a priori*, a saber:

$$\psi_c = \begin{cases} 0, & y_i = y_j \\ \theta_h^p |c| \theta^\alpha, & y_i \neq y_j. \end{cases} \quad (3.10)$$

onde, $|c|$ é a cardinalidade da vizinhança c , e θ_h^p e θ^α são parâmetros do modelo e a expressão $\theta_h^p |c| \theta^\alpha$ fornece o custo de inconsistência do rótulo.

Contudo, se todos os pixels de uma vizinhança, exceto um, tiverem o mesmo rótulo a mesma penalidade é inserida como se todos tivessem rótulos diferentes. Para resolver esse problema, Kohli et al. (2008) propuseram uma nova função potencial chamada de modelo P^n Potts Robusto. Essa função potencial insere a informação contextual não imediata de forma mais suave, através de um parâmetro que controla a curva da função potencial, como mostra a Figura 3.1.

Figura 3.1 - Comportamento das funções potenciais P^n Potts e P^n Potts Robusto.



Fonte: Adaptado de Kohli et al. (2008)

O custo associado a um rótulo é calculado em função da homogeneidade do segmento obtido *a priori*. De modo que o custo máximo é atribuído no caso de mais de um pixel com um rótulo diferente do rótulo dominante. No caso de uma rotulagem mais homogênea dentro do segmento, o custo é linearmente reduzido dependendo do número de pixels que não levam o rótulo dominante.

A principal vantagem dessa função é permitir que pequenos objetos existam dentro de uma segmentação, evitando que eles sejam suprimidos pela componente interação espacial. Contudo, essa função é altamente parametrizada, o que dificulta a sua aplicação em modelos não supervisionados.

3.4 Segmentação Baseada em Campos Aleatórios

A aplicação de Campos Aleatórios, especialmente os Markovianos, na segmentação de imagens não é algo novo. Uma das primeiras aplicações de MRF na Visão Computacional para a segmentação de imagens foi realizada por Hansen e Elliott (1982). Já no Sensoriamento Remoto, Bouman e Shapiro (1994) propuseram o método *Multiscale Random Field* (MSRF), que utiliza uma série de Campos Aleatórios Markovianos em uma estrutura Quadtree, seguindo a abordagem multiescala, para assimilar a informação contextual no processo de segmentação.

Seguindo a abordagem multiescala, He et al. (2004) propuseram a utilização de um modelo de CRF seguindo essa abordagem com o objetivo de capturar relações contextuais de longo alcance. Para isso, a distribuição a posteriori é definida como um produto de três distribuições condicionais para assim capturar informações contextuais em diferentes níveis de iteração.

Li (2010) propôs um método similar ao proposto por He et al. (2004). Neste método, que também segue a abordagem multiescala, utilizando uma estrutura Quadtree, a formulação do problema segue a mesma linha apresentada em Li et al. (2008). Cada bloco da *Quadtree* é definido aleatoriamente no intervalo inteiro $[1, n]$, onde n é o número de regiões a priori, de modo que o algoritmo começa com um conjunto de n grupos. O método explora a propriedade da markovianidade de um Campo Aleatório, que define que uma variável aleatória é condicionalmente independente de todas as outras variáveis em sua vizinhança. Através da definição da vizinhança é criada uma lista de votação, que é utilizada para determinar o rótulo ideal a ser atribuído a cada bloco da Quadtree, em função apenas da similaridade entre os níveis de cinza dos blocos. A principal vantagem desse método é não requerer informação *a priori* sobre a imagem, como por exemplo, o número de padrões contidos nela.

Ladický et al. (2014) propuseram o *Associative Hierarchical Random Fields* (AHRF), método semelhante ao MSRF, que combina diferentes segmentações realizadas *a priori*, mas de modo que todas contribuam efetivamente na segmentação final. Para isso é utilizado um potencial pareado que permite considerar a homogeneidade de rótulos, ou seja, o contexto de rótulos entre os superpixels e não suas similaridades espectrais.

No Sensoriamento Remoto a utilização de Campos Aleatórios para segmentação é quase que totalmente restrita aos Campos Markovianos, sendo os CRF muito mais aplicados na classificação de imagens e na detecção de mudanças em imagens

ópticas e na segmentação de imagens de Radar de Abertura Sintética (SAR). Segundo [Nazarinezhad e Dehghani \(2019\)](#) esse interesse ocorre porque nesses modelos é considerada a relação espacial entre os pixels adjacentes, o que mitiga a presença de pixels isolados e regiões muito pequenas, algo comum devido ao efeito *speckle*, que é intrínseco a esse tipo de imagem.

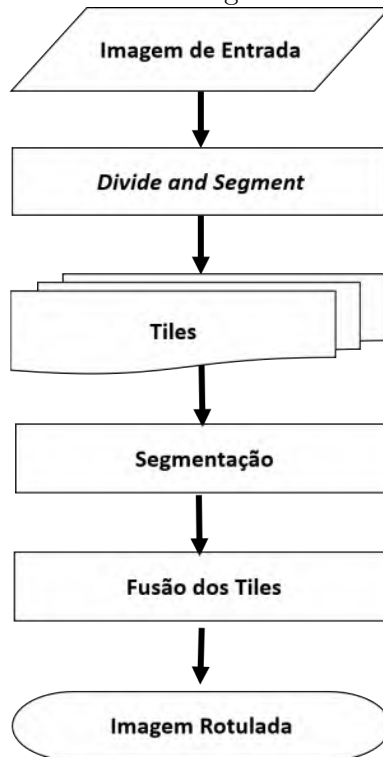
[Nazarinezhad e Dehghani \(2019\)](#) propuseram um método de segmentação para imagens SAR de alta-resolução espacial. Esse método utiliza uma segmentação realizada *a priori* pelo algoritmo *K*-Means combinada com a abordagem hierárquica para agrupá-los, através de uma métrica de similaridade que avalia a distância entre as funções de densidade de probabilidade de Wishart destes segmentos. O MRF é utilizado ao fim do processo, para incorporar a informação contextual. E utiliza o algoritmo ICM para minimizar o modelo de energia pareado, baseado no modelo de Potts.

4 UNSUPERVISED CONTEXTUAL SEGMENTATION

O método de segmentação proposto, *Unsupervised Contextual Segmentation* (UCS), é baseado na teoria de Campos Aleatórios Condicionais - CRF, e através de um modelo de energia de alta-ordem é capaz de rotular um pixel utilizando informações de contexto definidos na vizinhança 8-conectada e no contexto de não imediato. O UCS foi implementado utilizando na plataforma Matlab® devido à disponibilidade de pacotes básicos de processamento de imagem, e principalmente do algoritmo *Divide and Segment* utilizado no método.

A Figura 4.1 apresenta as etapas necessárias para realização da segmentação. Como pode ser observado a primeira etapa consiste na divisão da imagem de entrada em pequenos *tiles* para execução da segmentação em paralelo. A etapa de segmentação realiza o particionamento dos *tiles*, de modo que cada região irá possuir um rótulo único gerando ao fim dessa etapa *tiles* rotulados. Após a rotulação, os *tiles* são agregadas gerando a imagem rotulada que corresponde a segmentação da imagem de entrada.

Figura 4.1 - Estrutura do algoritmo de segmentação proposto.



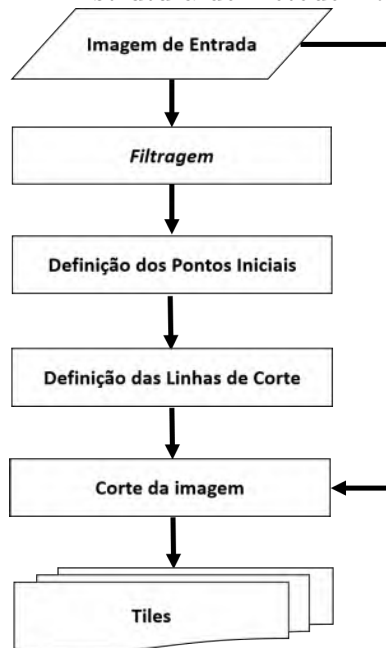
Fonte: Produção do autor.

O método de segmentação desenvolvido, possui uma fase de pré-processamento necessária para que seja possível sua execução em paralelo, visando aumentar a sua eficiência computacional. Essa fase inicial é responsável por dividir a imagem em *tiles* que sejam espacialmente coerentes, que são pequenas partes da imagem original onde os objetos contidos neles estão completos. Para essa tarefa, optou-se por utilizar o método *Divide and Segment* (SOARES et al., 2015; KÖRTING et al., 2013).

4.1 *Divide and Segment*

O método *Divide and Segment* tem como objetivo particionar uma imagem em *tiles* que sejam espacialmente coerentes. Para isso é criada uma linha de corte utilizando a informação de borda da imagem como guia. O processo para geração desta linha (Figura 4.2) tem como primeira etapa a filtragem da imagem de entrada para extração das bordas sob as quais a linha de corte será gerada. Com a imagem de borda são definidos os pontos iniciais para geração da linha para o corte da imagem. Com linha definida, o corte é realizado e os *tiles* criados.

Figura 4.2 - Estrutura do método *Divide and Segment*.



Fonte: Produção do autor.

A informação de borda é obtida através da combinação de filtros direcionais de Prewitt juntamente com filtro de mediana, para eliminar possíveis falhas ao longo

das bordas detectadas. Uma vez que estas feições são detectadas, o algoritmo cria uma linha de corte de forma adaptativa utilizando as bordas como guia para não cortar os objetos contidos na imagem. Através dessa linha, a imagem será cortada e os *tiles* serão criados.

Com estas pequenas partes da imagem é possível realizar a segmentação, ou outro processamento, de forma mais ágil uma vez que ele pode ser executado em paralelo. Além disso, mesmo com o particionamento inicial da imagem a coerência no resultado é mantida, uma vez que os objetos não deverão estar presentes em mais de um *tile* (WASSENBERG et al., 2009; HAPP et al., 2010; KÖRTING et al., 2011; MICHEL et al., 2012; LASSALLE et al., 2015; SOARES et al., 2015).

4.1.1 Detecção de bordas

A primeira fase do método é a de detecção de bordas. Esse processo é utilizado para encontrar as bordas dos objetos presentes na imagem. Essa é uma fase crucial, não apenas para o processo de geração dos *tiles*, mas também do processo de segmentação. Para isso, são utilizados filtros direcionais de Prewit, uma vez que eles realçam elementos lineares em direções específicas. Testes realizados por Soares et al. (2015) indicaram que através de filtros direcionais podem definir melhores caminhos para a geração da linha de corte.

Para criação desta linha é preciso considerar além dos pixels de maior intensidade, que representam as bordas mais significativas, seus vizinhos para evitar falhas ao longo das bordas. Essas falhas, que comumente ocorrem no processo de filtragem, podem dificultar a definição de uma linha de corte próxima do ideal. Por isso, após a filtragem utilizando os filtros direcionais, é utilizado o filtro de mediana para "preencher" possíveis falhas ao longo das bordas, de modo que eles não influenciem no processo de definição da linha de corte, como apresentado na Figura 4.3. Dessa forma, ao final desta etapa, serão obtidas duas imagens de borda, uma em cada direção (norte-sul e leste-oeste).


4.1.2 Definição dos pontos iniciais

Para geração da linha de corte é preciso determinar seu ponto de partida. A escolha desse ponto inicial é baseada na intensidade dos pixels. O ponto de partida sempre é o pixel com a maior intensidade na primeira coluna, ou linha, caso a linha de corte seja vertical. Caso existam dois pixels com intensidades iguais, o mais próximo do ponto de partida ideal é o escolhido. Esse ponto é o que deixa a imagem mais


Figura 4.3 - Imagem de bordas antes e após a aplicação do filtro de mediana.



(a) Imagem de entrada



(b) Imagem filtrada utilizando filtro direcional de Prewitt



(c) Imagem filtrada utilizando filtro direcional de Prewitt combinado com filtro de mediana

Fonte: Produção do autor.


simétrica possível em função do número de tiles desejados, que é definido *a priori* pelo usuário.

4.1.3 Definição da linha de corte

Depois de definir o ponto inicial, é criada uma matriz de adjacência com a qual será definida a linha de corte. De acordo com [Körting et al. \(2011\)](#), a matriz de adjacência é uma das formas de representação de um grafo, onde os vértices são os pixels da imagem e arcos são uma relação de adjacência entre pixels. Essa adjacência, é

definida por cinco conexões, como apresentado na Figura 4.4.

Figura 4.4 - Relações de adjacência utilizadas para construção da matriz de adjacência.



Fonte: Körting et al. (2011)

Os arcos, que conectam os nós do grafo, são ponderados de acordo com o valor do pixel. Se não há borda entre dois pixels, o valor do arco é atribuído como infinito. Desta forma o algoritmo não deve passar por esse arco. Quando a borda existe, o custo atribuído ao arco é mínimo em função da intensidade do pixel; quanto maior a sua intensidade, menor é seu custo. Para calcular a linha de custo mínimo entre os pontos inicial e final, optou-se pelo algoritmo de Dijkstra (DIJKSTRA, 1959).

Como o grafo demanda muita capacidade computacional, calcular a linha de corte sobre toda a imagem pode ser um problema. Para resolver esta questão, são criados blocos para limitar o tamanho do grafo. Usando esta estratégia, a linha de corte é criada com base no caminho mais curto entre as bordas de início e fim de cada bloco. Para evitar que os *tiles*, ao final do processo, possuam tamanhos muito diferentes, é definida uma área de amortização, que limita o deslocamento máximo da linha de corte. Uma vez que os *tiles* são gerados, é iniciado o processo de identificação de padrões para o processo de segmentação.

4.2 Segmentação

O funcionamento do método de segmentação proposto segue a abordagem não supervisionada baseada na técnica proposta por Li et al. (2008) combinada com a versão simplificada de CRF proposta por Zhang e Jia (2012), já aplicada na detecção de mudanças em imagens de Sensoriamento Remoto (LV et al., 2015; ZHOU et al., 2016; LV et al., 2018).

Originalmente a abordagem proposta por Li et al. (2008) foi desenvolvida para a

segmentação de séries temporais de expressão gênica, com o objetivo de identificar grupos de genes que possuem características comuns. Em seguida, foi estendida para a segmentação de imagens baseada na abordagem multi-escala (LI, 2010). Nessas duas aplicações, foram utilizados modelos pareados de energia. Neste trabalho, essa abordagem foi adaptada para utilizar um modelo de energia de alta-ordem para que as relações de dependência de longo-alcance também possam ser consideradas.

A abordagem proposta por Li et al. (2008), explora as características locais de um Campo Aleatório, também conhecida como *Markovianidade*. Essa propriedade, define que uma variável aleatória é condicionalmente dependente de todas as outras variáveis em sua vizinhança, ou seja, apenas os rótulos de pixels vizinhos têm interações diretas entre si.


Na abordagem proposta nesse trabalho cada rótulo que pode ser atribuído a um pixel i , é tratado como uma variável aleatória X_i . Como a abordagem Bayesiana tem como premissa que os objetos contidos na imagem seguem um padrão, se cada padrão for associado a um rótulo, o objetivo final da segmentação é assinalar um rótulo ótimo y , condicionando-o através dos dados observados em x_j , além dos rótulos dos pixels y_j , para todos os j pixels em uma vizinhança N_i . Dessa forma, a máxima probabilidade *a posteriori* é condicionada em função dos dados observados em i e no seu entorno, definido por:

$$P(y_i|x_i, x_{N_i}, y_{N_i}) \propto P(x_i, x_{N_i}|y_i, y_{N_i})P(y_i|y_{N_i}) \quad (4.1)$$

onde $P(x_i, x_{N_i}|y_i, y_{N_i})$ e $P(y_i|y_{N_i})$ representam são a distribuição de probabilidade condicional e a distribuição de probabilidade *a priori*, respectivamente, e x_{N_i} e y_{N_i} representam os valores observados e os rótulos na lista de votação, N_i , respectivamente.

No método proposto para cada pixel i da imagem é criada uma lista de votação, com o tamanho definido pelo total de rótulos/padrões possíveis na imagem. Dentro dessa lista ficam contidas as energias calculadas através de um modelo de alta-ordem que será detalhado a seguir. A Figura 4.5 ilustra as fases necessárias para execução do método. Inicialmente, os *tiles* que foram gerados através dos método *Divide and Segment* são lidos e em seguida passam por uma etapa inicial, responsável por definir o número de padrões na imagem. Em seguida, com essa quantidade definida é realizada uma rotulação inicial da imagem que é utilizada para inicialização do processo de minimização de energia, de modo que ao fim do processo é gerada uma

imagem rotulada.



Fonte: Produção do autor.

4.2.1 Extração de marcadores para identificação de padrões

A definição do número de grupos/padrões na imagem é crucial no processo de segmentação proposto. No UCS são utilizados os mínimos regionais da imagem como indicativo da quantidade de padrões existentes na imagem. Esses componentes conectados, são formados por pixels adjacentes que possuem o mesmo valor de intensidade (JAHNE et al., 1999; DOUGHERTY; LOTUFO, 2003). Geralmente esses componentes estão localizados nas partes centrais de objetos homogêneos.

A utilização de mínimos regionais durante o processo de segmentação não é algo novo, sendo especialmente utilizado no algoritmo Watershed (SADRKAZEMI; CILLIERS, 1997; LOTUFO et al., 2002; FALCÃO et al., 2004). Contudo, esses mínimos podem levar a uma superestimação da quantidade de padrões na imagem. Como forma de resolver esse problema, é comum a utilização da técnica de imposição dos mínimos regionais (IMR) (SOILLE, 1999). Essa técnica tem como objetivo eliminar mínimos regionais pouco significativos.

Devido a limitação da quantidade de bandas que podem ser utilizadas para a definição dos mínimos regionais através da técnica de IMR na plataforma onde o algoritmo foi desenvolvido, optou-se por utilizar uma imagem de borda para realizar o processo de imposição. Para criação dessa imagem, é calculado o gradiente de cada banda da imagem, que em seguida é normalizado, de forma que todas as bandas possuam a mesma relevância. Posteriormente, os gradientes de cada uma das bandas da imagem de entrada são integrados através da equação abaixo:


$$\nabla_{image} = \sum_i^{\lambda} w_{\lambda} \nabla_{\lambda} \quad (4.2)$$

onde λ é o número de bandas e w_{λ} é o peso atribuído a cada banda. Essa estratégia

também permite que o usuário forneça pesos diferentes para cada banda, podendo orientar o algoritmo a definir melhor certos objetos.

Com a imagem de bordas definida, é então realizado o processo de filtragem dos mínimos regionais através da IMR. Segundo Soille (1999) a imposição de mínimos pode ser realizada a partir da reconstrução morfológica da imagem. No método proposto o algoritmo utiliza a técnica de reconstrução morfológica por abertura.

Esta técnica é realizada utilizando um elemento de estruturante para definir a conectividade entre os mínimos regionais. O algoritmo proposto, utiliza uma combinação de 4 elementos estruturantes ilustrados na Figura 4.6.

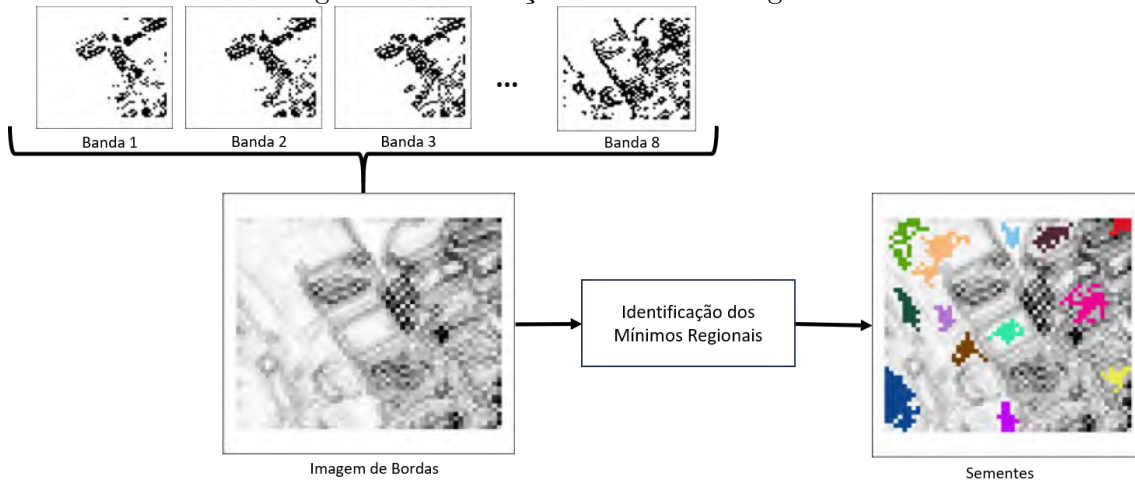


Fonte: Produção do autor

Com cada um dos elementos estruturantes apresentados, é realizada a filtragem dos mínimos regionais através da reconstrução por abertura. Ao final, é obtida uma imagem com a indicação das posições dos mínimos regionais identificados por cada um dos elementos estruturantes, que por fim são agregadas, gerando assim uma imagem de mínimos regionais única.

Utilizando essa abordagem sobre a imagem de bordas é possível obter pixels que são similares ao longo de todas as bandas da imagem, já que durante o processo de detecção, apenas grupos de pixels iguais espectralmente podem produzir um mínimo regional. A Figura 4.7, ilustra o processo de integração das bandas da imagem de entrada e os mínimos regionais ao final do processo.

Figura 4.7 - Definição dos mínimos regionais.




Fonte: Produção do autor

O principal limitante do uso de mínimos regionais no processo de segmentação, é que eles podem levar a super-segmentação da imagem, já que um objeto pode conter dois ou mais mínimos regionais, por exemplo. Como forma de contornar esse problema, optou-se por unir regiões utilizando um parâmetro, chamado de similaridade.

Este parâmetro atua como um condicionante, que permite unir mínimos regionais que sejam similares espectralmente, conforme Figura 4.8, onde após o processo de IMR número de padrões encontrados eram de 12, e após a etapa de agregação em função da similaridade esse número caiu para 8. Dessa forma, evita-se que o número de grupos seja maior que a real quantidade de padrões na imagem.

Figura 4.8 - Resultados da etapa de união das sementes. a) Imagem original, b) sementes obtidas no processo de detecção dos mínimos Regionais (12 padrões) e c) sementes após a etapa de união (re-rotulação) (8 padrões).



Fonte: Produção do autor

De forma prática, a união das regiões implica na sua re-rotulação, de modo que as duas regiões similares possuam o mesmo rótulo. Dessa forma, a quantidade de rótulos na imagem define o número de grupos contidos nela, sendo essa informação necessária para realização da próxima etapa, a rotulação inicial da imagem. Essa classificação inicial é fundamental no processo, já que irá prover a rotulação inicial necessária para o método.

4.2.2 Rotulação Inicial

Para realizar o processo de minimização, é necessário uma rotulação inicial da imagem, para isso seguindo a abordagem não supervisionada de Lv et al. (2018), o método proposto utiliza o algoritmo *Fuzzy C-Médias* (FCM), utilizando como número de classes, a quantidade de padrões definido pelos mínimos regionais. O FCM realiza o agrupamento dos pixels de forma iterativa, buscando em cada iteração um conjunto de grupos e os centros de grupo que representam a estrutura dos dados da melhor forma possível.

No algoritmo FCM, também é conhecido como *soft K-Médias*, cada pixel no espaço de atributos é ponderado para um grupo, de modo que o pixel não é definido de forma rígida como pertencente ou não a um grupo. Pelo contrário, ele possui diferentes níveis de pertinência, mais forte ou mais fraco, para cada um dos grupos. Para tal tarefa, o algoritmo minimiza uma função objetivo, que avalia os deslocamentos entre os dados e os centros dos grupos, definida por:

$$J_h = \sum_{i=1}^R \sum_{j=1}^N u_{ji}^h \|x_i - r_j\|^2 \quad (4.3)$$

onde: h é qualquer número real maior que 1, u_{ij} é o grau de associação de x_i no agrupamento j , x_i é o i -ésimo elemento, R é o número de agrupamentos, c_j é o centro do agrupamento j e $\|*\|$ é qualquer norma que expresse a semelhança entre quaisquer dados medidos e o centroide de um grupo. O particionamento é realizado através de uma otimização iterativa da função objetivo, com a atualização da associação u_{ij} e do centro do grupo c_j por:

$$u_{ij} = \frac{1}{\sum_{t=1}^R \left(\frac{\|x_i - r_j\|}{\|x_i - r_t\|} \right)^{\frac{2}{h-1}}} \quad (4.4)$$

$$c_j = \frac{\sum_{i=1}^N u_{ij}^h x_i}{\sum_{i=1}^N u_{ij}^h} \quad (4.5)$$

A iteração pára quando ϵ , que é um critério de parada, é menor que a função $\max_{ij} \{|u_{ij}^{(t+1)} - u_{ij}^t|\}$, onde t é o número de iterações. No final, para um dado pixel, a soma dos valores de pertinência para todos os grupos é de 1.

Embora a classificação não supervisionada possa não gerar bons resultados, no método proposto, assume-se que esta imagem é um bom ponto de partida para o processo de segmentação. Espera-se que boa parte das inconsistências na atribuição dos rótulos devem ser resolvidas com a inclusão da informação proveniente do potencial de iteração espacial e de alta-ordem.

4.2.3 Modelo de Energia

Segundo Kohli e Rother (2012), modelos de energia de alta-ordem são bastante úteis para a segmentação de objetos com limites bem definidos. Dessa forma, no método proposto optou-se pelo uso desse tipo de modelo de energia.

Geralmente modelos de alta-ordem são compostos por três componentes: (1) a componente unária, usualmente definida por um classificador, que utiliza um vetor de informações sobre uma região ou pixel e retorna a probabilidade desse pixel pertencer a um rótulo; (2) a componente de iteração espacial que provê um nível inicial de

informação contextual, já que descreve a compatibilidade entre o pixel em análise e seus vizinhos, no caso do modelo proposto, dentro da vizinhança 8-conectada e (3) a componente de alta-ordem, fornece a informação contextual não-imediata e indica como um pixel está relacionado com seu entorno além da vizinhança 8-conectada. Dessa forma o modelo proposto é definido como:

Dada uma imagem I , contendo N pixels, e \mathcal{E} é o conjunto de todos os pares de pixels vizinhos ao pixel i , o modelo de energia adotado é expresso por:

$$E_i(y_i, y_{N_i}, x_i, x_{N_i}, x_s) = \psi_u(x_i, y_i) + \sum_{(i,j) \in \mathcal{E}} \psi_{ij}(x_i, x_j, y_i, y_j) + \psi_s(x_s) \quad (4.6)$$

onde, a componente unária $\psi_u(x_i, y_i)$ é a medida de probabilidade inversa, ou seja, ela é o custo do pixel i receber o rótulo y_i , e as componentes de iteração espacial $\psi_{ij}(x_i, x_j)$ são o custo dos rótulos y_i, y_j para os pixels i, j simultaneamente, S é o conjunto de *superpixels* obtidos *a priori* e ψ_s é a componente potencial de alta ordem. A seguir cada uma das componentes serão detalhadas.

4.2.3.1 Componente Unária

A componente unária, também chamada de componente de associação, relaciona um pixel a um rótulo. De forma geral, qualquer algoritmo que forneça graus de pertinência pode ser aplicado. No UCS, como apresentado anteriormente, foi utilizado o algoritmo de clusterização *Fuzzy C-Médias*. A componente unária é definida da seguinte forma:

$$\psi_u(x_i, y_i) = -\log(P(x_i, y_i)_{FCM}) \quad (4.7)$$

A função log é utilizada para converter a probabilidade fornecida pelo classificador para o domínio de energia. Dessa forma, quanto maior a probabilidade, menor é a energia.

4.2.3.2 Componente de Iteração Espacial

Em formulações tradicionais de CRF, a componente de iteração espacial é expressa por:

$$\phi(y_i, y_j, x_i, x_j, \theta_\phi) = \sum_{i=1}^N \sum_{j=1}^N \theta_{\phi_{ij}}^T \mu(x_i, x_j) \delta(y_i = i) \delta(y_j = j) \quad (4.8)$$

onde, ϕ é o potencial de iteração espacial responsável por impor a informação contextual imediata, $\theta_{\phi_{ij}}^T$ é o vetor de parâmetros transposto, $\mu(x_i, x_j)$ é o vetor de característica que concatena todos os elementos de dois vetores espectrais observados (x_i, x_j) .

Para ajustar o parâmetro $\theta_{\phi_{pq}}$, é necessária uma etapa de treinamento que é complexa e que inviabiliza uma abordagem não supervisionada. Contudo, [Zhang e Jia \(2012\)](#) propôs uma abordagem onde $\theta_{\phi_{pq}}$ se torna um escalar dentro do potencial de iteração espacial. Desta forma, não há necessidade de treinamento para essa componente, o que permite a aplicação do CRF de forma não supervisionada. Essa abordagem é a utilizada nesse trabalho.

Como apresentado no Capítulo 3, o modelo clássico de Potts falha na detecção de descontinuidades, provocando a suavização da imagem. Dessa forma, é necessária a utilização de modelos mais restritivos, que considerem a variação espectral entre os pixels e não apenas a igualdade entre os rótulos. Ou seja, funções que sejam capazes de considerar tanto a informação contextual de rótulos quanto a espectral. Dessa forma, considerando a proposta de [Zhang e Jia \(2012\)](#), no método proposto a função *Contrast Sensitive Potts*, é definida por:

$$\psi_{ij}(y_i, y_j, x_i, x_j) = \begin{cases} 0, & \text{se } y_i = y_j \\ 1 - g_{i,j}, & \text{se } y_i \neq y_j \end{cases} \quad (4.9)$$

Nesta função, o problema de suavização pode ser reduzido, pois ele considera as características espectrais dos pixels, o que reduz a probabilidade de pixels com diferença espectral significativa possuam o mesmo rótulo. Essa função modela a interação entre os pixels vizinhos i e j , medindo a diferença espectral entre eles por meio da norma quadrada da diferença entre os pixels. Segundo [Suhubi \(2003\)](#), qualquer espaço vetorial induzido por uma norma se torna naturalmente um espaço métrico.

$$g_{i,j} = \frac{(\|x_i - x_j\|^2)}{2\sigma^2} \quad (4.10)$$

onde x_i e x_j representam as respostas espectrais dos pixels i e j e σ^2 é o parâ-

metro de similaridade definido pelo usuário. Desta forma, quanto maior o número de pixels, na vizinhança 8-conectada, que pertencem a mesma classe do pixel analisado, mesmo com pequena diferença espectral entre eles, menor é sua energia.

4.2.3.3 Componente de Alta-Ordem

Esta componente é responsável por assimilar a informação de contexto de não imediato. Dessa forma, é possível identificar como um determinado pixel se relaciona com os demais pixels em nível regional. Uma estratégia para obter esta informação é através de Superpixels. Segundo Cigula e Alatan (2010), essas regiões tem como característica serem bastante significativas, já que cada Superpixel agrupa pixels espectralmente semelhantes. Uma característica importante dos Superpixels é que eles devem aderir bem as bordas dos objetos, de modo que em um superpixel, não devem existir mais do que um objeto. Essa característica é especialmente relevante para o método proposto, já que é exatamente esse nível de informação necessária para impor consistência a imagem. Com os superpixels, é possível obter a quantidade de rótulos distintos numa mesma região que determinado pixels, extrair a probabilidade máxima para cada rótulo dentro de um superpixel, além de saber qual o rótulo dominante em uma região.

O método proposto utiliza o algoritmo de segmentação SLIC0. Esse algoritmo foi escolhido pela sua simplicidade, já que depende apenas de um parâmetro, além da sua eficiência computacional. Uma vez que os superpixels são obtidos, para cada região, é extraída a máxima probabilidade para cada rótulo y , conforme equação abaixo:

$$\psi_s(x_s) = \max\{-\log(P(x_s = l_i))\}, \quad i \in Y \quad (4.11)$$

Usando essa abordagem, a rigidez da função P^n Potts é evitada, assim como do P^n Potts Robusta (KOHLI et al., 2008), que demanda uma série de parâmetros, tornando o processo de segmentação mais complexo.

4.2.4 Minimização de energia

A utilização de uma lista de votação para definir o melhor rótulo para um pixel, segue os mesmos fundamentos do método de minimização proposto por Besag (1986), o "Iterated Conditional Modes". Em sua implementação Li et al. (2008), utilizaram uma abordagem "winner-take-all", onde é atribuído ao pixel o rótulo de menor

energia, ou seja, o rótulo com maior probabilidade dentre os demais.

Para cada pixel da imagem é calculada, usando o modelo de energia proposto, a probabilidade dele receber cada um dos rótulos possíveis. O pixel recebe o rótulo daquele que teve a menor energia dentre todos os demais (SZELISKI et al., 2006). Esse processo é repetido até a convergência da imagem rotulada.

Apesar do método ser computacionalmente eficiente, ele apresenta alguns problemas em função da sua sensibilidade à rotulação inicial (VEKSLER; ZABIH, 1999). Se a rotulagem inicial não for satisfatória, o erro pode ser disseminado na imagem após algumas iterações.

4.3 Funcionamento

O método UCS possui 2 parâmetros: um associado à similaridade espectral e outro a escala, que define o quanto de informação contextual não imediata será considerada no modelo. O parâmetro de similaridade é utilizado para reduzir o número de rótulos e evitar que um objeto seja definido por dois ou mais rótulos oriundos do processo de detecção do mínimo regional. Além disso, ele também é utilizado no cálculo da componente de iteração espacial, como apresentado anteriormente.

Já o parâmetro de escala é utilizado exclusivamente no algoritmo SLIC0, para definir o tamanho médio dos superpixels a serem gerados pelo algoritmo. Quanto maior este valor, maiores são as regiões, ou seja, valores pequenos restringem a capacidade contextual do algoritmo, tornando o segmentador mais local.

Após a definição do número de padrões contidos na imagem, a partir dos mínimos regionais, esse valor é utilizado para a classificação com o algoritmo FCM. Além da imagem classificada, que é utilizada como rotulagem inicial para o processo de segmentação, as probabilidades de cada pixel receber cada um dos possíveis rótulos são calculadas.

O processo de segmentação ocorre de forma iterativa. A cada nova iteração, novas energias para cada pixel são calculadas. Dentro da iteração, a primeira etapa é a de cálculo da componente de iteração espacial e sua principal função é garantir a consistência da rotulação, eliminando pixels isolados e contribuindo para resolução de inconsistência em regiões de borda. Para cada pixel da imagem seus vizinhos, na vizinhança 8-conectada, são analisados. O intuito dessa análise é avaliar o contexto imediato do pixel na sua vizinhança, considerando tanto o contexto de rótulo quanto o espectral. Uma vez que todos os vizinhos são analisados, as energias para cada

rótulo são somadas. Se todos os vizinhos tiverem o mesmo rótulo, a energia do pixel para esse rótulo será igual a 0.

Após o cálculo da componente de iteração espacial, é realizado o cálculo da componente de alta-ordem. Para isso é utilizada a segmentação proveniente do algoritmo SLIC0. As regiões geradas nessa segmentação, são utilizadas para analisar a vizinhança não imediata de um pixel. Caso as probabilidades indicarem que dentro de uma região a probabilidade dos pixels pertencerem a um determinado rótulo for maior que dos demais rótulos, essa informação indica que os pixels dessa região tendem a receber aquele rótulo. De forma objetiva, essa componente responde às seguintes perguntas:

- Eu e meus vizinhos fazemos parte de um único objeto na imagem? Quão diferente sou em relação a cada um deles?
- Todos os meus vizinhos, dentro de um mesmo superpixel, possuem um rótulo igual ao meu?

A resposta da primeira pergunta, apesar de ser parcialmente respondida pela componente de iteração espacial, é reafirmada pela componente de alta-ordem. Já a resposta para a segunda pergunta é mais significativa pois, indica se o rótulo de um determinado pixel é coerente com seu entorno.

Após o cálculo de todas as funções potenciais, seus valores são normalizados e só então a energia final é calculada. Dessa forma garante-se que as três componentes influenciam o resultado com o mesmo peso. Com a lista de votação definida, o rótulo que possui a menor energia dentro da lista de votação é atribuído ao pixel. Uma vez que todos os pixels da imagem têm suas energias atualizadas, o processo é iniciado novamente. Desta vez, a imagem rotulada, utilizada como dado de entrada para a componente de iteração espacial é a imagem rotulada da iteração anterior. Caso a imagem de saída seja idêntica à imagem rotulada da iteração anterior, após todos os pixels terem sido processados, a segmentação é finalizada. O algoritmo abaixo, apresenta uma visão geral do método de segmentação proposto.

Algoritmo 1 Pseudo-código do processo de Segmentação.

UCS - Unsupervised Context-based Segmentation Algorithm by Conditional Random Fields

1. Realize o processo de filtragem na imagem para extração de imagem de borda
 2. Extraia marcadores na imagem de borda a partir da técnica de imposição do mínimo regional
 3. Agrupe os marcadores que são similares espectralmente
 4. Use o número de grupos obtidos após o agrupamento para classificar a imagem através do algoritmo Fuzzy C -Médias
 5. Execute o algoritmo SLIC0 para geração dos superpixels
 6. Para cada pixel i
 - 6.1. Crie uma lista de votação, N_i
 - 6.2. Calcule as funções de custo dos rótulos na votação
 - 6.3. Calcule as probabilidades dos rótulos com base em suas funções de custo
 - 6.4. Atribua o rótulo com a maior probabilidade ao pixel i
 7. Volte para o Passo 6 se o rótulo de qualquer pixel for atualizado, caso contrário pare
-

5 RESULTADOS E AVALIAÇÃO

Nesse capítulo, inicialmente serão apresentados os *datasets* bem como as métricas utilizadas para avaliação do desempenho do método UCS. Em seguida serão apresentados os resultados obtidos em cada um dos *datasets* utilizados.

5.1 Construção dos *Datasets*

Para avaliação do desempenho do método, foram criados 4 *datasets*, sendo dois com imagens de média resolução espacial, 1 de alta-resolução e mais 1 de altíssima resolução espacial. As tabelas 5.1 e 5.2 apresentam informações sobre as imagens utilizadas.

Tabela 5.1 - Informações das imagens de alta resolução.

Sensor	WorldView-2	Quickbird
Data de aquisição	21/02/2011	17/05/2004
Localização	São José dos Campos/SP	São José dos Campos/SP
Tamanho da imagem	5024×8632	2371×1948
Resolução Espacial	2m	60cm
Resolução Radiométrica	11 bits	16 bits
Número de Bandas	8	4

Fonte: Produção do autor

Tabela 5.2 - Informações das imagens de média resolução.

Sensor	OLI/Landsat-8	MUX/CBERS-4
Data de aquisição	07/04/2018	23/04/2018
Localização	Nova Xantina/MT	Nova Xantina/MT
Tamanho da imagem	310×322	466×483
Resolução Espacial	30m	20m
Resolução Radiométrica	12 bits	8 bits
Número de Bandas	7	4

Fonte: Produção do autor


5.2 Avaliação dos Resultados

Como apontado por Neubert et al. (2008), a avaliação da segmentação é uma tarefa crucial para o desenvolvimento de abordagens efetivas e também na determinação de parâmetros ótimos. Apesar dos diversos métodos de avaliação disponíveis na literatura, a análise visual ainda é utilizada. As suas principais limitações estão na subjetividade do processo, na falta de informações qualitativas, e no esforço para analisar grandes áreas que podem conter dezenas de milhares de polígonos. Dessa forma, neste trabalho apesar de avaliar a segmentação visualmente, a análise dos resultados do algoritmo proposto será realizada em função de métricas supervisionadas.

Para avaliação através das métricas supervisionadas, para as imagens WorldView-2 e Quickbird, 96 e 93 objetos de referência, respectivamente, foram definidos para avaliação (Apêndice A). Objetos com contornos bem definidos, como telhados de casas, pequenos edifícios, praças públicas, armazéns industriais e corpos d'água com tamanhos e formas distintos, foram escolhidos como referência.

Para as imagens OLI/Landsat-8 e MUX/CBERS-4, um segundo intérprete selecionou 141 objetos, com características de entorno distintas, desde objetos com bordas mais significativas em relação ao entorno e como também com bordas menos proeminentes. Estes objetos representam áreas agrícolas e pastagens, como mostra a Figura 5.1.

Figura 5.1 - Polígonos de Referência dos *datasets* OLI e MUX.



(a) Referência OLI.

(b) Referência MUX.

Fonte: Produção do autor

Essas métricas utilizam abordagens com base nos parâmetros de segmentação, nas bordas do segmento ou no próprio segmento (ZHANG et al., 2015). Neste caso, o número de pixels do segmento gerados pelo algoritmo de segmentação e o número de pixels da região de referência são usados (NEUBERT et al., 2008). Neste trabalho foram utilizadas 6 métricas supervisionadas propostas por Rijsbergen (1979) e Delves et al. (1992).

5.2.1 Precisão-Revocação

A métrica Precisão proposta por Rijsbergen (1979), indica a quantidade de elementos que foram identificados como corretos, quando efetivamente eram corretos. Essa métrica tem por característica indicar valores elevados mesmo que apenas um elemento tenha de fato sido corretamente rotulados, apesar de todos os outros terem sido incorretamente rotulados como pertencentes a outra classe.

$$Precisão = \frac{VP}{VP + FP} \quad (5.1)$$

onde, VP é a quantidade de elementos que foram corretamente rotulados a uma dada classe, VN é a quantidade de elementos que foram corretamente rotulados

como não pertencentes uma dada classe e FP é a quantidade de elementos que foram incorretamente rotulados a uma dada classe.

Já a Revocação, diferente da Precisão, indica com qual frequência um elemento é realmente rotulado como pertencente a uma classe. De acordo com Casanova (2011), a desvantagem dessa métrica é que ela não leva em consideração todos os elementos, o que pode fazer com que essa métrica seja superestimada em alguns casos.

$$Revocação = \frac{VP}{VP + VN} \quad (5.2)$$

onde, VN é a quantidade de elementos que foram incorretamente rotulados como não pertencentes uma dada classe.

As medidas Precisão e Revocação podem ser utilizadas em conjunto para indicar a qualidade de segmentação. Em um caso ideal, quando a segmentação é idêntica à referência, tanto a Precisão quanto a Revocação devem atingir o valor máximo de 1 (ZHANG et al., 2015).

Uma forma de visualizar os resultados obtidos entre as métricas de Precisão e Revocação é através de um gráfico de dispersão, onde cada uma das métricas correspondem um eixo. A partir da Figura 5.2 avalia-se o resultado da segmentação. As partes superiores direita e inferior esquerda representam a boa e má segmentação, respectivamente. A porção superior direita, é a ideal por indicar altos valores de Precisão e Revocação, diferentemente da inferior esquerda que indica baixos valores dessas métricas.

Através da combinação da Precisão e da Revocação é possível ainda obter outra métrica, a *F-measure*, que leva em conta tanto os falsos positivos quanto os falsos negativos. Ela é definida por:

$$F\text{-measure} = \frac{2 \cdot \text{Precisão} \cdot \text{Revocação}}{\text{Precisão} + \text{Revocação}} \quad (5.3)$$

5.2.2 Medidas de Sucesso

Delves et al. (1992) propuseram que, para cada região da segmentação de referência uma região resultante do segmentador seja selecionada para avaliação, que é chamada de *Bestfit*. Diferente do método proposto por Zhang et al. (2015), esse método

Figura 5.2 - Gráfico Precisão-Revocação.



Fonte: Achanccaray et al. (2014)

detecta se o segmento resultante foi diferente da segmentação referência em função da sua forma, tamanho, área e intensidade dos pixels dentro do segmento.

Seja a segmentação de referência, Q , com R segmentos e a segmentação a ser avaliada, O , com L segmentos, ambas com H colunas e W linhas. Seja, uma determinada região na segmentação de referência, p , e um determinado segmento, f , na segmentação a ser avaliada. A notação \bar{g}_p representa a média da métrica g em uma dada região p , $N(p)$ representa o número de pixels de p e x_p e y_p indicam a localização do ponto dentro do segmento p , respectivamente coluna e linha (REIS et al., 2015). Duas matrizes, Gf e Fit , ambas com H linhas e W colunas, são construídas utilizando as seguintes equações:

$$Gf(p, f) = \frac{N(p \cap f)}{N(p \cup f)} \quad (5.4)$$

$$Fit = \frac{xd + yd + \frac{pd+id}{2}}{Gf(p, f)} \quad (5.5)$$

no qual:

$$xd = \frac{|\bar{x}_p > -\bar{x}_f|}{H} \quad (5.6)$$

$$yd = \frac{|\bar{y}_p - \bar{y}_f|}{W} \quad (5.7)$$

$$pd = \frac{|N(p) - N(f)|}{|N(p) + N(f)|} \quad (5.8)$$

$$id = \frac{|V(\bar{p}) - V(\bar{f})|}{|V(\bar{p}) + V(\bar{f})|} \quad (5.9)$$

Usando as matrizes Fit e Gf 4 métricas são calculadas: $FITXY$, $FITI$, $FITN$, G_{shape} . Cada uma é calculada para cada região.

$$FITXY = 1 - \frac{xd + yd}{2} \quad (5.10)$$

$$FITI = 1 - \frac{|\langle V(p) \rangle - \langle V(f) \rangle|}{\langle V(p) \rangle + \langle V(f) \rangle} \quad (5.11)$$

$$FITN = 1 - \frac{|N(p) - N(f)|}{N(p) + N(f)} \quad (5.12)$$

$$G_{shape}(p, f) = \frac{N(p \cap f)}{N(p \cup f)} \quad (5.13)$$

A métrica $FITXY$ (Equação 5.10) define o grau de deslocamento entre o resultado do algoritmo de segmentação avaliado e o segmento de referência. Neste caso, o centro de gravidade de ambos os polígonos é calculado e comparado. A métrica $FITI$ (Equação 5.11) compara a intensidade de nível de cinza dos segmentos, utilizando a imagem original.

$FITN$ (Equação 5.12), por sua vez, compara a corretude entre o número de pixels do polígono de referência e com o número de pixels segmento gerado pelo algoritmo analisado. G_{shape} (Equação 5.13) compara a forma do segmento gerado pelo algoritmo e a referência. Essa métrica avalia se o algoritmo conseguiu definir a forma dos objetos na imagem de forma correta. Todas as métricas produzem valores no intervalo $[0, 1]$. Pode-se usar a média de todas métricas, denotada como FITM, como uma única métrica.

Para definição do segmento a ser comparada com a referência, sempre foi escolhido o segmento de maior sobreposição em relação ao polígono de referência. Uma vez que esse segmento era determinado, as métricas eram calculadas bem como as médias para cada um dos *datasets*.

No caso específico da imagem WorldView-2, por questão de tempo de processamento, optou-se por segmentar apenas pequenas partes da imagem que continham polígonos de referência, como ilustrado na Figura 5.3. Uma vez que os polígonos de referência (polígono amarelo) foram delineados, seus polígonos envolventes (polígono vermelho) foram utilizados para geração de polígonos e com eles foram gerados *buffers* de 50 metros (polígono verde). Através desses polígonos maiores, a imagem WorldView-2 foi cortada em pequenas partes, uma para cada referência e essas partes foram então segmentadas. Com os segmentos gerados, o processo de avaliação seguiu o mesmo dos demais *datasets*.

Figura 5.3 - Processo de geração do *dataset* WorldView-2



Fonte: Produção do autor

5.2.3 Teste de Hipótese

Para comparação do desempenho do algoritmo proposto, foram selecionados 3 algoritmos de segmentação amplamente utilizados no Sensoriamento Remoto. São eles: o Multirresolução (MRS), disponível no software *Definiens eCognition*, o algoritmo de crescimento por regiões proposto por [Bins et al. \(1996\)](#), disponível nos *softwares* TerraView e que a partir de agora será denominado como "algoritmo de Bins", e o algoritmo Meanshift, disponível no software Qgis, através do módulo Sextante e proposto por [Comaniciu e Meer \(1997\)](#).

Para avaliar se os resultados obtidos pelo método UCS eram de fato significativos, foram realizados teste de hipótese, para determinar se os resultados obtidos pelo segmentador UCS eram estatisticamente iguais ou não aos dos demais algoritmos analisados. Para isso foi utilizado o Teste de hipótese de Wilcoxon. Foram definidos 3 possíveis testes. O primeiro avaliou se os resultados do UCS eram estatisticamente iguais ou diferentes aos dos demais algoritmos considerando a significância com 5%; O segundo teste avaliou se os resultados do UCS eram superiores aos dos demais algoritmos; O terceiro para avaliar se os resultados do UCS eram inferiores, nesse caso como no anterior a significância foi definida em 2,5%.

5.3 Desempenho do Algoritmo

5.3.1 Tempo de Execução

Para avaliar o desempenho do algoritmo proposto, testes foram realizados utilizando uma estação de trabalho com 24GB de RAM, processador Core i7–6700 com 3.4GHz e AMD Radeon R5 340X e um servidor octa-core com 64GB de memória RAM. O software utilizado foi o MATLAB 2016b.

Considerando apenas a etapa de segmentação, a etapa de minimização de energia foi o gargalo do método proposto, representando, em média, 99% do tempo total de processamento, que foi de 105 segundos em média para os pequenos recortes do *dataset* WorldView-2. A inicialização, para esse *dataset*, inclui leitura de imagem, definição de semente, fusão de sementes e criação de superpixels, o que representou menos de 1%.

Os *datasets* Quickbird, OLI/Landsat-8 e MUX/CBERS-4, passaram pelo *Divide and Segment* que realiza a divisão da imagem em *tiles*. Na imagem Quickbird, esse processo durou pouco mais de 2 minutos, enquanto para as imagens OLI e MUX menos de 30 segundos foram gastos.

5.3.2 *Divide and Segment*

O método *Divide and Segment* foi utilizado em três dos *datasets* nos quais o algoritmo de segmentação foi avaliado. A imagem Quickbird foi dividida em 100 tiles (Figura 5.4) para otimizar o processo de segmentação. Apesar da eficiência deste método, alguns objetos foram divididos. Contudo, a grande maioria dos objetos não foi afetada no processo de divisão. A maior parte dos objetos (telhados) que foram cortados, apresentavam variações de intensidade causados pela variação na luminosidade, como mostra a Figura 5.5. Este problema foi observado especialmente em residências com mais de um pavimento e que apresentavam telhados em diferentes níveis. Apesar de não terem sido delimitados como referências, várias árvores foram divididas em função da iluminação sobre o dossel.

Figura 5.4 - Resultado do *Divide and Segment* na imagem Quickbird (Composição Colorida: R3G2B1).



Fonte: Produção do autor


Figura 5.5 - Telhados cortados pela imagem gerada pelo *Divide and Segment* sobre composição colorida: R3G2B1.



Fonte: Produção do autor

Para a imagem OLI (Figura 5.7(a)) foram gerados 16 *tiles*. Nessa imagem, 25 das 141 referências utilizadas, foram afetadas pela linha de corte, sendo divididas em duas ou mais partes. Além disso, pequenas falhas ocorreram em áreas de vegetação devido à iluminação. Na imagem MUX/CBERS-4 (Figura 5.7(b)) também foram gerados 16 *tiles*. Nessa imagem, o algoritmo apresentou desempenho melhor, onde apenas 15 dos 139 polígonos foram afetados pela linha de corte.

Figura 5.6 - Linhas de corte para divisão dos tiles.



(a) Linhas de corte da imagem OLI sobre composição colorida: R4G3B2.

(b) Linhas de corte da imagem MUX sobre Composição Colorida: R3G2B1.

Fonte: Produção do autor

5.3.3 *Fuzzy C*-Means - Componente Unária


Por padrão, o algoritmo de classificação utiliza os seguintes parâmetros para o processo de classificação: taxa de sobreposição entre os *clusters* de 1.5, número máximo de 10.000 iterações e o incremento mínimo (ϵ) da função objetivo de 10^{-15} . Esses mesmos parâmetros foram utilizados para todos os *datasets*.

Os resultados obtidos pelo algoritmo *Fuzzy C*-Means foram bons, sobretudo nas imagens de alta resolução espacial WorldView-2 e Quickbird, como apresentados nas Figuras 5.7 e 5.8 que são referentes a parte destas imagens. Na Figura 5.7, o algoritmo apresentou um bom desempenho apesar da qualidade espectral da imagem, oriunda do processo de fusão, estar bem degradada.

Figura 5.7 - Classificação obtida para imagem WorldView-2 utilizando estratégia não supervisionada. Linhas pretas delimitam as referências utilizadas.



(a) Imagem WorldView-2 - Composição Colorida: R4G3B2.



(b) Classificação obtida pelo algoritmo FCM para imagem WorldView-2

Fonte: Produção do autor

Figura 5.8 - Classificação obtida para imagem Quickbird utilizando estratégia não supervisionada. Linhas pretas delimitam as referências utilizadas e linhas pretas pontilhadas, o limite do tile gerado através do Dividir e Segmentar.



(a) Imagem Quickbird - Composição Colorida: R3G2B1.




(b) Classificação obtida pelo algoritmo FCM para imagem Quickbird.

Fonte: Produção do autor

Apesar do desempenho satisfatório do algoritmo nas imagens de alta-resolução, o algoritmo não teve bons resultados nas imagens de média resolução OLI/Landsat-8 e MUX/CBERS-4. Nessas imagens, como grande parte das áreas são de vegetação, a diferença espectral entre os pixels é pequena, principalmente na imagem MUX/CBERS-4. Na imagem OLI (Figura 5.9) as áreas de pastagem, em função da sua pequena variação espectral, apresentaram um grande desafio para determinação de um parâmetro ótimo de similaridade. Em um cenário ideal, a classificação deveria isolar cada um dos objetos na imagem. Como pode ser observado nas figuras abaixo isto não aconteceu.

Figura 5.9 - Classificação obtida para imagem OLI utilizando estratégia não supervisionada. Linhas pretas delimitam as referências utilizadas.




(a) Imagem OLI - Composição Colorida: R4G3B2.

(b) Classificação obtida pelo algoritmo FCM para imagem OLI.

Fonte: Produção do autor

Na imagem MUX/CBERS-4, Figura 5.10, este problema aconteceu novamente e de forma intensa, apesar de que em alguns casos a classificação obtida foi satisfatória. A Figura 5.11 apresenta a diferença espectral entre as sementes obtidas durante a etapa de identificação de padrões descrita no capítulo anterior. Na imagem MUX, a diferença entre sementes foi na maioria dos casos muito pequena, apresentado uma diferença menor que 10 níveis digitais.

Figura 5.10 - Classificação obtida para imagem MUX utilizando estratégia não supervisionada.




(a) Imagem MUX/CBERS-4 - Composição colorida: R3G2B1

(b) Classificação obtida pelo algoritmo FCM para imagem MUX.

Fonte: Produção do autor

Figura 5.11 - Histograma da diferença espectral entre as mínimos regionais da imagem MUX.



Fonte: Produção do autor

5.4 Testes de Segmentação

Para produzir os resultados das segmentações, os parâmetros foram determinados empiricamente de modo a gerar uma supersegmentação da imagem para evitar que dois objetos fossem representados por um único segmento, mas ainda assim sempre tentando obter 1 segmento por objeto. Para avaliação destes resultados, foram escolhidas 6 métricas supervisionadas, que avaliam a corretude da segmentação em relação ao tamanho ($FITN$), forma (G_{shape}) e centro de gravidade das regiões definidas pelo segmentador ($FITXY$), como também sua Precisão, Revocação e F-measure em relação às referências.

5.4.1 Worldview-2

Para testar a segmentação da imagem WorldView-2, foram definidos os seguintes parâmetros para o algoritmo MRS:

- Escala: 45;
- Forma: 0, 3;
- Compacidade: 0, 7 ;
- Peso 2 para as bandas localizadas na região do infravermelho, as demais tiveram o peso definido como 1.

Para o algoritmo de Bins, foram definidos os seguintes parâmetros:

- Tamanho mínimo: 30;
- Similaridade: 0,0025;

Para o algoritmo Meanshift, foram definidos os seguintes parâmetros:

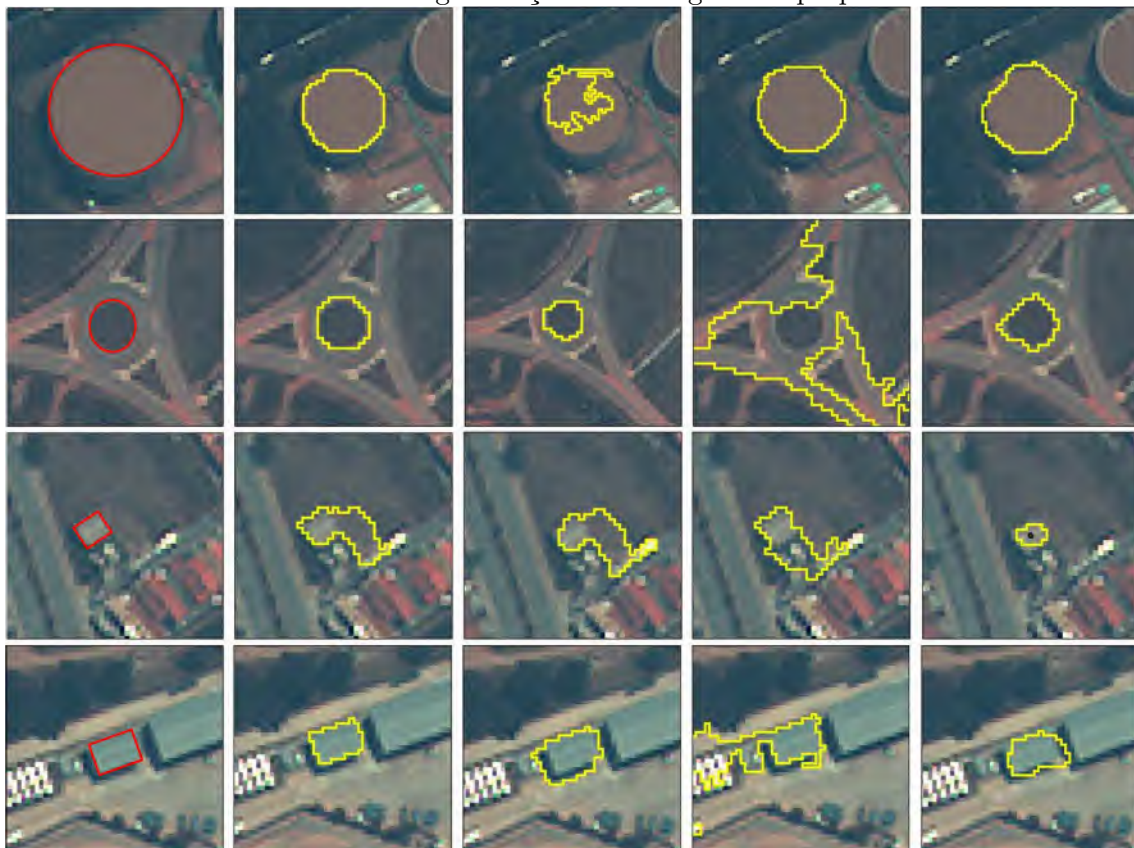
- Raio espacial: 30;
- Raio da faixa: 40;
- Tamanho mínimo: 40;

Para o segmentador UCS, proposto neste trabalho, foram definidos os seguintes parâmetros:

- Similaridade: 220;
- Escala: 25;

A Figura 5.12, apresenta resultados de segmentação de alguns dos *tiles* gerados no *dataset* WorldView-2, considerando os segmentadores mencionados acima. Para estes objetos, visualmente, o algoritmo MRS e o algoritmo proposto obtiveram os melhores resultados. Na primeira imagem, linha 1, o MRS obteve o melhor resultado, seguido pelo algoritmo de Bins. Eles conseguiram boa aderência às bordas, enquanto o algoritmo proposto falhou nesse quesito. Já o Meanshift, obteve o pior dos resultados, super-segmentando o objeto, não aderindo à borda e nem preservando a forma do objeto. Para o segundo objeto, o Meanshift obteve o melhor resultado, aderindo bem às bordas, assim como o MRS e o algoritmo proposto. Neste caso, o algoritmo de Bins apresentou o pior resultado.

Figura 5.12 - Da esquerda para direita: Imagem original com a referência sobreposta, segmentação com MRS, segmentação com Meanshift, segmentação com o algoritmo de Bins e a segmentação com o algoritmo proposto.



Fonte: Produção do autor

Tabela 5.3 - Resultados obtidos por cada algoritmo.

Métrica	MRS	Meanshift	Bins	UCS
Precisão	$0,801 \pm 0,258$	$0,768 \pm 0,254$	$0,741 \pm 0,243$	$0,820 \pm 0,207$
Revocação	$0,782 \pm 0,173$	$0,741 \pm 0,228$	$0,775 \pm 0,201$	$0,751 \pm 0,199$
F-measure	$0,750 \pm 0,198$	$0,693 \pm 0,190$	$0,709 \pm 0,175$	$0,753 \pm 0,167$
<i>FITXY</i>	$0,963 \pm 0,041$	$0,957 \pm 0,043$	$0,953 \pm 0,040$	$0,965 \pm 0,032$
<i>FITN</i>	$0,873 \pm 0,131$	$0,833 \pm 0,148$	$0,833 \pm 0,154$	$0,890 \pm 0,129$
G_{shape}	$0,730 \pm 0,195$	$0,671 \pm 0,192$	$0,659 \pm 0,195$	$0,738 \pm 0,174$


Fonte: Produção do autor

Na terceira linha, o algoritmo proposto obteve o melhor resultado aderindo muito bem às bordas dos objetos, enquanto os demais falharam nesse ponto em uma das laterais do objeto. Na última linha o MRS obteve o melhor resultado dentre os demais. Enquanto o Meanshift e o algoritmo de Bins cresceram bastante além das bordas, o algoritmo proposto não subsegmentou muito o objeto como os demais, mas não aderiu muito bem às bordas como o MRS, que gerou um segmento bastante fiel à forma e com grande aderência às bordas.

A Tabela 5.3 apresenta os valores médios e os desvios padrão, todos truncados em 3 casas decimais, que foram obtidos pelo algoritmo proposto e demais algoritmos. Esses resultados indicam a eficiência do algoritmo UCS, uma vez que ele obteve resultados superiores aos demais na maioria das métricas de avaliação, exceto em Revocação. Essa métrica está relacionada com a capacidade do algoritmo de identificar todos os pixels que fazem parte do segmento em análise, de modo que quando ela é menor que 1 indica que alguns pixels que pertencem a região não foram definidos como pertencentes a ela, ou seja, houve um super-segmentação do objeto. Na métrica *FITXY*, que está avaliando o deslocamento do centro de massa do segmento gerado em relação ao centro de massa da referência, todos os algoritmos analisados alcançaram seus melhores resultados, onde a média obtida por todos os algoritmos foi acima de 0,95.

A seguir são apresentados boxplots do tipo violino para cada uma das métricas utilizadas na avaliação. As seções mais largas deste tipo de boxplot representam áreas com maior probabilidade de ocorrência daquele valor. Por outro lado, as áreas mais estreitas indicam uma menor probabilidade. Como é possível observar em todas as métricas, as regiões mais largas estão localizadas na parte superior do gráfico, sobretudo, na métrica *FITXY*.


Segundo a métrica Precisão (Figura 5.13) a distribuição dos resultados do algoritmo UCS concentrou a área mais larga na parte superior, acima de 0,75, assim como o MRS. Contudo, o algoritmo proposto por Baatz e Schäpe (2000), apresentou maior variação interquartil que a do algoritmo proposto. O Meanshift apresentou um resultado semelhante, mas com uma área menos larga na região acima de 0,75. Já o algoritmo de Bins apresentou uma amplitude grande nessa métrica e a menor mediana dentre todos.



Fonte: Produção do autor

Para a Revocação (Figura 5.14) a distribuição do método proposto concentrou seus resultados na parte superior do gráfico, acima de 0,75, além disso ele apresentou a menor amplitude, enquanto o Meanshift apresentou a maior. Diferentemente da métrica Precisão, nenhum dos algoritmos obteve *outliers* na sua distribuição.


Figura 5.14 - Boxplot da métrica Revocação no *dataset WorldView-2*.



Fonte: Produção do autor


Para a métrica F-Measure (Figura 5.15) todos os algoritmos apresentaram *outliers*, exceto o Meanshift. Contudo ele possui a maior variação interquartil. O MRS e o algoritmo proposto mais uma vez apresentaram distribuições semelhantes, mas o método proposto apresentou amplitude e variação interquartil menor.

Figura 5.15 - Boxplot da métrica F-Measure no *dataset WorldView-2*.



Fonte: Produção do autor


Para a métrica *FITXY* (Figura 5.16) todos os algoritmos obtiveram excelentes resultados, com distribuições semelhantes, contudo o algoritmo proposto apresentou o menor número de *outliers*.



Fonte: Produção do autor

Na métrica *FITN*, o algoritmo proposto obteve uma diferença significativa em relação ao demais. Mesmo com a presença de *outliers*, e com variação interquartil similar à do MRS, a distribuição dos resultados obtidos com o algoritmo proposto foi mais estreita na parte inferior, e com grande concentração na parte superior, acima de 0,85. Por outro lado, o MeanShift e o algoritmo de Bins, apresentaram uma distribuição uniforme ao longo da parte superior do gráfico.


Figura 5.17 - Boxplot da métrica $FITN$ no *dataset WorldView-2*.



Fonte: Produção do autor

Em relação à métrica G_{shape} (Figura 5.18) o MeanShift e o algoritmo de crescimento por regiões apresentaram distribuições concentradas na parte central do gráfico, em torno de 0,65, enquanto o MRS e o algoritmo proposto além de concentrarem suas distribuições acima de 0,75, também apresentaram variações interquartil menores que os demais.

Figura 5.18 - Boxplot da métrica G_{shape} no *dataset WorldView-2*.



Fonte: Produção do autor

Como os resultados dos algoritmos apresentaram uma diferença pequena no seu desempenho, sobretudo entre o MRS e o algoritmo UCS, foram realizados testes de hipótese de Wilcoxon, para avaliar se de fato os algoritmos tiveram o mesmo desempenho ou se um deles foi superior ao outro.

Os resultados dos testes de hipótese, apresentados a seguir, indicam que para o *dataset* WorldView-2 o algoritmo proposto é estatisticamente igual ao MRS em todas as métricas analisadas, além de ser superior aos demais algoritmos na maioria delas.

Tabela 5.4 - Precisão - WorldView-2

Proposto X	<i>p-valor</i>	Conclusão
MRS	0,7099	Igual
Meanshift	0,1118	Igual
Bins	0,9992	Superior

Tabela 5.6 - F-Measure - WorldView-2

Proposto X	<i>p-valor</i>	Conclusão
MRS	0,8775	Igual
Meanshift	0,9990	Superior
Bins	0,9970	Superior

Tabela 5.8 - *FITN* - WorldView-2

Proposto X	<i>p-valor</i>	Conclusão
MRS	0,0782	Igual
Meanshift	0,9999	Superior
Bins	0,9999	Superior

Tabela 5.5 - Revocação - WorldView-2

Proposto X	<i>p-valor</i>	Conclusão
MRS	0,2201	Igual
Meanshift	0,9395	Igual
Bins	0,2511	Igual

Tabela 5.7 - *FITXY* - WorldView-2

Proposto X	<i>p-valor</i>	Conclusão
MRS	0,9236	Igual
Meanshift	0,1858	Igual
Bins	0,9997	Superior

Tabela 5.9 - G_{shape} - WorldView-2

Proposto X	<i>p-valor</i>	Conclusão
MRS	0,2304	Igual
Meanshift	0,9993	Superior
Bins	0,9999	Superior


Fonte: Produção do autor

Para observar como se dá a relação entre as métricas Precisão e Revocação nos resultados do MRS e do algoritmo proposto, os resultados obtidos nesse *dataset* foram plotados em um gráfico de dispersão, como mostra a Figura 5.19. Nesse gráfico, os resultados do MRS são exibidos como círculos pretos, enquanto os resultados do algoritmo proposto são exibidos como triângulos pretos.

O algoritmo MRS obteve bons resultados, como pode ser observada a alta concentração de círculos no canto superior direito da Figura 5.19. O algoritmo proposto obteve

bons resultados para Precisão. No entanto, um desempenho inferior para Revocação. De forma geral, podemos concluir que o algoritmo proposto super-segmentou os objetos mais que o algoritmo MRS.

Figura 5.19 - Gráfico de dispersão - Precisão e Revocação.



Fonte: Produção do autor

5.4.2 Quickbird

Para a imagem Quickbird, utilizamos utilizados os seguintes parâmetros para o algoritmo MRS:

- Escala: 28;
- Forma: 0,6;
- Compacidade: 0,9.

Para o algoritmo de Bins, definimos os seguintes parâmetros:

- Tamanho mínimo: 20;
- Similaridade: 0,0015;

Para o método Meanshift definimos os seguintes parâmetros:

- Raio espacial: 30;
- Raio da faixa: 40;
- Tamanho mínimo: 40;

Para o algoritmo proposto, definimos os seguintes parâmetros:

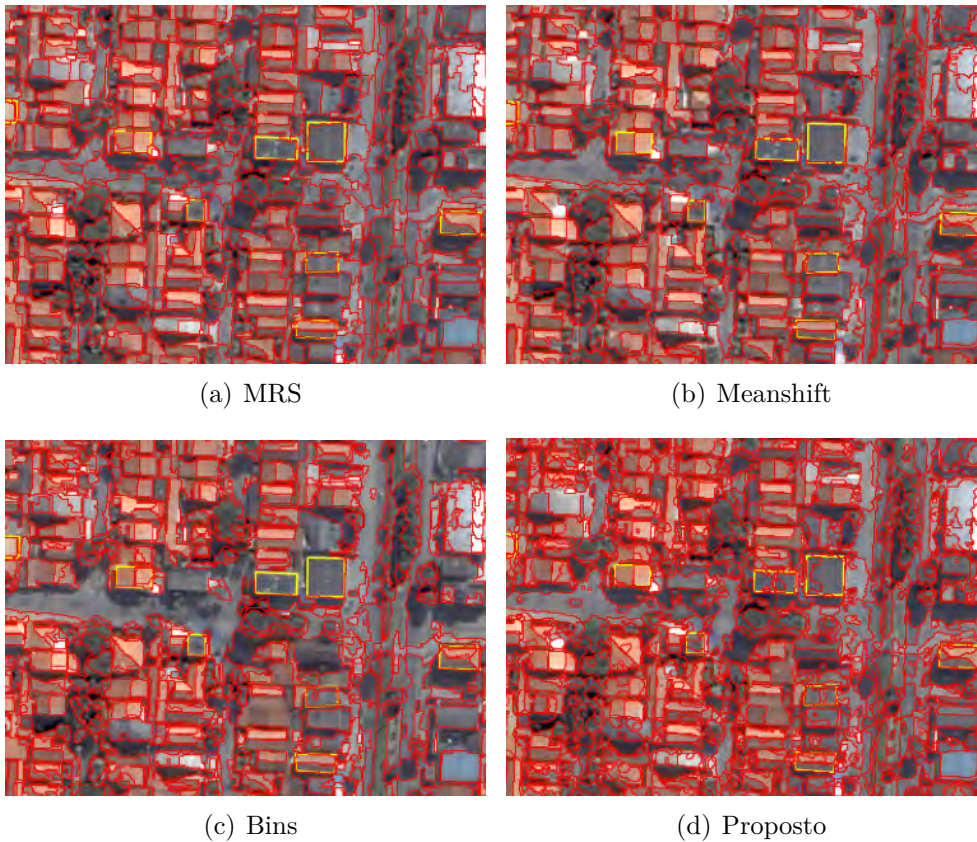
- Similaridade: 85;
- Escala: 100;

Devido ao processo de fusão que a imagem Quickbird passou ela ficou bastante degradada; alguns telhados ficaram bastantes saturados e as bordas de alguns objetos não tiveram boa definição. Isso influenciou significativamente o desempenho dos algoritmos, especialmente na métrica Revocação.

A Figura abaixo apresenta os resultados da segmentação produzida pelos algoritmos em parte da imagem Quickbird. Todas as segmentações produzidas para esse *dataset* e os seguintes, estão apresentados no Apêndice 3. O MRS obteve o melhor resultado dentre todos como mostra a Figura 5.21(a). O método aderiu bem as bordas, mas dividiu a maioria dos telhados da imagem, o que influenciou no desempenho em relação à métrica Revocação. Assim como o MRS, o Meanshift (Figura 5.21(b)) obteve bons resultados no geral, segmentando bem objetos com bom contraste em relação ao entorno. O algoritmo de Bins não produziu boa segmentação (Figura 5.21(c)) subsegmentando alguns objetos. Diferentemente do algoritmo de Bins, o algoritmo proposto supersegmentou a imagem.

Como é possível observar na Tabela 5.10, todos os algoritmos alcançaram resultados próximos de 0,6 na métrica Revocação, sendo que o Meanshift obteve o melhor resultado, assim como na métrica *FITN*. Nas demais métricas, o MRS obteve os

Figura 5.20 - Resultados da segmentação do *dataset* Quickbird. Polígonos amarelos são as referências delineadas por um especialista e os polígonos com bordas vermelhas são os resultados produzidos por cada algoritmo.



Fonte: Produção do autor

melhores resultados, com um resultado bastante superior aos demais em relação à métrica Precisão, superando o algoritmo proposto por Bins em quase 0,2.

O Meanshift, depois do MRS, apresentou os melhores resultados, ficando com desempenho próximo na métrica F-Measure. O algoritmo proposto por Bins mais uma vez apresentou o pior resultado dentre todos, especialmente na métrica Precisão. O algoritmo proposto apresentou resultados ruins devido às bordas pouco definidas em alguns dos objetos, apesar disso, superou o algoritmo proposto por Bins e ficou próximo dos resultados alcançados pelo Meanshift.

A seguir, apresentamos os boxplots para cada uma das métricas utilizadas. Para métrica Precisão (Figura 5.21), a exceção do MRS, todos os demais algoritmos apresentaram grande amplitude nas distribuições. Além disso, o MRS, o Meanshift e o algoritmo proposto possuíram vários *outliers*. Neste gráfico, podemos observar o

Tabela 5.10 - Resultados obtidos por cada algoritmo para o *dataset* Quickbird.


Métrica	MRS	Meanshift	Bins	UCS
Precisão	$0,931 \pm 0,098$	$0,799 \pm 0,241$	$0,703 \pm 0,351$	$0,810 \pm 0,227$
Revocação	$0,560 \pm 0,212$	$0,602 \pm 0,220$	$0,587 \pm 0,223$	$0,565 \pm 0,230$
F-measure	$0,673 \pm 0,162$	$0,625 \pm 0,172$	$0,529 \pm 0,231$	$0,604 \pm 0,178$
<i>FITXY</i>	$0,973 \pm 0,027$	$0,969 \pm 0,028$	$0,956 \pm 0,041$	$0,967 \pm 0,035$
<i>FITN</i>	$0,861 \pm 0,114$	$0,863 \pm 0,148$	$0,833 \pm 0,145$	$0,857 \pm 0,129$
<i>G_{shape}</i>	$0,754 \pm 0,141$	$0,727 \pm 0,161$	$0,685 \pm 0,173$	$0,726 \pm 0,152$

Fonte: Produção do autor

baixo desempenho dos algoritmos, em especial o do algoritmo proposto por Bins.

A distribuição dos resultados deste algoritmo foi esparsa ao longo do gráfico, apresentando variação interquartil muito significativa, variando entre 0,45 e 0,98. É importante ressaltar que a distribuição do Meanshift e do algoritmo proposto também ficaram longe do ideal, apesar de serem muito melhores que o do algoritmo de Bins. Ainda, nos gráficos, podemos observar como o MRS foi mais regular que os demais na métrica Precisão.


Figura 5.21 - Boxplot da métrica Precisão no *dataset* Quickbird.



Fonte: Produção do autor

Para a Revocação (Figura 5.22) as distribuições foram bastante similares, nas me-


dianas (0,45), variação interquartil (0,4 – 0,75) e forma. Além disso, nessa métrica não ocorreram *outliers* em nenhum dos resultados gerados pelos algoritmos. Apesar de possuírem uma forma bastante similar entre eles, a distribuição dos resultados do MRS obteve uma maior amplitude e ficou mais concentrada na região de 0,5.



Fonte: Produção do autor

Para a métrica F-Measure (Figura 5.23) o algoritmo de Bins apresentou a maior variação interquartil (0,43 – 0,67) e a menor mediana (0,58). Além disso, ocorreram outliers e o mínimo foi próximo a 0. Já o MRS apresentou a maior mediana (0,65) e menor amplitude, de modo que esses resultados evidenciam o melhor desempenho do MRS. Já o Meanshift apesar de possuir a menor amplitude e a distribuição dos resultados ter permanecido próximo a 0,6, seus resultados foram um pouco piores que o MRS. O algoritmo proposto teve seus resultados concentrados entre 0,45 e 0,65, diferente do MRS e Meanshift.


Figura 5.23 - Boxplot da métrica F-Measure no *dataset* Quickbird.



Fonte: Produção do autor

Para a métrica *FITXY* todos os algoritmos tiveram excelentes resultados (Figura 5.24), com medianas em 0,99, apesar da existência de *outliers*, especialmente nos resultados do algoritmo de Bins, mas ainda assim com bom ajuste, acima de 0,85.

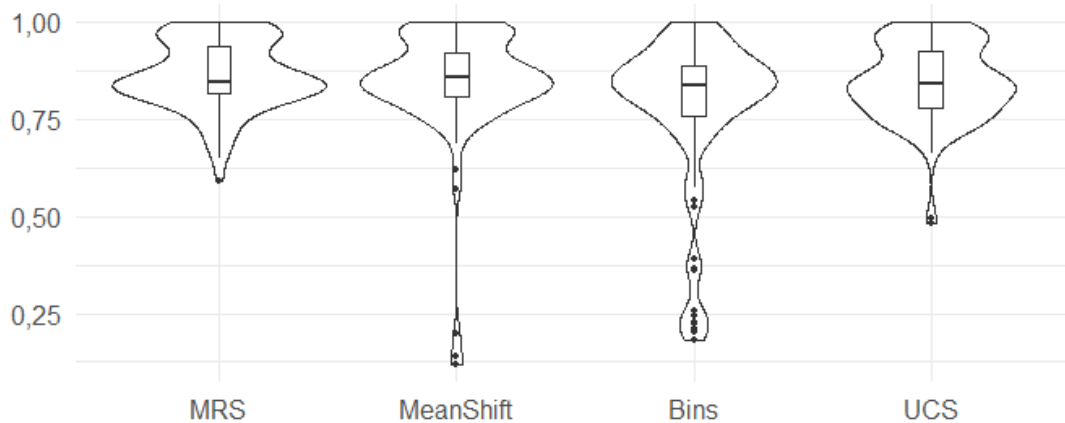
Figura 5.24 - Boxplot da métrica *FITXY* no *dataset* Quickbird.



Fonte: Produção do autor

Para a métrica $FITN$, diferentemente do que aconteceu nas demais, o resultado do algoritmo proposto apresentou maior variação interquartil. Apesar disso, a maior parte dos dados ficaram em torno de 0,8. O resultado do MRS apresentou a menor amplitude. Os resultados do algoritmo de Bins apresentaram grande amplitude além de um grande número de *outliers*, 12. Já o Meanshift, apesar de também apresentar *outliers*, teve sua distribuição similar ao MRS.


Figura 5.25 - Boxplot da métrica $FITN$ no *dataset* Quickbird.



Fonte: Produção do autor

Em relação à métrica G_{shape} (Figura 5.26), que avalia a forma dos segmentos, as distribuições do MRS e Meanshift apresentaram formas semelhantes, apesar do Meanshift apresentar *outliers*, além disso também tiveram medianas similares, com diferença menor que 0,012. O algoritmo de Bins apesar de possuir a menor variação interquartil, novamente apresentou muitos *outliers*, 13 no total, positivamente e negativamente. O algoritmo proposto apresentou resultados um pouco abaixo do MRS, em torno de 0,3 e bastante similares ao Meanshift.

Figura 5.26 - Boxplot da métrica G_{shape} no *dataset* Quickbird.



Fonte: Produção do autor

Da mesma forma como foi realizado nos testes da imagem WorldView-2, foram realizados testes de hipótese de Wilcoxon. Pode-se observar nas tabelas abaixo que o algoritmo UCS obteve um desempenho inferior ao MRS apenas na métrica Precisão. Nas demais, eles foram estatisticamente iguais com α 5%. Já em relação ao Meanshift, o algoritmo proposto foi estatisticamente igual em todas as métricas. Quando comparado com os resultados do algoritmo de Bins, os resultados obtidos foram iguais estatisticamente em apenas 2 das 6 métricas (Revocação e *FITN*).

Diferentemente dos resultados obtidos no *dataset* WorldView-2, o algoritmo proposto obteve resultados inferiores ao MRS, como pode ser comprovado pelos testes de hipótese de Wilcoxon; algoritmo proposto teve desempenho inferior ao MRS em 4 das 6 métricas analisadas. Quando comparado ao Meanshift, o método proposto teve desempenho semelhante, perdendo apenas na métrica Revocação. Quando comparado ao algoritmo de Bins, ele obteve um desempenho superior em 3 das 6 métricas analisadas.

Na segmentação pelo algoritmo proposto, mais de 88 mil polígonos foram gerados, enquanto o MRS gerou pouco mais de 27 mil (Figura 5.27). Dos 88 mil segmentos gerados, aproximadamente 40 mil deles possuíam áreas menores que $5m^2$. Devido a isto, nesse *dataset* testamos a utilização de um parâmetro de área mínima, para remover esses pequenos segmentos e avaliar o efeito que esse parâmetro poderia causar no resultado do algoritmo. Esta operação foi realizada no software ArcGIS 10.1,

Tabela 5.11 - Precisão - Quickbird

Proposto X	<i>p</i> -valor	Conclusão
MRS	1	Inferior
Meanshift	0,6974	Igual
Bins	0,1705	Igual

Tabela 5.13 - F-Measure - Quickbird

Proposto X	<i>p</i> -valor	Conclusão
MRS	0,9933	Inferior
Meanshift	0,1816	Igual
Bins	0,9950	Superior

Tabela 5.15 - *FITN* - Quickbird

Proposto X	<i>p</i> -valor	Conclusão
MRS	0,3342	Igual
Meanshift	0,2652	Igual
Bins	0,9797	Superior

Tabela 5.12 - Revocação - Quickbird

Proposto X	<i>p</i> -valor	Conclusão
MRS	0,9290	Igual
Meanshift	0,9854	Inferior
Bins	0,3492	Igual

Tabela 5.14 - *FITXY* - Quickbird

Proposto X	<i>p</i> -valor	Conclusão
MRS	0,9963	Inferior
Meanshift	0,8076	Igual
Bins	0,0613	Igual


Tabela 5.16 - G_{shape} - Quickbird

Proposto X	<i>p</i> -valor	Conclusão
MRS	0,9926	Inferior
Meanshift	0,2397	Igual
Bins	0,9970	Superior

Fonte: Produção do autor

através da ferramenta *Eliminate*. Os segmentos menores que $20m^2$ foram agregados aos adjacentes de maior área sem levar em conta a informação espectral.

Figura 5.27 - Total de segmentos gerados por cada algoritmo de segmentação no *dataset Quickbird*.



Fonte: Produção do autor

A Tabela 5.17, apresenta os resultados obtidos após a etapa de agregação dos segmentos. Apesar da informação espectral não ter sido considerada, a remoção dos polígonos menores resultou em uma pequena melhora, especialmente na Revocação, e por consequência na F-Measure, além da *FITXY*. Além disso, houve redução dos desvios padrão. A Figura 5.28, apresenta as segmentações geradas pelo algoritmo proposto, com e sem a agregação dos segmentos menores que $20m^2$.


Tabela 5.17 - Resultados obtidos pelo algoritmo UCS antes e após a agregação dos polígonos menores que $20m^2$.

Métrica	Antes da Agregação	Após Agregação
Precisão	$0,810 \pm 0,227$	$0,748 \pm 0,251$
Revocação	$0,565 \pm 0,230$	$0,628 \pm 0,213$
F-measure	$0,604 \pm 0,178$	$0,623 \pm 0,181$
<i>FITXY</i>	$0,967 \pm 0,035$	$0,988 \pm 0,014$
<i>FITN</i>	$0,857 \pm 0,129$	$0,854 \pm 0,136$
<i>G_{shape}</i>	$0,726 \pm 0,152$	$0,717 \pm 0,132$

Fonte: Produção do autor

Como é possível observar, a etapa de agregação melhorou a definição de alguns segmentos, resultando segmentos mais coerentes em relação a borda.

Figura 5.28 - Segmentação da imagem Quickbird antes e depois do processo de agregação. Os segmentos pretos foram gerados sem a área mínima, os vermelhos foram obtidos após a agregação dos polígonos menores que $20m^2$.



Fonte: Produção do autor

5.4.3 Landsat-8/OLI

Para este dado, os seguintes parâmetros para o método MRS foram definidos:

- Escala: 100;
- Forma: 0, 1;
- Compacidade: 0, 3.

Para o algoritmo de Bins, definimos os seguintes parâmetros:

- Tamanho mínimo: 100;

- Similaridade: 0,0015;

Para o método Meanshift, definimos os seguintes parâmetros:

- Raio espacial: 5;
- Raio da faixa: 280;
- Tamanho mínimo: 100;


Para o algoritmo proposto, definimos os seguintes parâmetros:

- Similaridade: 480;
- Escala: 200;

Durante os testes, observamos que a supersegmentação é a melhor solução para todos os algoritmos, uma vez que a porção inferior da imagem apresenta bordas muito suaves.


A Figura a seguir apresenta a segmentação produzida pelos algoritmos para o *dataset* OLI/Landsat-8. O MRS obteve o melhor resultado dentre todos como mostra a Figura 5.30(a), apesar da dificuldade em aderir bem nas bordas mais fracas presentes na imagem, o que levou a sub-segmentação em alguns casos. Já o Meanshift, na Figura 5.30(b), obteve bons resultados no geral, apresentando algumas áreas com sub-segmentação, em quantidade um pouco superior ao MRS. O algoritmo de Bins não produziu uma boa segmentação, mostrada na Figura 5.30(c). Na porção superior, alguns objetos foram super-segmentados enquanto que na porção inferior outros objetos foram subsegmentados. O ajuste dos parâmetros não foi satisfatório para toda a imagem. O algoritmo proposto super-segmentou severamente a imagem (Figura 5.30(d)) resultado da classificação inicial e da pouca efetividade da componente pareada para a suavização da imagem.

Figura 5.29 - Resultados da segmentação do *dataset* OLI/Landsat-8. Polígonos amarelos são as referências delineadas por um especialista e os polígonos com bordas vermelhas são os resultados produzidos por cada algoritmo.



(a) MRS

(b) Meanshift



(c) Bins

(d) Proposto

Fonte: Produção do autor

A Tabela 5.18 apresenta os valores médios e os desvios padrão, todos truncados em 3 casas decimais, obtidos para cada algoritmo. Mais uma vez o algoritmo proposto, apesar dos problemas, apresentou bons resultados e superiores ao algoritmo de Bins e similares ao MRS e Meanshift. Pode-se observar que o MRS apresentou os melhores resultados em todas as métricas, exceto a Revocação. Na Precisão, em especial, obteve a maior diferença em relação aos demais, chegando 0,14 em relação ao algoritmo de Bins. Mais uma vez, todos os algoritmos obtiveram excelentes resultados

Tabela 5.18 - Resultados obtidos por cada algoritmo para o *dataset* OLI/Landsat-8.


Métrica	MRS	Meanshift	Bins	UCS
Precisão	$0,811 \pm 0,244$	$0,758 \pm 0,223$	$0,680 \pm 0,276$	$0,754 \pm 0,255$
Revocação	$0,722 \pm 0,200$	$0,737 \pm 0,198$	$0,757 \pm 0,190$	$0,726 \pm 0,192$
F-measure	$0,717 \pm 0,178$	$0,701 \pm 0,175$	$0,663 \pm 0,193$	$0,693 \pm 0,180$
<i>FITXY</i>	$0,973 \pm 0,027$	$0,970 \pm 0,028$	$0,957 \pm 0,040$	$0,968 \pm 0,035$
<i>FITN</i>	$0,861 \pm 0,114$	$0,865 \pm 0,147$	$0,834 \pm 0,145$	$0,858 \pm 0,129$
G_{shape}	$0,753 \pm 0,141$	$0,729 \pm 0,160$	$0,686 \pm 0,173$	$0,727 \pm 0,152$

Fonte: Produção do autor

na métrica *FITXY*, todos acima de 0,95, com o MRS alcançando o melhor ajuste. Na métrica *FITN*, MRS e Meanshift alcançaram resultados muito similares, uma diferença de 0,002. Contudo o Meanshift apresentou desvio padrão um levemente superior. O algoritmo MRS mais uma vez, obteve o melhor ajuste em relação à forma dos objetos, com uma diferença de 0,03 para o Meanshift e o algoritmo proposto. O algoritmo de Bins, foi o pior nessa métrica.

A seguir, apresentamos os boxplots para cada uma das métricas utilizadas. Para métrica Precisão (Figura 5.30), todos os algoritmos apresentaram grande amplitude nas distribuições. Além disso, no caso dos algoritmos MRS e Meanshift ocorreu a presença de vários *outliers*, especialmente no Meanshift. O MRS e o algoritmo de Bins apresentaram distribuições semelhantes, onde a maior parte da distribuição ficou concentrada acima de 0,75. Contudo, essa presença não foi tão forte quanto no caso do MRS e do Meanshift, que apresentaram amplitudes interquartil menores.


Figura 5.30 - Boxplot da métrica Precisão no *dataset* OLI/Landsat-8.



Fonte: Produção do autor

Para a Revocação as distribuições (Figura 5.31) foram similares, em amplitude, mediana e variação interquartil. Além disso, nessa métrica não ocorreram *outliers* em nenhum dos resultados. Apesar das características em comum, as distribuições foram levemente diferentes, sobretudo, no resultado do algoritmo proposto, onde a distribuição dos resultados ficou próximo a 0,75, enquanto os demais alcançaram valores acima de 0,8.


Figura 5.31 - Boxplot da métrica Revocação no *dataset* OLI/Landsat-8.



Fonte: Produção do autor

Para a métrica F-Measure (Figura 5.32) o algoritmo de Bins apresentou a maior amplitude e a menor mediana. Além disso, seus resultados ficaram concentrados entre 0,65 e 0,9. Já o MRS apresentou a menor amplitude, sendo que parte dos seus resultados ficaram concentrados acima de 0,85, obtendo o melhor resultado. Por outro lado, o Meanshift, apesar de possuir a maior mediana, apresentou o menor valor máximo, abaixo inclusive do algoritmo de Bins e, então, grande parte dos seus resultados ficaram entorno de 0,8. O algoritmo proposto concentrou a maior parte dos seus resultados em torno de 0,75, além de apresentar *outliers* abaixo de 0,25.


Figura 5.32 - Boxplot da métrica F-Measure no *dataset* OLI/Landsat-8.



Fonte: Produção do autor

Para a métrica *FITXY* (Figura 5.33), todos os algoritmos tiveram excelentes resultados, apesar de alguns *outliers*. Os valores interquartis também foram semelhantes, contudo o algoritmo proposto apresentou uma maior amplitude. No geral o desempenho geral de todos os algoritmos foi bastante semelhante.


Figura 5.33 - Boxplot da métrica $FITXY$ no *dataset* OLI/Landsat-8.



Fonte: Produção do autor

Para a métrica $FITN$ (Figura 5.34), diferentemente do que aconteceu nas demais, os resultados do Meanshift apresentaram uma grande amplitude, além de conter alguns *outliers*. Apesar disso, a variação interquartil foi semelhante em todos os algoritmos, além de que seus resultados foram concentrados próximos a 0,97. O resultado do MRS apresentou a menor amplitude dentre os demais, contudo, a distribuição dos seus resultados foi mais esparsa em torno de 0,8. Os resultados do algoritmo de Bins apresentou amplitude tão alta quanto a do Meanshift. Contudo, a variação interquartil foi maior. Já os resultados do algoritmo proposto apresentaram variação interquartil próxima a do MRS e amplitude similar à do Meanshift e apresentou *outliers*. Entretanto, a maior parte da distribuição ficou concentrada acima de 0,9.


Figura 5.34 - Boxplot da métrica $FITN$ no *dataset* OLI/Landsat-8.



Fonte: Produção do autor

Em relação à métrica G_{shape} (Figura 5.35) o MRS apresentou a menor amplitude em seus resultados e foi o único que não teve outliers. O Meanshift, apesar de obter a maior mediana, apresentou alguns outliers e o máximo da sua distribuição não superou 0,9. O algoritmo de Bins apresentou a maior amplitude dentre todos. Além disso, a maior parte dos seus resultados ficaram concentrados abaixo de 0,75, evidenciando o baixo desempenho para este *dataset*. O algoritmo proposto também apresentou um resultado pouco satisfatório, além da grande amplitude e presença de *outliers*. A maior parte dos resultados ficou concentrada em torno de 0,75, evidenciando um desempenho geral pior que os algoritmos MRS e o Meanshift.

Figura 5.35 - Boxplot da métrica G_{shape} no *dataset* OLI/Landsat-8.



Fonte: Produção do autor

Da mesma forma, novamente foram realizados testes de hipótese de Wilcoxon, para avaliar se de fato os algoritmos tiveram o mesmo desempenho ou se um deles foi superior ao outro. Como é possível observar nas tabelas abaixo, o algoritmo UCS obteve um desempenho inferior ao MRS apenas na métrica Precisão, nas demais eles foram estatisticamente iguais com α de 5%.

Em relação ao Meanshift, o algoritmo proposto também foi estatisticamente igual em todas as métricas. Quando comparado com os resultados do algoritmo de Bins, os resultados obtidos foram estatisticamente iguais em apenas 2 das 6 métricas (Revocação e *FITN*). Nas demais, o algoritmo proposto apresentou resultado superior.

Tabela 5.19 - Precisão - OLI/Landsat-8

Proposto X	p -valor	Conclusão
MRS	0,9994	Inferior
Meanshift	0,2222	Igual
Bins	0,9999	Superior

Tabela 5.21 - F-Measure - OLI/Landsat-8

Proposto X	p -valor	Conclusão
MRS	0,1230	Igual
Meanshift	0,4950	Igual
Bins	0,9866	Superior

Tabela 5.23 - $FITN$ - OLI/Landsat-8

Proposto X	p -valor	Conclusão
MRS	0,9363	Igual
Meanshift	0,3118	Igual
Bins	0,1354	Igual

Tabela 5.20 - Revocação - OLI/Landsat-8

Proposto X	p -valor	Conclusão
MRS	0,5666	Igual
Meanshift	0,6431	Igual
Bins	0,1243	Igual

Tabela 5.22 - $FITXY$ - OLI/Landsat-8

Proposto X	p -valor	Conclusão
MRS	0,3521	Igual
Meanshift	0,8433	Igual
Bins	0,9978	Superior

Tabela 5.24 - G_{shape} - OLI/Landsat-8

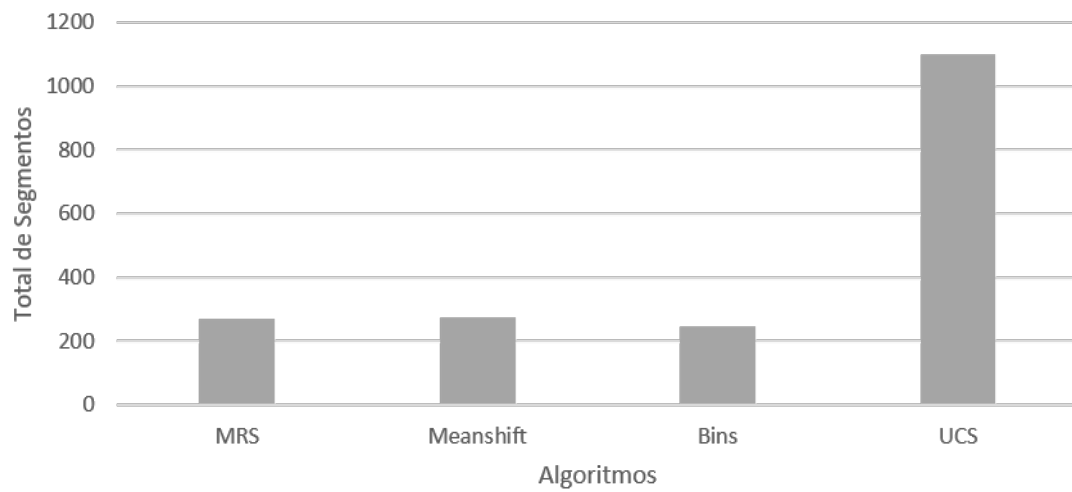
Proposto X	p -valor	Conclusão
MRS	0,0779	Igual
Meanshift	0,9413	Igual
Bins	0,9984	Superior

Fonte: Produção do autor

Os resultados obtidos para o *dataset* OLI/Landsat-8, mais uma vez demonstram a robustez do algoritmo proposto, apesar dos problemas ocorridos durante a etapa de classificação, que afetou o desempenho geral do algoritmo. Mesmo com os problemas de supersegmentação, nas referências utilizadas o algoritmo proposto obteve um bom desempenho, sendo inferior ao MRS apenas na Precisão, e superior ao algoritmo proposto por Bins em 4 das 6 métricas.

O algoritmo proposto gerou o maior número de segmentos como pode ser observado na Figura 5.36, por isso usamos mais uma vez um parâmetro de tamanho mínimo para os segmentos, para reduzir o número de polígonos. O algoritmo proposto produziu mais de 1.100 polígonos, enquanto os algoritmos MRS, Meanshift, de Bins geraram, respectivamente, apenas 269, 273 e 245.

Figura 5.36 - Total de segmentos gerados por cada algoritmo de segmentação.



Fonte: Produção do autor

A super-segmentação (Figura 5.37) gerada pelo algoritmo proposto ocorreu em virtude da má qualidade de informação unária. Essa confusão ocorreu sobretudo em função da alta similaridade entre os objetos que acarretou, em certos casos, poucos padrões na imagem, afetando o desempenho do algoritmo de classificação FCM. Somado a isso, ainda podemos considerar o efeito da abordagem de minimização, que apresenta problemas com os mínimos locais.

Figura 5.37 - Resultados da classificação do *dataset* OLI/Landsat-8 sobrepostos pelos segmentos gerados pelo algoritmo proposto.



Fonte: Produção do autor

5.4.4 MUX/CBERS-4

O experimento com a imagem MUX/CBERS-4 foi realizado com os seguintes parâmetros para o algoritmo MRS:

- Escala: 24;
- Forma: 0, 1;
- Compacidade: 0, 9.

Para o algoritmo de Bins, utilizamos os seguintes parâmetros:

- Tamanho mínimo: 40;
- Similaridade: 0,0015;

Para o algoritmo Meanshift utilizamos os seguintes parâmetros:

- Raio espacial: 5;
- Raio da faixa: 3;
- Tamanho mínimo: 200;

Para o algoritmo proposto utilizamos os seguintes parâmetros:

- Similaridade: 8;
- Escala: 150;


A Figura a seguir apresenta a segmentação produzida pelos algoritmos para o *dataset* MUX/CBERS-4. O MRS obteve o melhor resultado dentre todos, como mostra a Figura 5.39(a), apesar da dificuldade em aderir às bordas mais fracas presentes na imagem. Isto acarretou subsegmentação em algumas áreas na parte central da imagem. O Meanshift (Figura 5.39(b)) no geral, obteve bons resultados, apresentando algumas áreas com super-segmentação, como na porção superior esquerda da imagem, caracterizada por talhões onde o pasto estava baixo e com falhas. Além disso, algumas bordas mais suaves, assim como no caso do MRS, foram ignoradas pelo segmentador.

O algoritmo de Bins novamente não produziu bons resultados, como mostra a Figura 5.39(c). Em grande parte dos polígonos, na parte superior da imagem houve supersegmentação dos objetos, enquanto que na porção inferior da imagem, que apresenta áreas com bordas menos proeminentes, ocorreram áreas subsegmentadas.


Como pode ser observado na Figura 5.39, o algoritmo proposto gerou o maior número de segmentos, com mais de 1.200, resultado da supersegmentação. Enquanto os algoritmos MRS, Meanshift e Bins resultaram, respectivamente, 240, 261 e 599 segmentos.

A Tabela 5.25 apresenta os valores médios e os desvios padrão, todos truncados em 3 casas decimais, obtidos para cada um dos algoritmos utilizados. Neste *dataset*, o


Figura 5.38 - Resultados da segmentação do *dataset* MUX/CBERS-4. Polígonos amarelos são as referências delineadas por um especialista e os polígonos com bordas vermelhas são os resultados produzidos por cada algoritmo.




(a) MRS



(b) Meanshift



(c) Bins

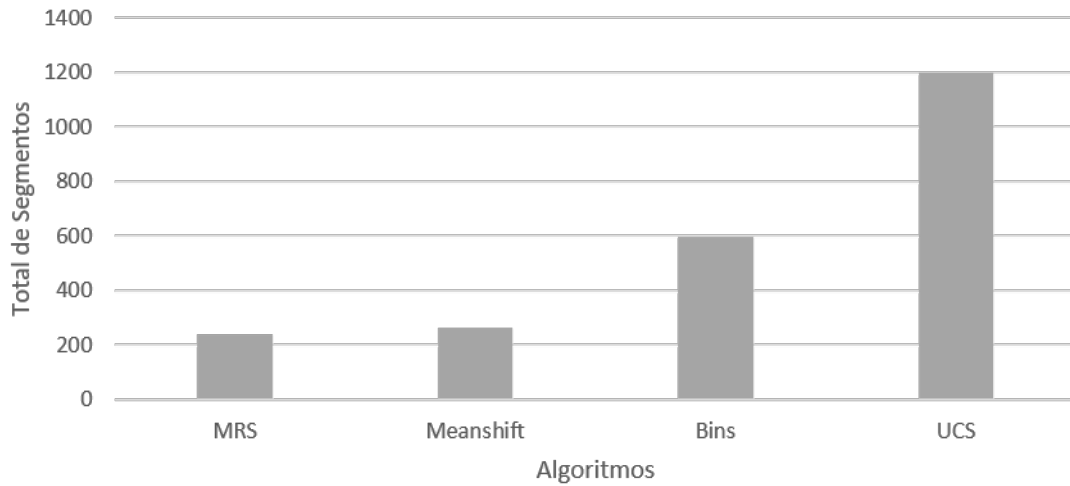


(d) Proposto

Fonte: Produção do autor

MRS obteve o melhor resultado na maioria das métricas, em especial na Revocação e G_{shape} , onde obteve a maior vantagem em relação aos demais. O Meanshift superou o MRS na Precisão, obtendo valores bastante próximos nas demais métricas. O algoritmo de Bins alcançou seu melhor resultado na métrica $FITXY$, que avalia o ajuste do segmento gerado em relação ao centro de massa, e na métrica $FITN$, relacionada ao tamanho do segmento, ficando apenas um pouco atrás do MRS em média. O algoritmo proposto apresentou seu pior desempenho, com resultados inferiores aos demais na maioria das métricas. No caso da Revocação foi registrada a

Figura 5.39 - Total de segmentos gerados por cada algoritmo de segmentação para o *dataset* MUX/CBERS-4.



Fonte: Produção do autor

maior diferença para os demais, chegando a 0,13 quando comparada ao MRS.

Tabela 5.25 - Resultados obtidos por cada algoritmo para o *dataset* MUX/CBERS-4.


Métrica	MRS	Meanshift	Bins	UCS
Precisão	$0,726 \pm 0,256$	$0,740 \pm 0,215$	$0,730 \pm 0,197$	$0,723 \pm 0,242$
Revocação	$0,838 \pm 0,156$	$0,803 \pm 0,192$	$0,743 \pm 0,196$	$0,701 \pm 0,200$
F-measure	$0,736 \pm 0,190$	$0,730 \pm 0,179$	$0,698 \pm 0,163$	$0,666 \pm 0,176$
<i>FITXY</i>	$0,949 \pm 0,047$	$0,949 \pm 0,045$	$0,951 \pm 0,038$	$0,949 \pm 0,038$
<i>FITN</i>	$0,861 \pm 0,140$	$0,863 \pm 0,140$	$0,833 \pm 0,116$	$0,849 \pm 0,125$
<i>G_{shape}</i>	$0,715 \pm 0,187$	$0,694 \pm 0,184$	$0,673 \pm 0,172$	$0,668 \pm 0,158$

Fonte: Produção do autor

A seguir, apresentamos os boxplots para cada uma das métricas utilizadas. Para métrica Precisão, todos os algoritmos apresentaram uma grande amplitude nas distribuições, sendo a do algoritmo de Bins a menor. Além disso, nos métodos Meanshift e MRS ocorreram *outliers*. O algoritmo proposto concentrou os resultados acima de 0,8. Entretanto, essa concentração não foi tão forte quanto nos demais algoritmos, em comparação em especial com o MRS, que apresentou uma distribuição seme-

lhante em forma, mas com magnitude diferente.


Figura 5.40 - Boxplot da métrica Precisão no *dataset* MUX/CBERS-4.



Fonte: Produção do autor

Para a Revocação o MRS apresentou seus resultados entre 0,75 e 0,95, reforçando o excelente desempenho do algoritmo. O método Meanshift, apesar da maior amplitude (Figura 5.41) dos resultados, apresentou um desempenho similar ao MRS, com uma variabilidade maior. O algoritmo de Bins, mais uma vez, apresentou um resultado ruim. A distribuição dos resultados foi mais esparsa que dos demais métodos, com exceção do algoritmo proposto, que teve um desempenho muito abaixo dos demais nessa métrica.


Figura 5.41 - Boxplot da métrica Revocação no *dataset* MUX/CBERS-4.



Fonte: Produção do autor

A Figura 5.42 apresenta os resultados obtidos na métrica F-Measure. Como essa métrica é obtida usando a média harmônica da Revocação e da Precisão, o desempenho do algoritmo proposto foi o pior entre todos. Os métodos MRS e o MeanShift tiveram resultados próximos, com uma pequena vantagem para o MRS. Contudo, ele apresentou o maior desvio padrão e maior número de *outliers*. O algoritmo de Bins, apesar de superar o algoritmo proposto, ainda ficou abaixo dos demais.


Figura 5.42 - Boxplot da métrica F-Measure no *dataset* MUX/CBERS-4.



Fonte: Produção do autor

Para a métrica *FITXY* todos os algoritmos tiveram excelentes resultados como pode ser observado na Figura 5.43, apesar de alguns *outliers*. Para esta métrica, o algoritmo de Bins teve seu melhor desempenho, superando os demais métodos, com uma pequena margem. Os demais algoritmos, apesar de terem médias iguais, apresentaram valores de desvio padrão diferentes, sendo o do MRS o maior. No geral, os algoritmos apresentaram desempenhos similares, com diferenças pequenas abaixo de 0,1 em amplitude e variação interquartil.


Figura 5.43 - Boxplot da métrica *FITXY* no *dataset* MUX/CBERS-4.



Fonte: Produção do autor

Na métrica *FITN* (Figura 5.44) o MRS obteve o melhor desempenho entre todos os algoritmos e alcançando a maior média e a menor variação interquartil. O Meanshift teve o pior desempenho com a menor média, maior desvio padrão e maior variação interquartil, além de *outliers*. Já o algoritmo de Bins, apresentou a menor amplitude e um resultado próximo ao MRS, com diferença inferior a 0,05.


Figura 5.44 - Boxplot da métrica $FITN$ no *dataset* MUX/CBERS-4.



Fonte: Produção do autor

Em relação à métrica G_{shape} (Figura 5.45), o MRS apresentou a menor amplitude em seus resultados e foi o único que não apresentou outliers. O Meanshift, embora obteve a maior mediana, apresentou alguns outliers e o máximo da sua distribuição não superou 0,9, enquanto os demais algoritmos conseguiram. O algoritmo de Bins apresentou a maior amplitude dentre todos os métodos. Além disso, a maior parte dos seus resultados ficaram concentrados abaixo de 0,75, evidenciando, assim, o mau desempenho para este *dataset*. O algoritmo proposto também apresentou um resultado pouco satisfatório, além da grande amplitude e da presença de *outliers*. A maior parte dos resultados ficou concentrada em torno de 0,75, evidenciando um desempenho geral pior que o MRS e o Meanshift.

Figura 5.45 - Boxplot da métrica G_{shape} no dataset MUX/CBERS-4.



Fonte: Produção do autor

Os testes de hipótese de Wilcoxon confirmaram que algoritmo UCS teve de fato desempenho inferior ao MRS e ao Meanshift na maioria das métricas. Quando comparado aos resultados do algoritmo de Bins, os resultados obtidos foram iguais estatisticamente em apenas 5 das 6 métricas.

Tabela 5.26 - Precisão - MUX/CBERS-4

Proposto X	p -valor	Conclusão
MRS	0,6996	Igual
Meanshift	0,6057	Igual
Bins	0,6249	Igual

Tabela 5.27 - Revocação - MUX/CBERS-4

Proposto X	p -valor	Conclusão
MRS	0,9776	Inferior
Meanshift	0,9999	Inferior
Bins	0,9776	Inferior

Tabela 5.28 - F-Measure - MUX/CBERS-4

Proposto X	p -valor	Conclusão
MRS	0,9999	Inferior
Meanshift	0,9999	Inferior
Bins	0,0506	Iguais

Tabela 5.29 - $FITXY$ - MUX/CBERS-4

Proposto X	p -valor	Conclusão
MRS	0,4734	Igual
Meanshift	0,5323	Igual
Bins	0,6918	Igual

Tabela 5.30 - $FITN$ - MUX/CBERS-4

Proposto X	p -valor	Conclusão
MRS	0,1992	Igual
Meanshift	0,6926	Igual
Bins	0,7434	Igual

Tabela 5.31 - G_{shape} - MUX/CBERS-4

Proposto X	p -valor	Conclusão
MRS	0,9996	Inferior
Meanshift	0,9951	Inferior
Bins	0,9656	Igual

Fonte: Produção do autor

Os resultados obtidos para o *dataset* MUX/CBERS-4, MUX/CBERS-4, destoaram dos resultados obtidos para os outros *datasets*, para os quais o algoritmo proposto apresentou resultados similares aos demais. Nesse *dataset*, em função do desempenho inferior do algoritmo na classificação da imagem, o desempenho do algoritmo ficou aquém dos demais. Isso também demonstra a sensibilidade do algoritmo em relação ao resultado da classificação *a priori* que pode ser ruim, ocasionado pelo método de minimização utilizado, além da componente pareada que suaviza menos a imagem.

5.5 Discussão

Como forma de resumir os resultados obtidos, optou-se por utilizar a estatística *Plus/Minus*. Esta estatística aponta o número de vitórias, derrotas e empates dos testes estatísticos realizados. A componente *Plus* agrega todos os casos nos quais algoritmo UCS foi superior aos demais. Já a componente *Minus*, acumula todos os casos nos quais algoritmo UCS foi inferior aos demais.

Para avaliação foram utilizadas 6 métricas em 4 *datasets*, de forma que o máximo que as componentes podem atingir é a +4 ou -4. Dessa forma a pontuação total

que podem ser atingidas por cada uma das componentes é de +24 ou -24. Nos casos onde os algoritmos foram estatisticamente iguais não são somados valores a nenhuma das duas componentes. A Tabela 5.32 apresenta os resultados obtidos através dessa estatística.

Tabela 5.32 - Valores da estatística *Plus/Minus*

Métrica	MRS	Meanshift	Bins
Precisão	0/-3	0/0	+2/0
Revocação	0/-1	0/-2	0/-1
F-measure	0/-2	+1/-1	+3/0
FITXY	0/-1	0/0	+2/0
FITN	0/0	+1/0	+2/0
Gshape	0/-2	+1/-1	+3/-1
Total	0/-9	3/-4	+12/-2

Fonte: Produção do autor

Como pode ser observado, o algoritmo UCS teve um desempenho inferior ao MRS em 3 dos 4 datasets na métrica Precisão, resultado que também repercutiu na métrica F-Measure. Apesar da superioridade na Precisão, o MRS não teve grande superioridade nas demais métricas. Do total de 24 pontos possíveis o UCS não foi superior ao MRS em nenhuma das métricas, porém foi inferior em apenas 9.

Em relação ao Meanshift o desempenho foi mais similar. Houveram empates em todos os *datasets* na Precisão e no *FITXY* que avalia o deslocamento em relação ao centro de massa. O Meanshift foi superior apenas na Revocação, enquanto o UCS foi superior em um caso na métrica *FITN*, que avalia a coerência em relação ao tamanho do segmento de referência. Nos demais casos, houve equilíbrio, o que fez com que na pontuação total o UCS tenha alcançado +3 na componente *Plus* e o Meanshift -4 na outra componente. Nas demais 17 avaliações, os algoritmos foram estatisticamente iguais.

Em relação o algoritmo de Bins, o UCS já se mostrou superior, alcançando pontuações expressivas na métrica F-Measure e na G_{shape} . O algoritmo de Bins mostrou-se superior em apenas dois momentos, na Revocação e também no G_{shape} , que avalia o ajuste do segmento gerado em relação a forma do segmento de referência. O desempenho do algoritmo UCS fez com que no total a componente *Plus* alcançasse 12

pontos, enquanto o algoritmo de Bins fez apenas 2 pontos.

Apesar dos resultados inferiores no *dataset* MUX/CBERS-4, o desempenho do algoritmo UCS nos demais datasets foi similar aos demais algoritmos, especialmente ao Meanshift, e inclusive superando o MRS em algumas métricas. Esse desempenho coloca o algoritmo proposto numa boa posição em relação aos demais, uma vez que menos parâmetros precisam ser definidos para realizar a segmentação, o que facilita sua utilização pelo analista.

Contudo os resultados do método UCS indicam a necessidade de tratar pequenos segmentos gerados durante a segmentação. Como foi possível observar nos *dataset* Quibkbird, OLI/Landsat-8 e MUX/CBERS-4, o algoritmo proposto gerou uma quantidade muito grande de segmentos. Uma possível forma de resolver esse problema é utilizar um algoritmo de minimização robusto como o α *expansion*. Esta alteração pode promover um ganho de desempenho, evitando a supersegmentação da imagem. Uma alternativa mais simples seria a utilização de um parâmetro de área mínima para redução do número de pequenos segmentos.

Além disso, outro ponto que pode ser melhorado é a abordagem de classificação não supervisionada. Neste caso, pode-se utilizar algoritmos mais robustos do que o FCM como, por exemplo, *Support a Vector Machines* (SVM), embora algumas adaptações sejam necessárias.

A abordagem não supervisionada proposta por Li et al. (2008) combinada com o modelo CRF simplificado proposto por Zhang e Jia (2012), mostrou-se viável para segmentar imagens de Sensoriamento Remoto, especialmente imagens de alta resolução.

6 CONCLUSÕES

Esse trabalho teve como objetivo principal desenvolver um novo segmentador contextual não supervisionado adequado para segmentar imagens de satélite. O algoritmo baseou-se na abordagem proposta por Li et al. (2008). Embora ela seja similar a versão original, é um avanço por assimilar a informação contextual de alta-ordem durante o processo de segmentação com uma nova função potencial, mais simples que a função P^n Potts. O algoritmo foi implementado em linguagem de programação MATLAB e pode ser executado em todas as plataformas suportadas por este *software* (Windows, Linux e Mac OS).

O algoritmo foi implementado por módulos, o que permite a integração de novas funcionalidade de maneira simples, uma vez que os módulos podem ser tratados individualmente. Um bom exemplo é o módulo de classificação (FCM), que pode ser substituído facilmente por outro, com pequenas modificações no algoritmo principal. Além disso, outros desenvolvedores podem aproveitar os módulos desenvolvidos para aplicação em outros algoritmos.

Com relação ao desempenho dos módulos de classificação, suavização e minimização do algoritmo de segmentação, conclui-se que:

- A estratégia para obtenção do número de classes para o FCM utilizando mínimos regionais mostrou-se eficiente especialmente nas imagens de alta resolução espacial;
- A classificação com o algoritmo FCM apresentou limitações, especialmente em áreas com bordas suaves e pouca variação espectral;
- A componente de iteração espacial, em função da sua construção, não conseguiu suavizar de forma satisfatória certas regiões das imagens, o que acarretou em problemas de super-segmentação;
- A estratégia de minimização local utilizando o ICM, não se mostrou eficiente em alguns casos, de modo que novos métodos de minimização precisam ser avaliados;
- O método de minimização combinado com a rigidez da componente de iteração espacial, provocou a geração de diversos pequenos segmentos na imagem, acarretando em super-segmentações.

Em relação ao desempenho do algoritmo UCS e as análises comparativas realizadas com os algoritmos MRS, Meanshift e de Bins, pode-se concluir que:

- O UCS apresentou bons resultados sobretudo nas imagens de alta resolução espacial, devido à boa classificação inicial obtida pelo FCM;
- Nas imagens de média resolução espacial, o desempenho do algoritmo foi inferior aos demais em algumas métricas, especialmente no Recall, o que ficou evidenciado pela supersegmentação dessas imagens;
- De modo geral, os resultados obtidos com o UCS foram superiores ao algoritmo proposto por Bins, na maioria das imagens;
- Em relação ao MRS, o UCS foi estatisticamente inferior em algumas das métricas, especialmente Recall, na maioria das imagens. Porém, para a imagem WorldView-2 os resultados foram estatisticamente superiores na maioria das métricas;
- A segmentação com o UCS apresentou o maior número de segmentos para todas as imagens. Portanto, o uso de um parâmetro de área mínima, similar ao método de Bins é necessário para melhorar o desempenho do algoritmo;
- Os algoritmos apresentaram seus melhores desempenhos na métrica FITXY, responsável por avaliar o erro em relação ao centroide do polígono de referência, o que indica que apesar de possíveis inconsistências em relação ao tamanho e forma do objeto, todos os algoritmos têm boa capacidade de detectar objetos distintos;

A partir dos resultados obtidos na segmentação dos *datasets*, observa-se que o algoritmo UCS tem potencial para segmentação de imagens de satélites, que, de forma geral, são complexas e difíceis de segmentar e classificar.

Como sugestões para futuros trabalhos:

- Incorporação ao algoritmo de um novo método de classificação com resultados melhores do que obtidos neste trabalho;
- Alteração da abordagem de minimização, de modo que seja possível atingir um resultado mais próximo do mínimo de energia global;

- Desenvolvimento de uma interface de visualização para interatividade com o usuário;
- Otimização dos módulos do algoritmo afim de melhorar o seu desempenho geral;
- Melhorar o algoritmo *Divide and Segment* para evitar que o algoritmo crie *tiles* com formas complexas além de elaborar uma nova estratégia para definição dos pontos iniciais e finais;
- Implementar o algoritmo UCS em linguagem C++ e disponibilizá-lo na biblioteca TerraLib (CÂMARA et al., 2008) desenvolvido pelo INPE, além de integrá-lo ao software GEODMA (KÖRTING et al., 2008).

REFERÊNCIAS BIBLIOGRÁFICAS

- ACHANCCARAY, P.; AYMA, V.; JIMENEZ, L.; GARCIA, S.; HAPP, P.; FEITOSA, R.; PLAZA, A. A free software tool for automatic tuning of segmentation parameters. **South-Eastern European Journal of Earth Observation and Geomatics**, v. 3, p. 707–712, 2014. 9, 53
- ACHANTA, R.; SHAJI, A.; SMITH, K.; LUCCHI, A.; FUA, P.; SÜSSTRUNK, S. Slıc superpixels compared to state-of-the-art superpixel methods. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 34, n. 11, p. 2274–2282, 2012. 12
- ACHANTA, R.; SÜSSTRUNK, S. Superpixels and polygons using simple non-iterative clustering. In: CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION. **Proceedings..** [S.l.]: IEEE, 2017. p. 4895–4904. 13
- ACHARYA, T.; RAY, A. K. **Image processing: principles and applications.** [S.l.]: John Wiley & Sons, 2005. 11
- BAATZ, M.; SCHÄPE, A. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. In: STROBL, J.; BLASCHKE, T.; GRIESEBNER, G. (Ed.). **Angewandte geographische informationsverarbeitung.** Heidelberg: Wichmann-Verlag, 2000. p. 12–23. 1, 8, 67
- BALAN, A. **Técnicas de segmentação de imagens aéreas para contagem de população de aves.** 88 p. Dissertação (Mestrado em Ciências da Computação e Matemática Computacional) — Universidade de São Paulo-São Carlos, 2003. 21
- BALLARD, D. H.; BROWN, C. M. **Computer vision.** [S.l.]: Prentice Hall, 1982. ISBN 0131653164. 1
- BARKER, S.; RAYNER, P. Unsupervised image segmentation using markov random field models. **Pattern Recognition**, v. 33, n. 4, p. 587 – 602, 2000. ISSN 0031-3203. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0031320399000746>>. 2
- BEJAR, H. H. C. **Conexidade fuzzy relativa em grafos dirigidos e sua aplicação em um método híbrido para segmentação interativa de imagens.** Dissertação (Mestrado em Ciências da Computação) — Universidade de São Paulo, São Paulo, 2016. 11, 14, 15

BESAG, J. On the statistical analysis of dirty pictures. **Journal of the Royal Statistical Society. Series B (Methodological)**, p. 259–302, 1986. 2, 22, 23, 44

BEUCHER, S. The watershed transformation applied to image segmentation. **Scanning Microscopy-Supplement**, n. 6, p. 299–314, 1992. 10

BEUCHER, S.; LANTUÉJOUL, C. Use of watersheds in contour detection. In: INTERNATIONAL WORKSHOP ON IMAGE PROCESSING. **Proceedings...** [S.l.], 1979. 10

BINS, L.; FONSECA, L.; ERTHAL, G.; II, F. Satellite imagery segmentation: a region growing approach. In: BRAZILIAN REMOTE SENSING SYMPOSIUM. **Proceedings...** Salvador: INPE, 1996. v. 8, p. 677–680. 6, 8, 56

BLAKE, A.; KOHLI, P.; ROTHER, C. **Markov random fields for vision and image processing**. [S.l.]: Mit Press, 2011. 472 p. ISBN 0262015773. 21, 22, 25

BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65, n. 1, p. 2–16, jan. 2010. ISSN 09242716. Disponível em:
<<http://linkinghub.elsevier.com/retrieve/pii/S0924271609000884>>. 21

BONADIO, I. **Desenvolvimento de um arcabouço probabilístico para implementação de campos aleatórios condicionais**. Dissertação (Mestrado em Ciência da Computação) — Universidade de São Paulo, São Paulo, 2013. 24

BOUMAN, C. A.; SHAPIRO, M. A multiscale random field model for bayesian image segmentation. **IEEE Transactions on Image Processing**, v. 3, n. 2, p. 162–177, 1994. 29

BOYKOV, Y.; VEKSLER, O.; ZABIH, R. Fast approximate energy minimization via graph cuts. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 23, n. 11, p. 1222–1239, 2001. 2, 24

CÂMARA, G.; VINHAS, L.; FERREIRA, K.; QUEIROZ, G.; SOUZA, R.; MONTEIRO, A.; CARVALHO, M.; CASANOVA, M.; FREITAS, U. TerraLib: An open source GIS library for large-scale environmental and socio-economic applications. **Open Source Approaches in Spatial Data Handling**, v. 2, p. 247–270, 2008. Disponível em:
<<http://www.springerlink.com/index/K505665570287237.pdf>>. 107

CAMPBELL, N. D.; SUBR, K.; KAUTZ, J. Fully-connected crfs with non-parametric pairwise potential. In: CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 2013. **Proceedings...** [S.l.]: IEEE, 2013. p. 1658–1665. 6, 15

CAO, G.; ZHOU, L.; LI, Y. A new change-detection method in high-resolution remote sensing images based on a conditional random field model. **International Journal of Remote Sensing**, v. 37, n. 5, p. 1173–1189, 2016. Disponível em: <<https://doi.org/10.1080/01431161.2016.1148284>>. 2, 25

CASANOVA, M. A. **Utilizando aprendizado de máquina para construção de uma ferramenta de apoio a moderação de comentários**. Dissertação (Mestrado em Informática) — Pontifícia Universidade Católica, Rio de Janeiro, 2011. 52

CELIKYILMAZ, A.; SARIKAYA, R.; HAKKANI-TUR, D.; LIU, X.; RAMESH, N.; TUR, G. A new pre-training method for training deep learning models with application to spoken language understanding. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM. **Proceedings...** [S.l.], 2016. p. 3255–3259. 2

CHENG, Y. Mean shift, mode seeking, and clustering. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 17, n. 8, p. 790–799, 1995. 12

CHIBA, E. A. **Corte em grafos e segmentação de imagens utilizando um algoritmo aglomerativo de agrupamento hierárquico**. Dissertação (Mestrado em Engenharia da Informação) — Universidade Estadual de Campinas, Limeira., 2014. 14

CIGULA, C.; ALATAN, A. A. Efficient graph-based image segmentation via speeded-up turbo pixels. In: INTERNATIONAL CONFERENCE ON IMAGE PROCESSING, 2010. **Proceedings...** [S.l.]: IEEE, 2010. p. 467–475. 44

COMANICIU, D.; MEER, P. Robust analysis of feature spaces: color image segmentation. In: COMPUTER SOCIETY CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 1997. **Proceedings...** IEEE, 1997. p. 750–755. Disponível em: <http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=609410>. 12, 56

COSTA, G.; CAMARGO, F.; OLIVEIRA, D.; ALMEIDA, C.; FEITOSA, R.; FERREIRA, R. Using the cognitive platform interimage to identify

geomorphological features. In: **MIPPR 2009 - Remote Sensing and GIS Data Processing and other Applications**. Yichang: [s.n.], 2009. 21

DAI, J.; HE, K.; SUN, J. Boxsup: exploiting bounding boxes to supervise convolutional networks for semantic segmentation. **arXiv**, abs/1503.01640, 2015. Disponível em: <<http://arxiv.org/abs/1503.01640>>. 25

D'ELIA, C.; POGGI, G.; SCARPA, G. A tree-structured markov random field model for bayesian image segmentation. **IEEE Transactions on Image Processing**, v. 12, n. 10, p. 1259–1273, 2003. 21

DELVES, L.; WILKINSON, R.; OLIVER, C.; WHITE, R. Comparing the performance of sar image segmentation algorithms. **International Journal of Remote Sensing**, v. 13, n. 11, p. 2121–2149, 1992. 51, 52

DERPANIS, K. G. **Mean shift clustering**. [s.n.], 2005. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.217.3313>>. 12

DEY, V.; ZHANG, Y.; ZHONG, M. A review on image segmentation techniques with remote sensing perspective. In: WAGNER, W.; SZKELY, B. (Ed.). **ISPRS TC VII Symposium**. [S.l.], 2010. 5

DIJKSTRA, E. A note on two problems in connexion with graphs. **Numerische Mathematik**, n. 1 959, p. 269–271, 1959. Disponível em: <<http://www.springerlink.com/index/uu8608u0u27k7256.pdf>>. 16, 17, 35

DO, T.-M.-T.; ARTIERES, T. Neural conditional random fields. In: INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE AND STATISTICS, 13 ., 2010. **Proceedings...** [S.l.], 2010. 2

DOUGHERTY, E. R.; LOTUFO, R. A. **Hands-on morphological image processing**. [S.l.]: SPIE press, 2003. 37

DRĂGUȚ, L.; CSILLIK, O.; EISANK, C.; TIEDE, D. Automated parameterisation for multi-scale image segmentation on multiple layers. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 88, p. 119–127, 2014. 9

DRĂGUȚ, L.; TIEDE, D.; LEVICK, S. R. Esp: a tool to estimate scale parameter for multiresolution image segmentation of remotely sensed data. **International Journal of Geographical Information Science**, v. 24, n. 6, p. 859–871, 2010. 9

DUAN, Y.; LIU, F.; JIAO, L. Sketching model and higher order neighborhood markov random field-based sar image segmentation. **IEEE Geoscience and Remote Sensing Letters**, v. 13, n. 11, p. 1686–1690, Nov 2016. ISSN 1545-598X. 21

DUTTA, M. An essential statistical approach to thermodynamic problem - ii. **Proceedings of the Indian National Science Academy**, v. 19, p. 109–126, 1953. 22

FACON, J. **Princípios básicos da visão por computador e do processamento de imagens**. Curitiba: Pontificia Universidade Católica do Paraná, 2002. 7

FACON, J. F. **Processamento e análise de imagens**. [S.l.: s.n.], 1993. 5

FALCÃO, A. X.; UDUPA, J. K.; HIRSCH, B. E. User-steered image boundary segmentation. **Proceedings SPIE**, v. 2710, p. 2710 – 2710 – 11, 1996. Disponível em: <<https://doi.org/10.1117/12.237930>>. 16

FALCÃO, A.; STOLFI, J.; ALENCAR LOTUFO, R. The image foresting transform: theory, algorithms, and applications. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 26, n. 1, p. 19–29, 2004. ISSN 0162-8828. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1261076>>. 11, 37

FELZENSZWALB, P.; HUTTENLOCHER, D. Efficient belief propagation for early vision. **International Journal of Computer Vision**, v. 70, n. 1, p. 41–54, 2006. 2

FELZENSZWALB, P. F.; HUTTENLOCHER, D. P. Efficient graph-based image segmentation. **International Journal of Computer Vision**, v. 59, n. 2, p. 167–181, 2004. 1, 15

FU, K.-S.; MUI, J. A survey on image segmentation. **Pattern Recognition**, v. 13, n. 1, p. 3–16, 1981. 5

FUKUNAGA, K.; HOSTETLER, L. The estimation of the gradient of a density function, with applications in pattern recognition. **IEEE Transactions on Information Theory**, v. 21, n. 1, p. 32–40, 1975. 12

GAETANO, R.; MASI, G.; POGGI, G.; VERDOLIVA, L.; SCARPA, G.
Marker-controlled watershed-based segmentation of multiresolution remote sensing images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 53, n. 6, p. 2987–3004, 2015. 11

GAO, L.; SONG, J.; NIE, F.; ZOU, F.; SEBE, N.; SHEN, H. T.
Graph-without-cut: an ideal graph learning for image segmentation. In: CONFERENCE ON ARTIFICIAL INTELLIGENCE 30., 2016. **Proceedings**. 2016. p. 1188–1194. Disponível em:
<<http://dblp.uni-trier.de/db/conf/aaai/aaai2016.html#GaoSNZSS16>>. 2

GEMAN, S.; GEMAN, D. Stochastic relaxation, gibbs distributions, and the bayesian restoration of images. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, n. 6, p. 721–741, Nov 1984. ISSN 0162-8828. 23

GOLDBARG, M. **Grafos: conceitos, algoritmos e aplicações**. [S.l.]: Elsevier Brasil, 2012. 14, 15

GONZALEZ, R.; WOODS, R. **Digital image processing**. New Jersey: Prentice Hall, 2002. ISBN 0201180758. Disponível em:
<<http://www.tandfonline.com/doi/abs/10.1080/02664768900000049>>. 6, 7

GONZALEZ, R. C.; WOODS, R. E. **Processamento digital de imagens**. [S.l.]: Pearson Prentice Hall, 2010. 5, 6, 10

GONZALO-MARTÍN, C.; LILLO-SAAVEDRA, M.; MENASALVAS, E.; FONSECA-LUENGO, D.; GARCÍA-PEDRERO, A.; COSTUMERO, R. Local optimal scale in a hierarchical segmentation method for satellite images. **Journal of Intelligent Information Systems**, v. 46, n. 3, p. 517–529, 2016. ISSN 1573-7675. Disponível em: <<http://dx.doi.org/10.1007/s10844-015-0365-4>>. 1

GRAU, V.; MEWES, A.; ALCANIZ, M.; KIKINIS, R.; WARFIELD, S. K.
Improved watershed transform for medical image segmentation using prior information. **IEEE Transactions on Medical Imaging**, v. 23, n. 4, p. 447–458, 2004. 26

GURNEY, C. M.; TOWNSHEND, J. R. The use of contextual information in the classification of remotely sensed data. **Photogrammetric Engineering and Remote Sensing**, v. 49, p. 55–64, 1983. 1

HAMMERSLEY, J. M.; CLIFFORD, P. E. **Markov random fields on finite graphs and lattices**. [S.l.]: Unpublished manuscript, 1971. 22

HANSEN, F.; ELLIOTT, H. Image segmentation using simple markov field models. **Computer Graphics and Image Processing**, v. 20, n. 2, p. 101 – 132, 1982. ISSN 0146-664X. Disponível em: <<http://www.sciencedirect.com/science/article/pii/0146664X82900405>>. 29

HAPP, P.; FERREIRA, R.; BENTES, C.; COSTA, G.; FEITOSA, R. Multiresolution segmentation: a parallel approach for high resolution image segmentation in multicore architectures. In: INTERNATIONAL CONFERENCE ON GEOGRAPHIC OBJECT-BASED IMAGE ANALYSIS, 3, 2010. **Proceedings...** [S.l.]: The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2010. 33

HARALICK, R. M.; SHAPIRO, L. G. Image segmentation techniques. **Computer Vision, Graphics, and Image Processing**, v. 29, n. 1, p. 100–132, 1985. 5

HAY, G. J.; CASTILLA, G.; WULDER, M. A.; RUIZ, J. R. An automated object-based approach for the multiscale image segmentation of forest scenes. **International Journal of Applied Earth Observation and Geoinformation**, v. 7, n. 4, p. 339–359, 2005. 1

HE, Y.; WANG, H.; ZHANG, B. Color-Based Road Detection in Urban Traffic Scenes. **IEEE Transactions on Intelligent Transportation Systems**, v. 5, n. 4, p. 309–318, dez. 2004. ISSN 1524-9050. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1364007>>. 29

HOBERG, T.; ROTTENSTEINER, F.; FEITOSA, R. Q.; HEIPKE, C. Conditional random fields for multitemporal and multiscale classification of optical satellite imagery. **IEEE Transactions on Geoscience and Remote Sensing**, v. 53, n. 2, p. 659–673, Feb 2015. ISSN 0196-2892. 2

HOROWITZ, S. L.; PAVLIDIS, T. Picture segmentation by a directed split-and-merge procedure. In: INTERNATIONAL JOINT CONFERENCE ON PATTERN RECOGNITION, 2, 1974. **Proceedings...** [S.l.], 1974. 9

HU, Y.; CHEN, J.; PAN, D.; HAO, Z. Edge-guided image object detection in multiscale segmentation for high-resolution remotely sensed imagery. **IEEE Transactions on Geoscience and Remote Sensing**, v. 54, n. 8, p. 4702–4711, Aug 2016. ISSN 0196-2892. 1

- HUANG, Q.; HAN, M.; WU, B.; IOFFE, S. A hierarchical conditional random field model for labeling and segmenting images of street scenes. In: IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 2011. **Proceedings...** [S.l.], 2011. p. 1953–1960. 26
- JAHNE, B.; GEISSLER, P.; HAUSSECKER, H. **Handbook of Computer Vision and Applications with Cdrom.** [S.l.]: Morgan Kaufmann, 1999. 37
- KASS, M.; WITKIN, A.; TERZOPOULOS, D. Snakes: active contour models. **International Journal of Computer Vision**, v. 1, n. 4, p. 321–331, 1988. 16
- KATO, Z.; ZERUBIA, J. et al. **Markov random fields in image segmentation.** [S.l.]: Now Publishers, Inc., 2012. 1–155 p. 23
- KHAN, M. W. A survey: image segmentation techniques. **International Journal of Future Computer and Communication**, v. 3, n. 2, p. 89, 2014. 5
- KIRKPATRICK, S.; GELATT, C. D.; VECCHI, M. P. Optimization by simulated annealing. **Science**, v. 220 4598, p. 671–80, 1983. 23
- KOHLI, P.; LADICKY, L.; TORR, P. H. Robust higher order potentials for enforcing label consistency. In: CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 2008. **Proceedings...** [S.l.], 2008. p. 1–8. 21, 28, 44
- KOHLI, P.; ROTHER, C. Higher-order models in computer vision. **Image Processing and Analysis with Graphs**, p. 65–100, 2012. 27, 41
- KOLMOGOROV, V. Convergent tree-reweighted message passing for energy minimization. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 28, n. 10, p. 1568–1583, 2006. 2
- KOLMOGOROV, V.; ROTHER, C. Minimizing nonsubmodular functions with graph cuts—a review. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 29, n. 7, p. 1274–1279, July 2007. ISSN 0162-8828. 24
- KOLTUN, V. Efficient inference in fully connected crfs with gaussian edge potentials. **Advances in Neural Information Processing Systems**, p. 1–9, 2011. 6, 15, 25
- KÖRTING, T.; DUTRA, L.; FONSECA, L. A resegmentation approach for detecting rectangular objects in high-resolution imagery. **IEEE Geoscience and Remote Sensing Letters**, v. 8, n. 4, p. 621–625, jul. 2011. ISSN 1545-598X.

Disponível em: <[http:](http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5692808)

[//ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5692808](http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5692808)>. 1, 17, 33, 34, 35

KÖRTING, T.; FONSECA, L.; ESCADA, M.; SILVA, F.; SILVA, M. GeoDMA - A novel system for spatial data mining. **IEEE International Conference on Data Mining Workshops**, p. 975–978, dez. 2008. 107

KÖRTING, T. S. **Processamento de imagens**. [S.l.]: São José dos Campos: INPE, 2016. 7

KÖRTING, T. S.; CASTEJON, E. F.; FONSECA, L. M. G. The divide and segment method for parallel image segmentation. In: BLANC-TALON, J.; KASINSKI, A.; PHILIPS, W.; POPESCU, D.; SCHEUNDERS, P. (Ed.). **Advanced concepts for intelligent vision systems**. Cham: Springer, 2013. p. 504–515. ISBN 978-3-319-02895-8. 17, 32

KRÄHENBÜHL, P.; KOLTUN, V. Efficient inference in fully connected crfs with gaussian edge potentials. **arXiv**, abs/1210.5644, 2012. Disponível em: <<http://arxiv.org/abs/1210.5644>>. 3

KRUSKAL, J. B. On the shortest spanning subtree of a graph and the traveling salesman problem. **Proceedings of the American Mathematical Society**, v. 7, n. 1, p. 48–50, 1956. ISSN 00029939, 10886826. Disponível em: <<http://www.jstor.org/stable/2033241>>. 15

LADICKÝ, L. **Global structured models towards scene understanding**. Tese (Doutorado em Ciências da Computação) — Oxford Brookes University, 2011. 24

LADICKÝ, L.; RUSSELL, C.; KOHLI, P.; TORR, P. H. S. Associative hierarchical random fields. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 36, n. 6, p. 1056–1077, June 2014. ISSN 0162-8828. 29

LAFFERTY, J. D.; MCCALLUM, A.; PEREIRA, F. C. N. Conditional random fields: probabilistic models for segmenting and labeling sequence data, 18., 2001. In: INTERNATIONAL CONFERENCE ON MACHINE LEARNING. **Proceedings...** San Francisco, CA, USA: Morgan Kaufmann Publishers, 2001. p. 282–289. ISBN 1-55860-778-1. Disponível em: <<http://dl.acm.org/citation.cfm?id=645530.655813>>. 24

LASSALLE, P.; INGLADA, J.; MICHEL, J.; GRIZONNET, M.; MALIK, J. A scalable tile-based framework for region-merging segmentation. **IEEE Transactions on Geoscience and Remote Sensing**, v. 53, n. 10, p. 5473–5485, Oct 2015. ISSN 0196-2892. [xv](#), [17](#), [19](#), [33](#)

LEITE, T. P. C. **Detecção de estruturas finas e ramificadas em imagens usando campos aleatórios de Markov e informação perceptual**. Tese (Doutorado em Ciência da Computação) — Universidade de São Paulo, São Paulo, 2012. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/45/45134/tde-22102012-153717/>>. [21](#), [22](#)

LI, C.-T. A conditional random field approach to unsupervised texture image segmentation. **EURASIP Journal on Advances in Signal Processing**, v. 2010, p. 76, 2010. [25](#), [29](#), [36](#)

LI, C.-T.; YUAN, Y.; WILSON, R. An unsupervised conditional random fields approach for clustering gene expression time series. **Bioinformatics**, v. 24, n. 21, p. 2467–2473, 2008. [29](#), [35](#), [36](#), [44](#), [104](#), [105](#)

LI, J.; BIOUCAS-DIAS, J. M.; PLAZA, A. Spectral–spatial hyperspectral image segmentation using subspace multinomial logistic regression and markov random fields. **IEEE Transactions on Geoscience and Remote Sensing**, v. 50, n. 3, p. 809–823, 2012. [21](#)

LI, S. Z. Modeling image analysis problems using markov random fields. In: SHANBHAG, D. N.; RAO, C. R. **Stochastic processes: modelling and simulation**. [S.l.]: Elsevier, 2003. p. 473–513. [21](#), [22](#)

LIU, H.; JIN, C.; ZHOU, A. Popular route planning with travel cost estimation. In: INTERNATIONAL CONFERENCE ON DATABASE SYSTEMS FOR ADVANCED APPLICATIONS 2016. **Proceedings...** [S.l.]: Springer, 2016. p. 403–418. [21](#)

LOTUFO, R. A.; O, A. X. F.; ZAMPIROLI, F. A. IFT-Watershed from gray-scale marker. In: BRAZILIAN SYMPOSIUM ON COMPUTER GRAPHICS AND IMAGE PROCESSING, 15., 2002. **Proceedings...** [S.l.], 2002. p. 146–152. [11](#), [37](#)

LV, P.; ZHONG, Y.; ZHAO, J.; ZHANG, L. Unsupervised change detection based on conditional random fields and texture feature for high resolution remote sensing

- imagery. In: INTERNATIONAL CONFERENCE ON SIGNAL AND INFORMATION PROCESSING. **Proceedings...** [S.l.], 2015. p. 1081–1085. 25, 35
- LV, P.; ZHONG, Y.; ZHAO, J.; JIAO, H.; ZHANG, L. Change detection based on a multifeature probabilistic ensemble conditional random field model for high spatial resolution remote sensing imagery. **IEEE Geoscience and Remote Sensing Letters**, v. 13, n. 12, p. 1965–1969, Dec 2016. ISSN 1545-598X. 2
- LV, P.; ZHONG, Y.; ZHAO, J.; ZHANG, L. Unsupervised change detection based on hybrid conditional random field model for high spatial resolution remote sensing imagery. **IEEE Transactions on Geoscience and Remote Sensing**, v. 56, n. 7, p. 4002–4015, July 2018. ISSN 0196-2892. 2, 25, 26, 35, 40
- MANSILLA, L. A. C. **Transformada imagem-floresta com funções de conectividade não suaves: pesos adaptativos, polaridade de borda e restrições de forma**. Tese (Doutorado em Ciências da Computação) — Universidade de São Paulo, São Paulo, 2014. 11, 14, 15
- MÁRQUEZ-NEILA, P.; KOHLI, P.; ROTHER, C.; BAUMELA, L. Non-parametric higher-order random fields for image segmentation. In: EUROPEAN CONFERENCE ON COMPUTER VISION. **Proceedings...** [S.l.], 2014. p. 269–284. 3
- MCCALLUM, A. Efficiently inducing features of conditional random fields. **ArXiv e-prints**, out. 2012. 24, 25
- MEIJSTER, A.; ROERDINK, J. B. Computation of watersheds based on parallel graph algorithms. In: MARAGOS P.; SCHAFFER, R. W. B. M. A. (Ed.). **Mathematical morphology and its applications to image and signal processing**. [S.l.]: Springer, 1996. p. 305–312. 11
- MENDONÇA, G. **Descritor local baseado no algoritmo SIFT para rastreamento e segmentação de objetos em vídeos via grafos de regiões**. Dissertação (Mestrado em Engenharia Elétrica) — Universidade de Brasília, Brasília, 2016. 11
- MEYER, F.; BEUCHER, S. Morphological segmentation. **Journal of Visual Communication and Image Representation**, v. 1, n. 1, p. 21–46, 1990. 11
- MICHEL, J.; GRIZONNET, M.; JAEN, A.; HARASSE, S.; HERMITTE, L.; GUINET, J.; MALIK, J.; SAVINAUD, M. Open tools and methods for large scale segmentation of very high resolution satellite images 2012, yverdon-les-bains,

- switzerland. In: OPEN GEOSPATIAL RESEARCH AND EDUCATION SYMPOSIUM. **Proceeding...** [S.l.], 2012. p. 179–184. 33
- MIRKAMALI, S. S.; NAGABHUSHAN, P. Rgbd image segmentation. In: IRANIAN CONFERENCE ON MACHINE VISION AND IMAGE PROCESSING. **Proceedings...** [S.l.], 2015. p. 41–44. 25
- MOSER, G.; GIORGI, A. D.; SERPICO, S. B. Multiresolution supervised classification of panchromatic and multispectral images by markov random fields and graph cuts. **IEEE Transactions on Geoscience and Remote Sensing**, v. 54, n. 9, p. 5054–5070, Sept 2016. ISSN 0196-2892. 21
- MOYA, N. **Interactive segmentation of multiple 3D objects in medical images by optimum graph cuts**. Dissertação (Mestrado em Ciência da Computação) — Universidade Estadual de Campinas, Campinas, 2013. 11
- MURPHY, K. P.; WEISS, Y.; JORDAN, M. I. Loopy belief propagation for approximate inference: An empirical study. In: CONFERENCE ON UNCERTAINTY IN ARTIFICIAL INTELLIGENCE. **Proceedings...** [S.l.], 1999. p. 467–475. 23
- NAZARINEZHAD, J.; DEHGHANI, M. A contextual-based segmentation of compact polsar images using markov random field (mrf) model. **International Journal of Remote Sensing**, v. 40, n. 3, p. 985–1010, 2019. Disponível em: <<https://doi.org/10.1080/01431161.2018.1523584>>. 30
- NEUBERT, M.; HEROLD, H.; MEINEL, G. Assessing image segmentation quality – concepts, methods and application. In: _____. **Object-based image analysis: spatial concepts for knowledge-driven remote sensing applications**. Berlin, Heidelberg: Springer, 2008. p. 769–784. ISBN 978-3-540-77058-9. Disponível em: <http://dx.doi.org/10.1007/978-3-540-77058-9_42>. 50, 51
- PAL, N. R.; PAL, S. K. A review on image segmentation techniques. **Pattern Recognition**, v. 26, n. 9, p. 1277–1294, 1993. Disponível em: <<http://www.sciencedirect.com/science/article/pii/003132039390135J>>. 5
- PAN, X.; ZHAO, J. High-resolution remote sensing image classification method based on convolutional neural network and restricted conditional random field. **Remote Sensing**, v. 10, n. 6, p. 920, 2018. 2

PENG, B.; ZHANG, L.; ZHANG, D. A survey of graph theoretical approaches to image segmentation. **Pattern Recognition**, v. 46, n. 3, p. 1020–1038, 2013. ISSN 0031-3203. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0031320312004219>>. 15, 16

PERCIANO, T.; USHIZIMA, D. M.; BETHEL, E. W.; MIZRAHI, Y. D.; PARKINSON, D.; SETHIAN, J. A. Reduced-complexity image segmentation under parallel markov random field formulation using graph partitioning. In: INTERNATIONAL CONFERENCE ON IMAGE PROCESSING. **Proceedings**. [S.l.], 2016. p. 1259–1263. 2

PRATT, W. K. Image enhancement. In: _____. **Digital image processing**. John Wiley, 2002. p. 243–296. ISBN 9780471221326. Disponível em: <<http://dx.doi.org/10.1002/0471221325.ch10>>. 6

RAMESH, S. H.; DHAR, A.; KUMAR, R. R.; V., A.; K.S., S.; PEARCE, J.; SUNDARESAN, K. R. Automatically identify and label sections in scientific journals using conditional random fields. In: SACK, H. AND DIETZE, S. AND TORDAI, A. AND LANGE, C. **Semantic web challenges**. Cham: Springer, 2016. p. 269–280. ISBN 978-3-319-46565-4. Disponível em: <http://dx.doi.org/10.1007/978-3-319-46565-4_21>. 25

REIS, M. S.; OLIVEIRA, M. A. F. de; KORTING, T. S.; PANTALEO, E.; SANT'ANNA, S. J. S.; DUTRA, L. V.; LU, D. Image segmentation algorithms comparison. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM. **Proceedings...** [S.l.], 2015. p. 4340–4343. ISSN 2153-6996. 53

REN, X.; MALIK, J. Learning a classification model for segmentation. In: INTERNATIONAL CONFERENCE OF COMPUTER VISION. **Proceedings...** [S.l.], 2003. v. 1, p. 10–17. 12

RIJSBERGEN, C. J. V. **Information retrieval**. 2. ed. Newton, MA, USA: Butterworth-Heinemann, 1979. ISBN 0408709294. 51

ROERDINK, J. B.; MEIJSTER, A. The watershed transform: definitions, algorithms and parallelization strategies. **Fundamenta Informaticae**, v. 41, n. 1, 2, p. 187–228, 2000. 11

SADRKAZEMI, N.; CILLIERS, J. An image processing algorithm for measurement of flotation froth bubble size and shape distributions. **Minerals Engineering**, v. 10, p. 1075–1083, 1997. Disponível em: <[http://dx.doi.org/10.1016/S0892-6875\(97\)00094-0](http://dx.doi.org/10.1016/S0892-6875(97)00094-0)>. 37

SALDANHA, M. F. S. **A multilevel segmentation algorithm for polarimetric SAR images based on Wishart distribution.** Tese (Doutorado em Computação Aplicada) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2013. 1

SEINSTRA, F. J.; KOELMA, D. User transparency: a fully sequential programming model for efficient data parallel image processing. **Concurrency and Computation: Practice and Experience**, v. 16, n. 6, p. 611–644, 2004. 17

SHI, J.; MALIK, J. Normalized cuts and image segmentation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 22, n. 8, p. 888–905, 2000. ISSN 01628828. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=868688>>. 16

SOARES, A. R.; KÖRTING, T. S.; FONSECA, L. M. G. Improvements of the divide and segment method for parallel image segmentation. In: **GEOINFO. Proceedings...** [S.l.], 2015. p. 222–232. 17, 18, 32, 33

SOILLE, P. **Morphological image processing: principles and applications.** [S.l.]: Cambridge University Press, 1999. 1, 37, 38

SUHUBI, E. **Functional analysis.** Springer, 2003. ISBN 9781402016165. Disponível em: <<https://books.google.com.br/books?id=lgy-8VeVXf4C>>. 43

SZELISKI, R.; ZABIH, R.; SCHARSTEIN, D.; VEKSLER, O.; KOLMOGOROV, V.; AGARWALA, A.; TAPPEN, M.; ROTHER, C. A comparative study of energy minimization methods for markov random fields. In: **EUROPEAN CONFERENCE ON COMPUTER VISION. Proceedings...** [S.l.], 2006. p. 16–29. 45

TARABALKA, Y.; TILTON, J. C.; BENEDIKTSSON, J. A.; CHANUSSOT, J. A marker-based approach for the automated selection of a single segmentation from a hierarchical set of image segmentations. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 5, n. 1, p. 262–272, Feb 2012. ISSN 1939-1404. 11

TRÉMEAU, A.; COLANTONI, P. Regions adjacency graph applied to color image segmentation. **IEEE Transactions on Image Processing**, v. 9, n. 4, p. 735–744, 2000. 10

TUIA, D.; VOLPI, M.; MOSER, G. Decision fusion with multiple spatial supports by conditional random fields. **IEEE Transactions on Geoscience and Remote Sensing**, v. 56, n. 6, p. 3277–3289, 2018. 2

VANTARAM, S. R.; SABER, E. Survey of contemporary trends in color image segmentation. **Journal of Electronic Imaging**, v. 21, n. 4, p. 040901–1–040901–28, 2012. Disponível em: <<http://dx.doi.org/10.1117/1.JEI.21.4.040901>>. 2, 5, 21

VEKSLER, O.; ZABIH, R. **Efficient graph-based energy minimization methods in computer vision**. Tese (Doutorado em Ciências da Computação) — Cornell University New York, 1999. 45

WANG, X. **Graph based approaches for image segmentation and object tracking**. Tese (Doutorado em Informática) — Ecole Centrale de Lyon, Ecully, 2015. 13, 15, 16

WASSENBERG, J.; MIDDELMANN, W.; SANDERS, P. An efficient parallel algorithm for graph-based image segmentation. In: JIANG, X. AND PETKOV, N. **Computer analysis of images and patterns**. Berlin, Heidelberg: Springer, 2009. p. 1003–1010. ISBN 978-3-642-03767-2. 17, 33

WEINMAN, J.; HANSON, A.; MCCALLUM, A. Sign detection in natural images with conditional random fields. In: INTERNATIONAL WORKSHOP ON MACHINE LEARNING FOR SIGNAL PROCESSING. 2004,. **Proceedings...** [S.l.], 2004. p. 549–558. 2

WERTHEIMER, M. Laws of organization in perceptual forms. In: ELLIS, W. (Ed.). **A source book of gestalt psychology**. Routledge, 1938. p. 71–88. ISBN 9780415209571. Disponível em: <<http://www.dominiopublico.gov.br/download/texto/ps000200.pdf>>. 1

WU, Z.; LEAHY, R. An optimal graph theoretic approach to data clustering: theory and its application to image segmentation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 15, n. 11, p. 1101–1113, 1993. 16

XIAO, P.; ZHAO, S.; SHE, J. Multispectral ikonos image segmentation based on texture marker-controlled watershed algorithm. **Proceedings of SPIE**, v. 6790, p. 67900U, 2007. 11

XU, B.; CHEN, C.; GAN, Z.; LIU, B. Aurora sequences classification and aurora events detection based on hidden conditional random fields. In: TAN, T.; LI, X.; CHEN, X.; ZHOU, J.; YANG, J.; CHENG, H.; TAN T.; LI, X. C. X. Z. J. Y. J. C. H. (Ed.). **Pattern recognition**. Berlin: Springer, 2016. p. 404–415. ISBN

978-981-10-3005-5. Disponível em:

<http://dx.doi.org/10.1007/978-981-10-3005-5_33>. 25

YANG, J.; JIANG, Z.; HAO, S.; ZHANG, H. Higher order support vector random fields for hyperspectral image classification. **ISPRS International Journal of Geo-Information**, v. 7, n. 1, p. 19, 2018. 2

YANG, W.; LI, D.; ZHU, L. An improved genetic algorithm for optimal feature subset selection from multi-character feature set. **Expert Systems with Applications**, v. 38, n. 3, p. 2733–2740, 2011. ISSN 09574174. Disponível em: <<http://dx.doi.org/10.1016/j.eswa.2010.08.063>>. 25, 26

YANG, X.; GAO, X.; TAO, D.; LI, X.; LI, J. An efficient mrf embedded level set method for image segmentation. **IEEE Transactions on Image Processing**, v. 24, n. 1, p. 9–21, Jan 2015. ISSN 1057-7149. 2

ZAITOUN, N. M.; AQEL, M. J. Survey on image segmentation techniques. **Procedia Computer Science**, v. 65, p. 797–806, 2015. 5

ZEGGADA, A.; BENBRAIKA, S.; MELGANI, F.; MOKHTARI, Z. Multilabel conditional random field classification for uav images. **IEEE Geoscience and Remote Sensing Letters**, v. 15, n. 3, p. 399–403, 2018. 2

ZHANG, G.; JIA, X. Simplified conditional random fields with class boundary constraint for spectral-spatial based remote sensing image classification. **IEEE Geoscience and Remote Sensing Letters**, v. 9, n. 5, p. 856–860, 2012. 35, 43, 104

ZHANG, X.; FENG, X.; XIAO, P.; HE, G.; ZHU, L. Segmentation quality evaluation using region-based precision and recall measures for remote sensing images. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 102, p. 73 – 84, 2015. ISSN 0924-2716. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S092427161500026X>>. 51, 52

ZHANG, X.; MEI, C.; CHEN, D.; LI, J. Feature selection in mixed data: a method using a novel fuzzy rough set-based information entropy. **Pattern Recognition**, v. 56, p. 1–15, 2016. ISSN 00313203. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0031320316000844>>. 2

ZHAO, J.; ZHONG, Y.; SHU, H.; ZHANG, L. High-resolution image classification integrating spectral-spatial-location cues by conditional random fields. **IEEE**

Transactions on Image Processing, v. 25, n. 9, p. 4033–4045, September 2016. 25

ZHAO, J.; ZHONG, Y.; ZHANG, L. Detail-preserving smoothing classifier based on conditional random fields for high spatial resolution remote sensing imagery. **IEEE Transactions on Geoscience and Remote Sensing**, v. 53, n. 5, p. 2440–2452, May 2015. ISSN 0196-2892. 25

ZHENG, C.; ZHANG, Y.; WANG, L. Multilayer semantic segmentation of remote-sensing imagery using a hybrid object-based markov random field model. **International Journal of Remote Sensing**, v. 37, n. 23, p. 5505–5532, 2016. Disponível em: <<http://dx.doi.org/10.1080/01431161.2016.1244364>>. 21

ZHENG, S.; JAYASUMANA, S.; ROMERA-PAREDES, B.; VINEET, V.; SU, Z.; DU, D.; HUANG, C.; TORR, P. H. Conditional random fields as recurrent neural networks. In: INTERNATIONAL CONFERENCE ON COMPUTER VISION. **Proceedings...** [S.l.]: IEEE, 2015. p. 1529–1537. 2

ZHONG, P.; WANG, R. Learning conditional random fields for classification of hyperspectral images. **IEEE Transactions on Image Processing**, v. 19, n. 7, p. 1890–1907, July 2010. ISSN 1057-7149. 25

ZHOU, L.; CAO, G.; LI, Y.; SHANG, Y. Change detection based on conditional random field with region connection constraints in high-resolution remote sensing images. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 9, n. 8, p. 3478–3488, 01 2016. ISSN 1939-1404. 2, 25, 35

ZHU, H.; MENG, F.; CAI, J.; LU, S. Beyond pixels: a comprehensive survey from bottom-up to semantic image segmentation and cosegmentation. **Journal of Visual Communication and Image Representation**, v. 34, p. 12 – 27, 2016. ISSN 1047-3203. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1047320315002035>>. 2, 12

APÊNDICE A - REFERÊNCIAS UTILIZADAS PARA AVALIAÇÃO DOS DATASETS WORLDVIEW-2 E QUICKBIRD.

Esse apêndice contém as referências criadas pelo autor para os *datasets* WorldView-2 e Quickbird.









Tabela A.1 - Polígonos de Referência do *dataset* WorldView-2.








Tabela A.2 - Polígonos de Referência do *dataset* Quickbird.

APÊNDICE B - INFORMAÇÕES SOBRE OS BOXPLOTS APRESENTADOS NO CAPÍTULO 7.

Esse apêndice contém dados estatísticos referentes aos resultados obtidos por cada um dos algoritmos analisados neste trabalho em cada um dos 4 *datasets* utilizados para avaliação.

B.1 WorldView-2

Precisão

Algoritmos	Multiresolução	Meanshift	Bins	UCS
Média	0,802	0,768	0,680	0,821
Desvio _{padrão}	0,258	0,255	0,274	0,208
Mínimo	0,049	0,091	0,061	0,090
Mediana	0,917	0,898	0,801	0,919
Máximo	1,000	1,000	1,000	1,000
Q1	0,643	0,538	0,429	0,699
Q3	0,985	0,962	0,911	0,966
Outliers	1	0	0	2

Revocação

Algoritmos	Multiresolução	Meanshift	Bins	UCS
Média	0,782	0,742	0,758	0,752
Desvio _{padrão}	0,173	0,229	0,191	0,200
Mínimo	0,254	0,107	0,302	0,318
Mediana	0,836	0,810	0,789	0,814
Máximo	1,000	1,000	1,000	1,000
Q1	0,636	0,545	0,601	0,557
Q3	0,911	0,948	0,931	0,923
Outliers	1	0	0	0

F-measure

Algoritmos	Multiresolução	Meanshift	Bins	UCS
Média	0,750	0,693	0,663	0,754
Desvio $_{padrão}$	0,199	0,191	0,194	0,168
Mínimo	0,094	0,167	0,112	0,145
Mediana	0,836	0,697	0,677	0,783
Máximo	0,979	0,967	0,986	0,969
Q1	0,641	0,577	0,538	0,648
Q3	0,905	0,869	0,828	0,905
Outliers	1	0	0	1

FITXY

Algoritmos	Multiresolução	Meanshift	Bins	UCS
Média	0,964	0,958	0,957	0,966
Desvio $_{padrão}$	0,042	0,043	0,041	0,033
Mínimo	0,782	0,766	0,820	0,816
Mediana	0,981	0,973	0,972	0,976
Máximo	0,999	0,998	0,999	0,998
Q1	0,953	0,948	0,938	0,955
Q3	0,992	0,988	0,987	0,989
Outliers	1	7	6	5

FITN

Algoritmos	Multiresolução	Meanshift	Bins	UCS
Média	0,873	0,833	0,835	0,891
Desvio $_{padrão}$	0,132	0,149	0,145	0,129
Mínimo	0,269	0,218	0,234	0,310
Mediana	0,924	0,852	0,869	0,936
Máximo	1,000	0,998	0,999	1,000
Q1	0,807	0,778	0,754	0,831
Q3	0,972	0,955	0,953	0,983
Outliers	1	3	4	3

GShape

Algoritmos	Multiresolução	Meanshift	Bins	UCS
Média	0,731	0,671	0,687	0,739
Desvio _{padrão}	0,196	0,193	0,174	0,175
Mínimo	0,159	0,115	0,124	0,164
Mediana	0,814	0,667	0,709	0,777
Máximo	0,969	0,947	0,985	0,962
Q1	0,626	0,537	0,562	0,637
Q3	0,884	0,839	0,818	0,880
Outliers	1	0	2	2

B.2 Quickbird

Precisão

Algoritmos	Multiresolução	Meanshift	Bins	UCS
Média	0,931	0,799	0,703	0,818
Desvio_Padrão	0,099	0,242	0,353	0,217
Mínimo	0,494	0,051	0,013	0,025
Mediana	0,972	0,882	0,906	0,893
Máximo	1,000	1,000	1,000	1,000
Q1	0,917	0,737	0,452	0,797
Q3	1,000	0,985	0,983	0,965
Outliers	1	8	0	11

Revocação

Algoritmos	Multiresolução	Meanshift	Bins	UCS
Média	0,560	0,602	0,587	0,561
Desvio_Padrão	0,213	0,221	0,224	0,228
Mínimo	0,119	0,250	0,225	0,227
Mediana	0,492	0,510	0,510	0,486
Máximo	0,981	1,000	1,000	0,992
Q1	0,436	0,449	0,429	0,385
Q3	0,741	0,787	0,772	0,761
Outliers	1	0	0	0

F-measure

Algoritmos	Multiresolução	Meanshift	Bins	UCS
Média	0,673	0,625	0,529	0,608
Desvio_Padrão	0,162	0,173	0,232	0,174
Mínimo	0,213	0,096	0,025	0,049
Mediana	0,653	0,620	0,583	0,609
Máximo	0,961	0,958	0,960	0,953
Q1	0,572	0,529	0,430	0,489
Q3	0,815	0,712	0,671	0,685
Outliers	1	4	5	2

FITXY

Algoritmos	Multiresolução	Meanshift	Bins	UCS
Média	0,993	0,991	0,982	0,991
Desvio_Padrão	0,006	0,009	0,025	0,008
Mínimo	0,958	0,949	0,877	0,942
Mediana	0,994	0,993	0,992	0,993
Máximo	1,000	1,000	0,999	1,000
Q1	0,992	0,990	0,983	0,990
Q3	0,998	0,995	0,996	0,996
Outliers	1	9	13	5

FITN

Algoritmos	Multiresolução	Meanshift	Bins	UCS
Média	0,860	0,838	0,773	0,842
Desvio_Padrão	0,088	0,153	0,203	0,100
Mínimo	0,589	0,118	0,182	0,482
Mediana	0,844	0,855	0,835	0,840
Máximo	0,999	0,998	0,999	0,999
Q1	0,816	0,809	0,756	0,776
Q3	0,937	0,920	0,885	0,922
Outliers	1	5	12	2

GShape

Algoritmos	Multiresolução	Meanshift	Bins	UCS
Média	0,763	0,722	0,653	0,726
Desvio_Padrão	0,097	0,148	0,197	0,102
Mínimo	0,525	0,061	0,094	0,401
Mediana	0,740	0,726	0,704	0,713
Máximo	0,962	0,959	0,961	0,954
Q1	0,703	0,678	0,632	0,655
Q3	0,843	0,784	0,751	0,770
Outliers	1	4	13	3

B.3 OLI

Precisão

Algoritmos	Multiresolução	Meanshift	Bins	UCS
Média	0,811	0,758	0,680	0,758
Desvio _{padrão}	0,245	0,224	0,274	0,253
Mínimo	0,085	0,073	0,061	0,070
Mediana	0,938	0,843	0,801	0,895
Máximo	1,000	1,000	1,000	1,000
Q1	0,712	0,699	0,429	0,579
Q3	0,984	0,910	0,911	0,952
Outliers	1	12	0	0

Revocação

Algoritmos	Multiresolução	Meanshift	Bins	UCS
Média	0,723	0,737	0,758	0,727
Desvio _{padrão}	0,200	0,198	0,191	0,193
Mínimo	0,280	0,253	0,302	0,253
Mediana	0,734	0,790	0,789	0,755
Máximo	1,000	1,000	1,000	1,000
Q1	0,558	0,559	0,601	0,578
Q3	0,915	0,906	0,931	0,891
Outliers	1	0	0	0

F-measure

Algoritmos	Multiresolução	Meanshift	Bins	UCS
Média	0,717	0,702	0,663	0,693
Desvio _{padrão}	0,179	0,175	0,194	0,180
Mínimo	0,157	0,136	0,112	0,130
Mediana	0,731	0,745	0,677	0,724
Máximo	0,971	0,959	0,986	0,976
Q1	0,605	0,575	0,538	0,584
Q3	0,877	0,852	0,828	0,838
Outliers	1	2	0	2

FITXY

Algoritmos	Multiresolução	Meanshift	Bins	UCS
Média	0,973	0,970	0,957	0,968
Desvio _{padrão}	0,028	0,028	0,041	0,035
Mínimo	0,861	0,811	0,820	0,794
Mediana	0,981	0,980	0,972	0,981
Máximo	0,999	0,997	0,999	0,999
Q1	0,965	0,960	0,938	0,956
Q3	0,994	0,990	0,987	0,992
Outliers	1	6	6	6

FITN

Algoritmos	Multiresolução	Meanshift	Bins	UCS
Média	0,861	0,865	0,835	0,859
Desvio _{padrão}	0,115	0,148	0,145	0,130
Mínimo	0,491	0,236	0,234	0,316
Mediana	0,882	0,911	0,869	0,887
Máximo	1,000	1,000	0,999	1,000
Q1	0,812	0,817	0,754	0,802
Q3	0,958	0,973	0,953	0,958
Outliers	1	6	4	6

GShape

Algoritmos	Multiresolução	Meanshift	Bins	UCS
Média	0,753	0,729	0,687	0,727
Desvio _{padrão}	0,142	0,161	0,174	0,153
Mínimo	0,363	0,129	0,124	0,187
Mediana	0,754	0,765	0,709	0,745
Máximo	0,966	0,951	0,985	0,973
Q1	0,671	0,648	0,562	0,635
Q3	0,878	0,857	0,818	0,838
Outliers	1	6	2	2

B.4 MUX

Precisão

Algoritmos	Multiresolução	Meanshift	Bins	UCS
Média	0,726	0,741	0,730	0,723
Desvio_Padrão	0,256	0,228	0,224	0,242
Mínimo	0,127	0,083	0,158	0,117
Mediana	0,850	0,837	0,838	0,831
Máximo	0,998	1,000	1,000	1,000
Q1	0,547	0,595	0,525	0,532
Q3	0,933	0,916	0,915	0,925
Outliers	1	1	0	0

Revocação

Algoritmos	Multiresolução	Meanshift	Bins	UCS
Média	0,839	0,803	0,743	0,701
Desvio_Padrão	0,156	0,192	0,197	0,201
Mínimo	0,433	0,318	0,218	0,173
Mediana	0,901	0,886	0,787	0,717
Máximo	1,000	1,000	1,000	1,000
Q1	0,754	0,661	0,601	0,555
Q3	0,957	0,957	0,906	0,884
Outliers	1	0	0	0

F-measure

Algoritmos	Multiresolução	Meanshift	Bins	UCS
Média	0,736	0,731	0,699	0,666
Desvio_Padrão	0,190	0,179	0,163	0,176
Mínimo	0,212	0,151	0,235	0,209
Mediana	0,767	0,763	0,706	0,672
Máximo	0,986	0,979	0,957	0,964
Q1	0,646	0,608	0,559	0,552
Q3	0,897	0,889	0,839	0,814
Outliers	1	1	0	0

FITXY

Algoritmos	Multiresolução	Meanshift	Bins	UCS
Média	0,949	0,950	0,951	0,949
Desvio_Padrão	0,048	0,045	0,038	0,039
Mínimo	0,764	0,766	0,853	0,782
Mediana	0,964	0,962	0,961	0,956
Máximo	0,999	0,999	0,999	0,997
Q1	0,926	0,914	0,923	0,926
Q3	0,989	0,987	0,985	0,980
Outliers	1	2	0	1

FITN


Algoritmos	Multiresolução	Meanshift	Bins	UCS
Média	0,861	0,845	0,855	0,850
Desvio_Padrão	0,141	0,140	0,116	0,125
Mínimo	0,442	0,372	0,553	0,414
Mediana	0,913	0,890	0,886	0,886
Máximo	0,999	1,000	0,997	0,999
Q1	0,799	0,759	0,762	0,770
Q3	0,972	0,964	0,955	0,948
Outliers	1	2	0	3

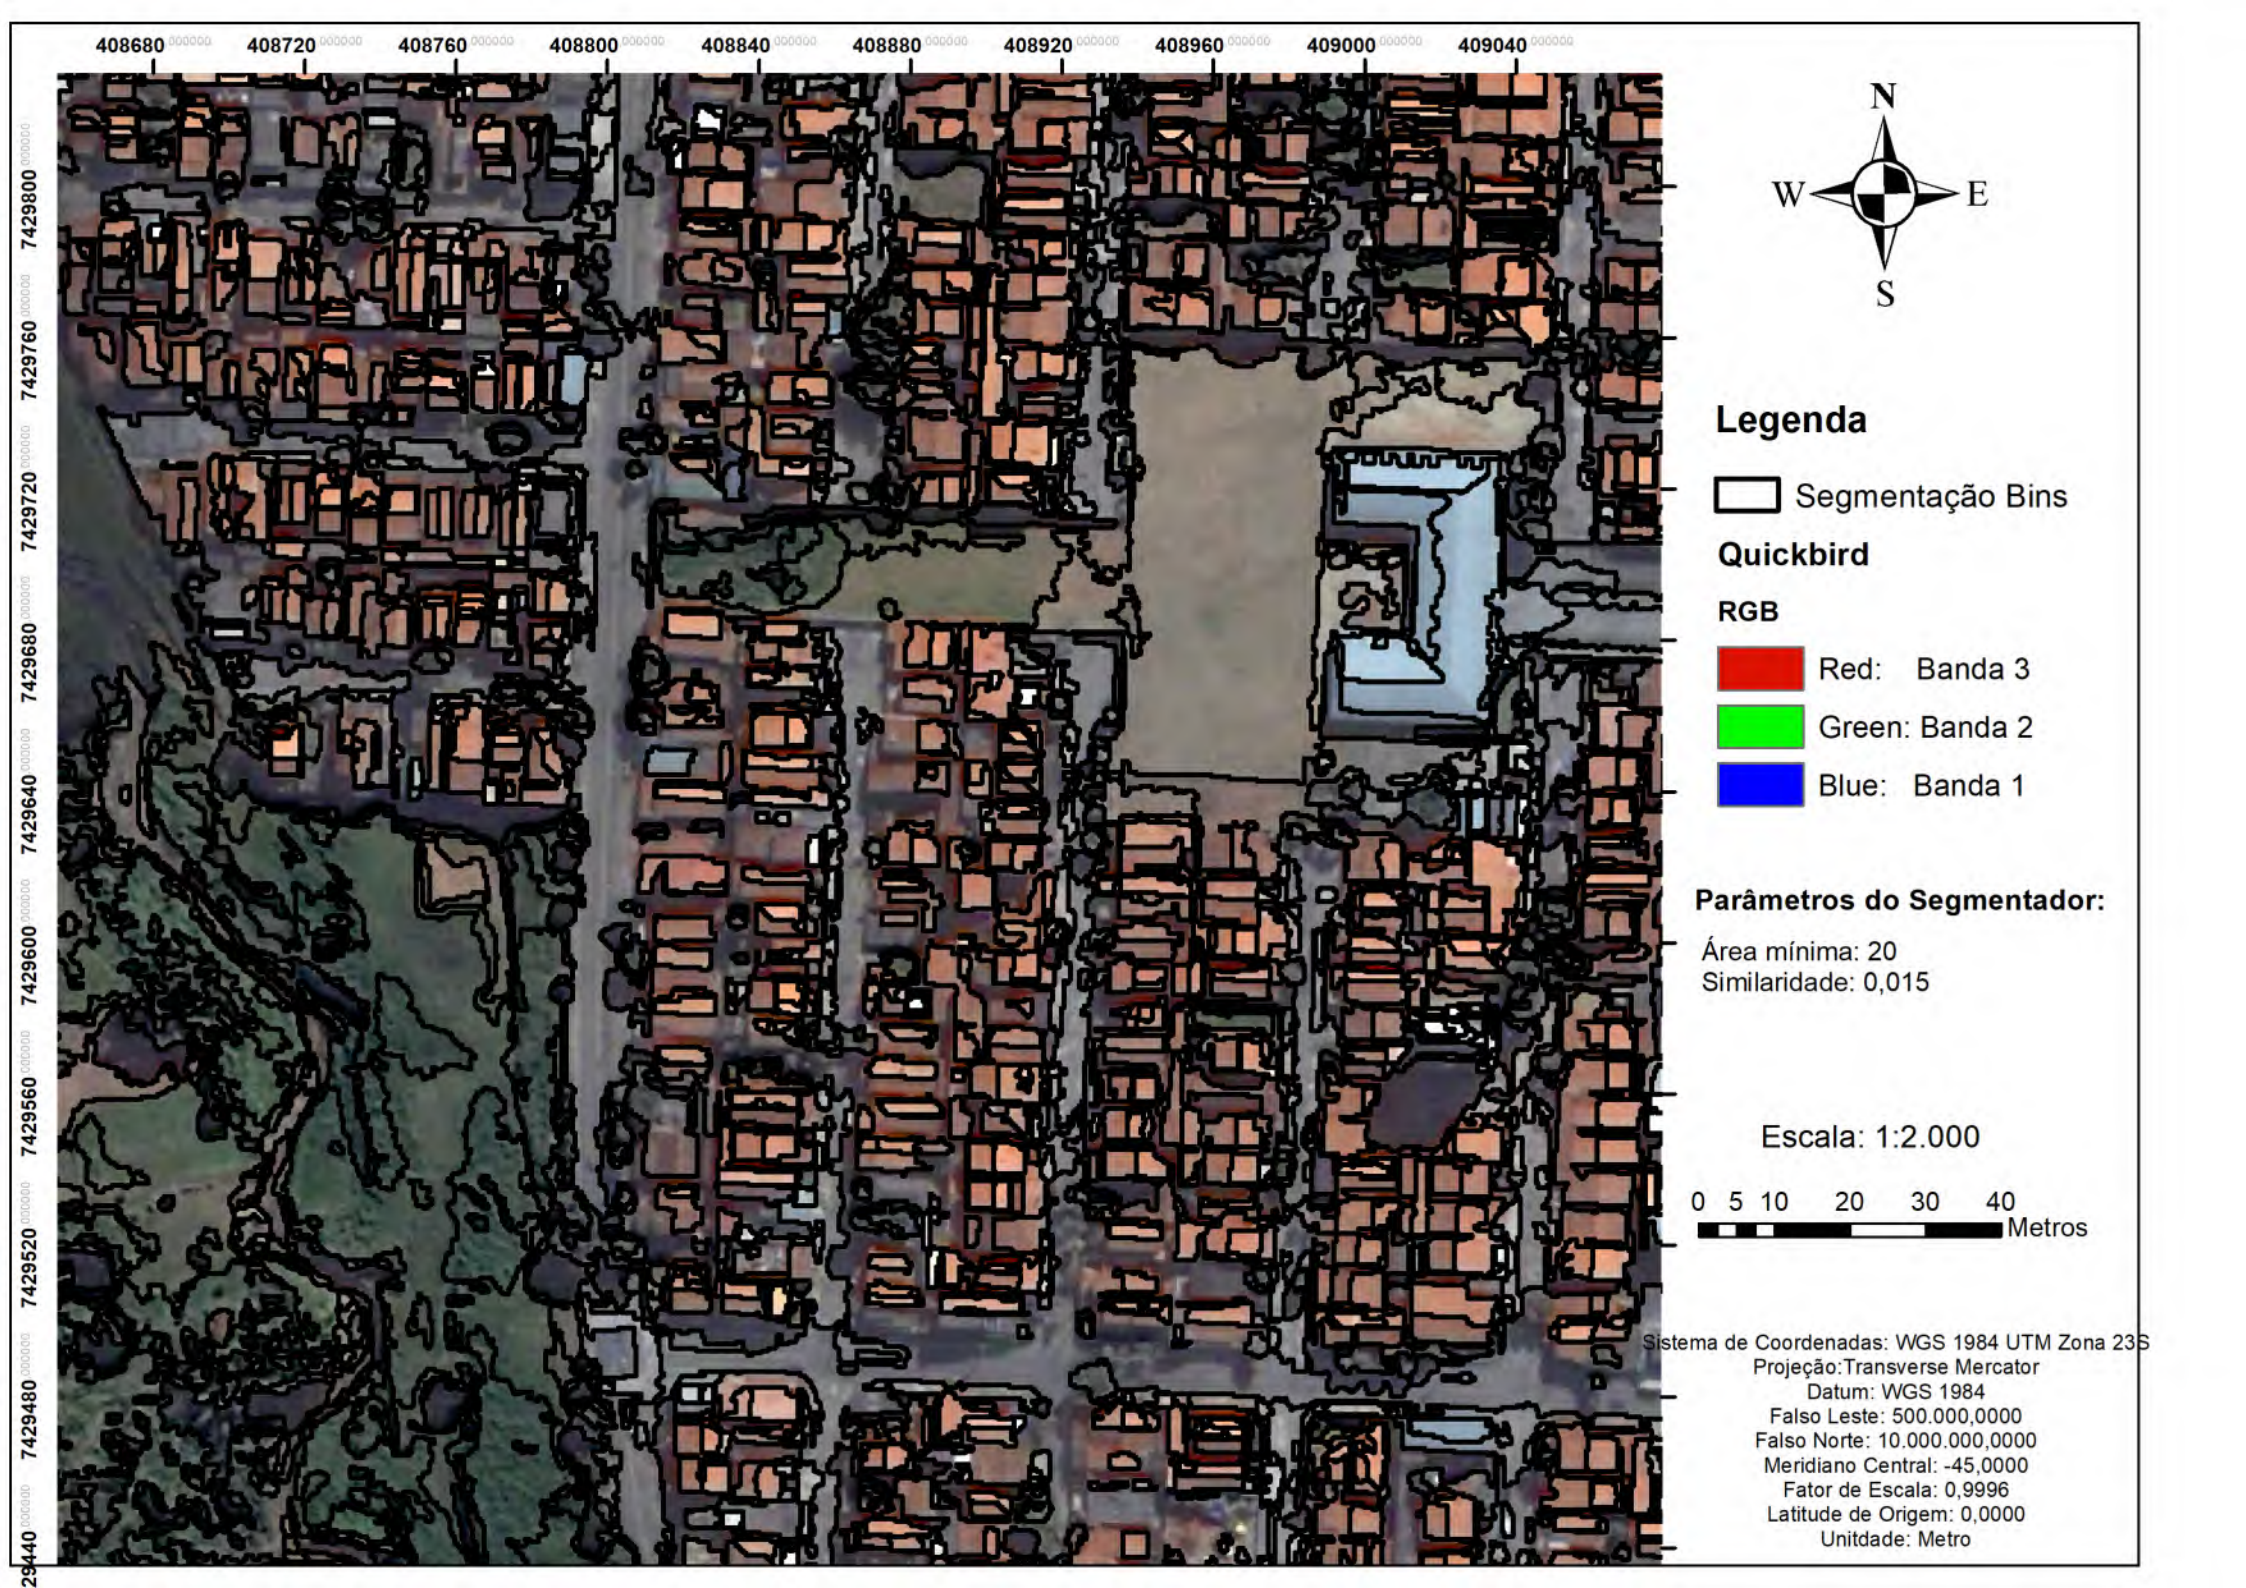
GShape

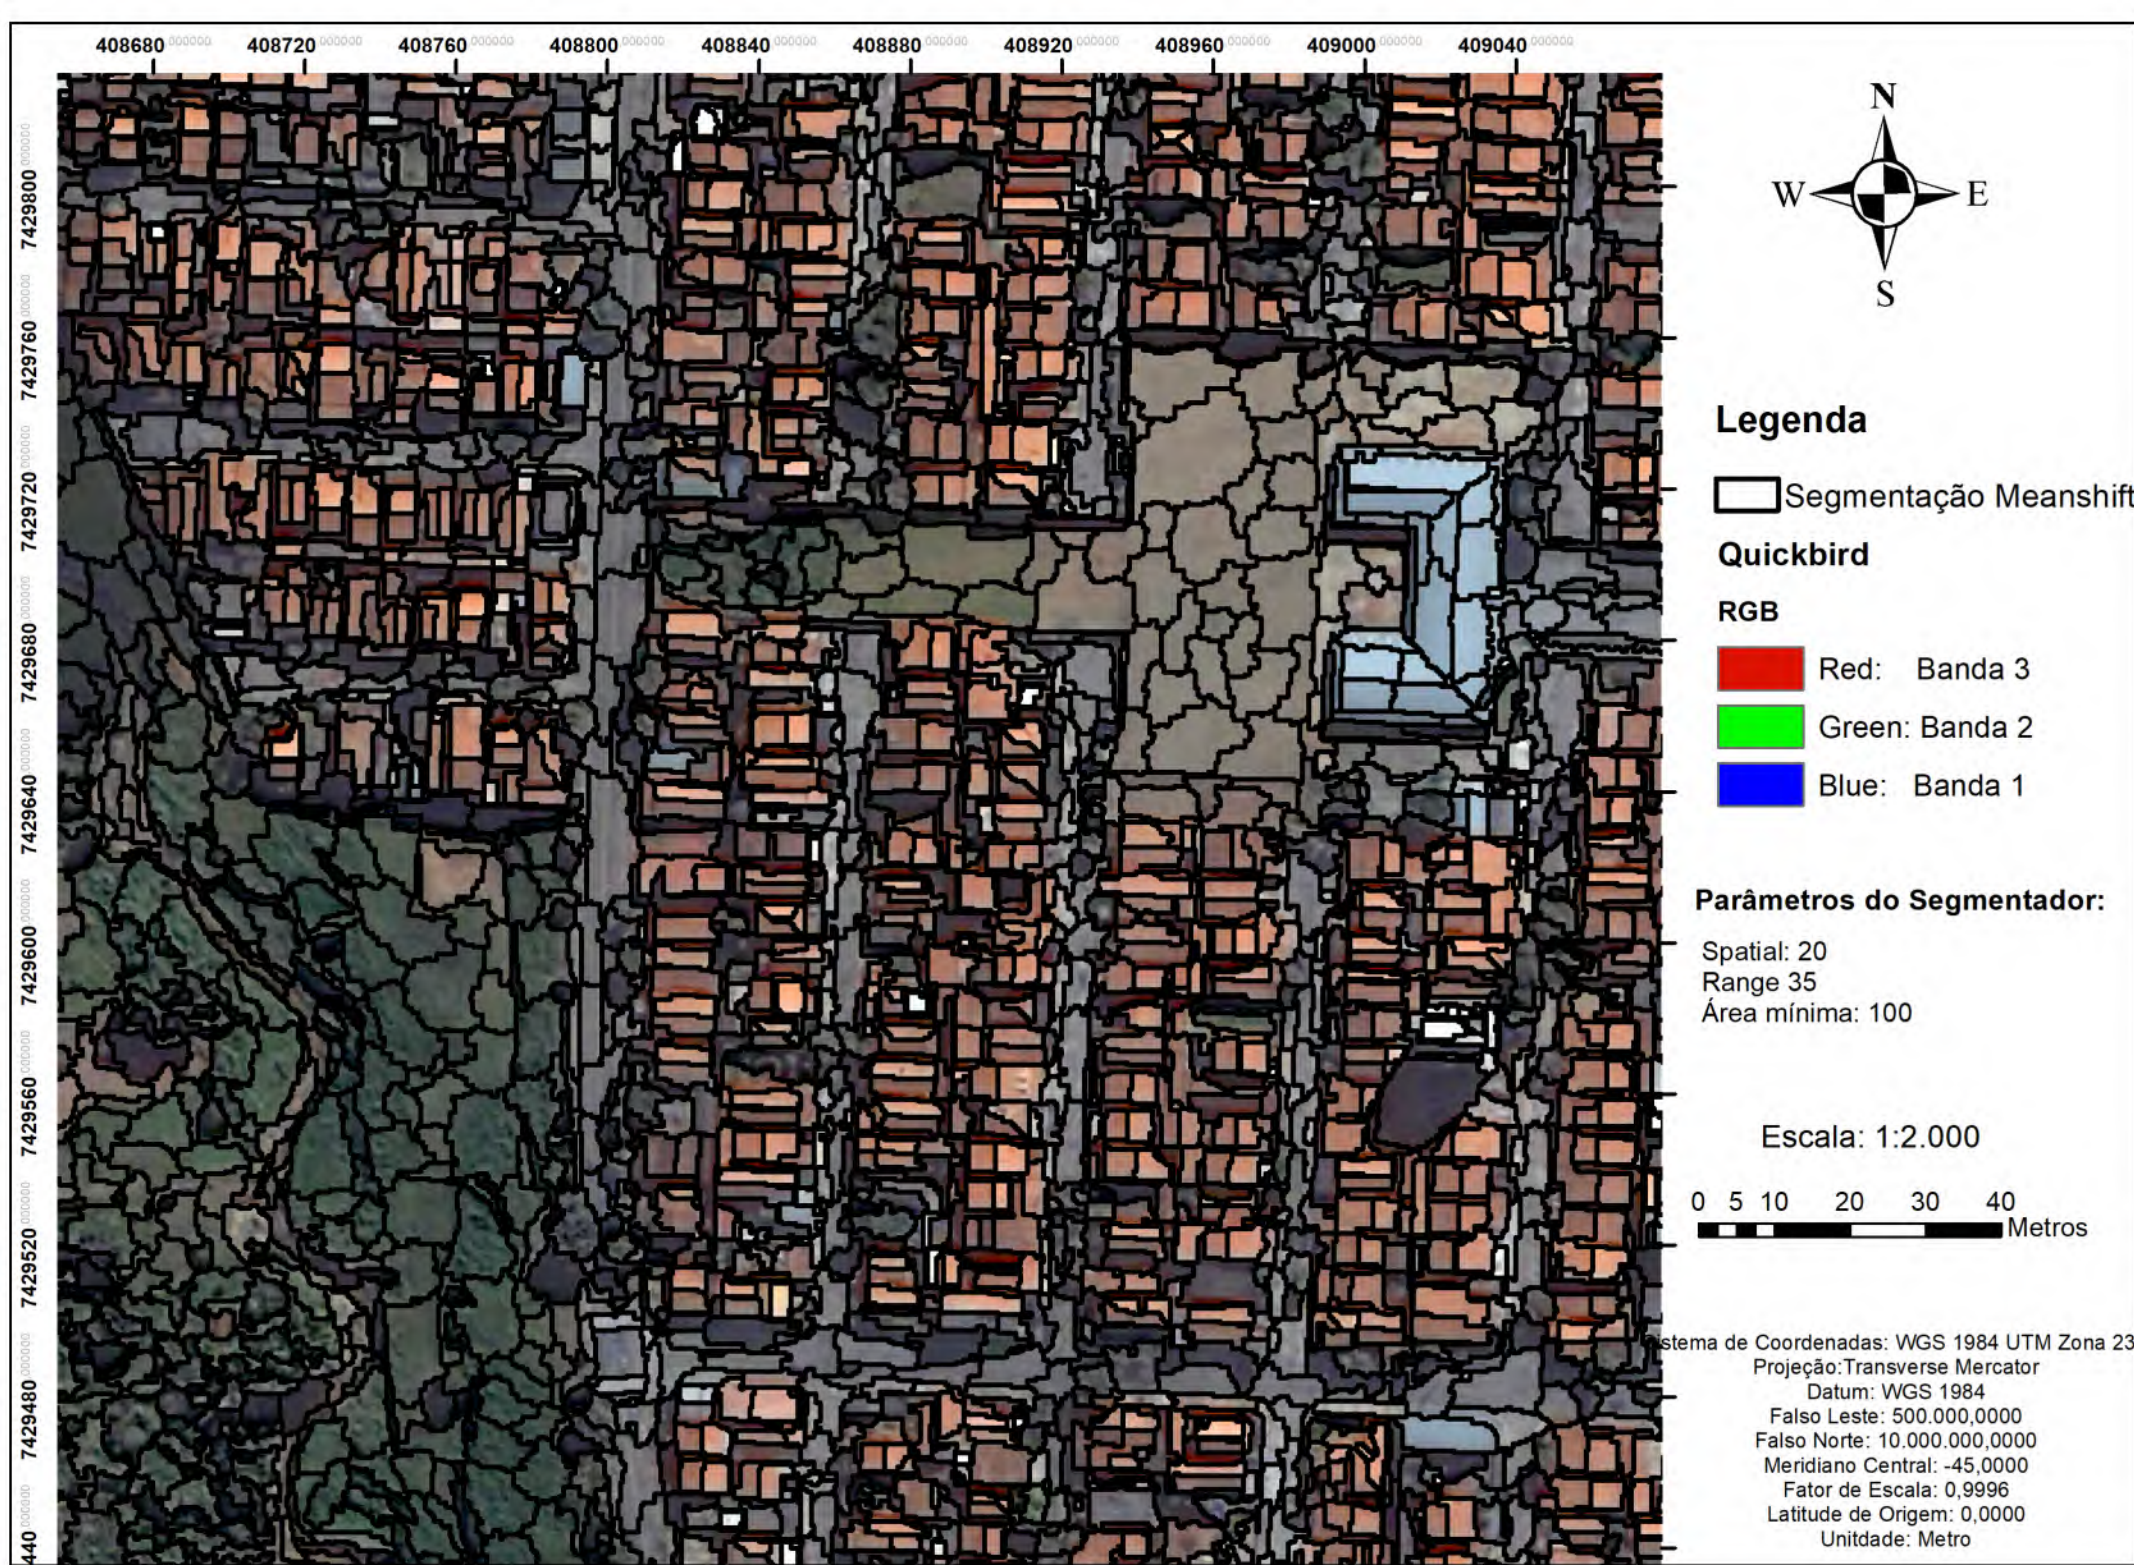
Algoritmos	Multiresolução	Meanshift	Bins	UCS
Média	0,715	0,695	0,673	0,669
Desvio_Padrão	0,188	0,184	0,172	0,159
Mínimo	0,263	0,212	0,293	0,247
Mediana	0,752	0,692	0,691	0,674
Máximo	0,979	0,968	0,945	0,953
Q1	0,602	0,552	0,538	0,565
Q3	0,879	0,874	0,822	0,799
Outliers	1	0	0	0

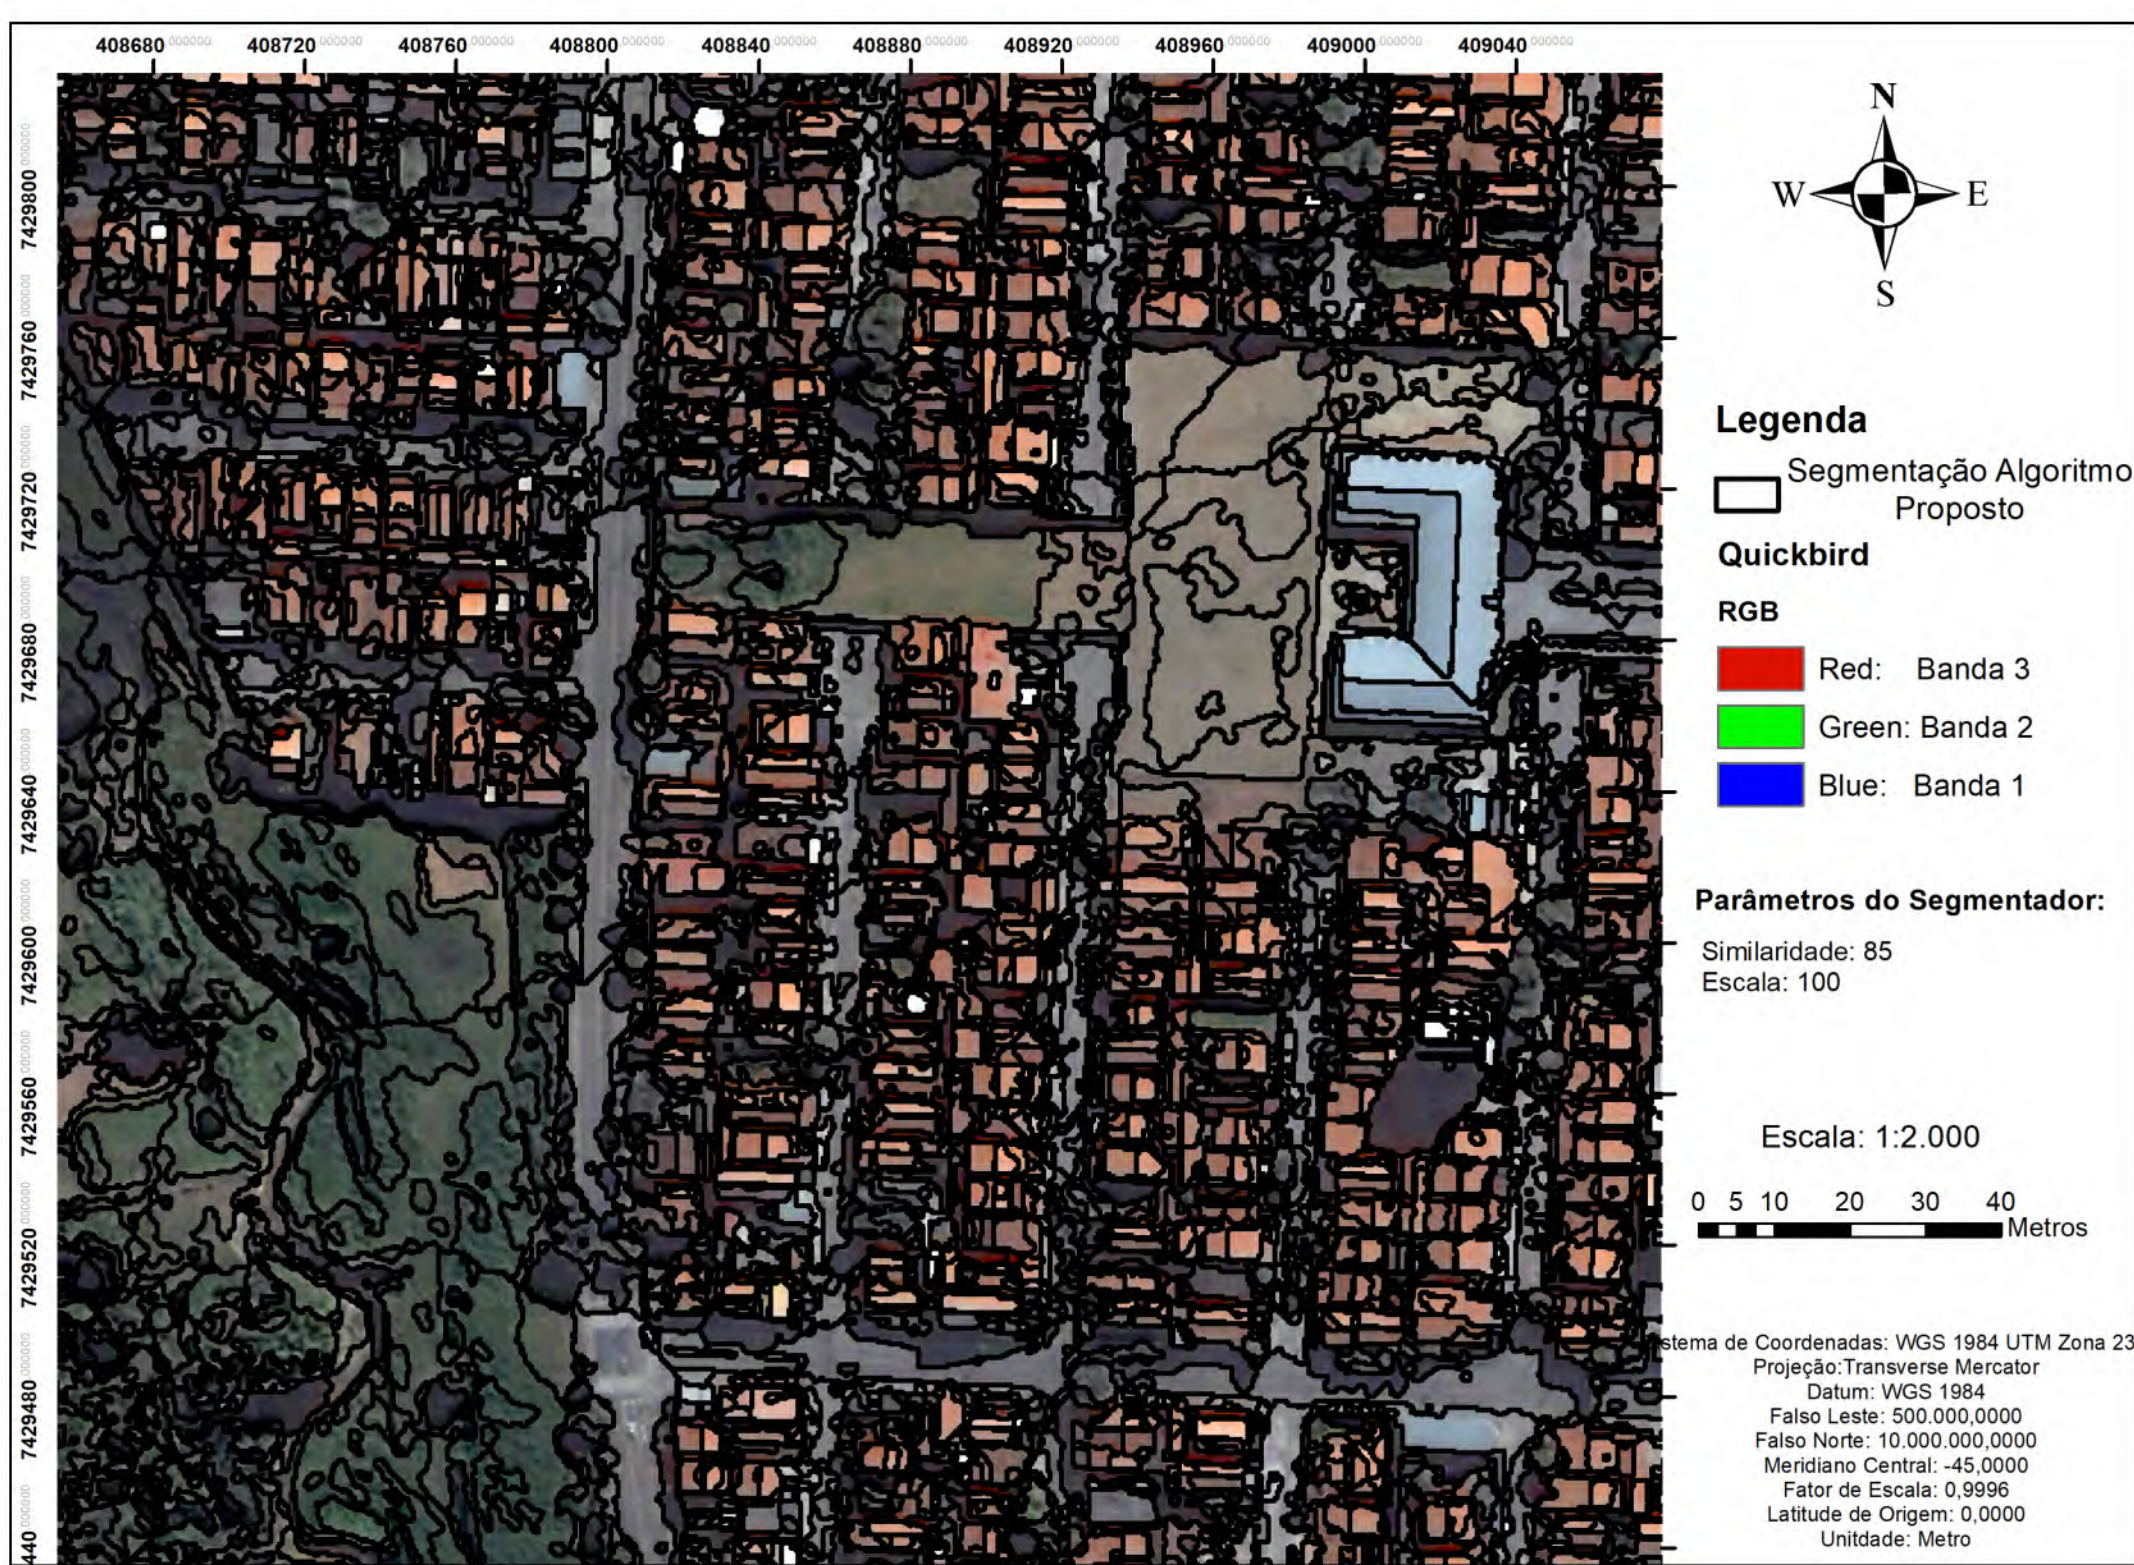
APÊNDICE C - MAPAS DE SEGMENTAÇÃO

Esse apêndice contém os mapas das segmentações geradas para os *datasets* Quickbird, OLI/Landsat-8 e MUX/CBERS-4.










Legenda

 Segmentação Algoritmo Proposto

Quickbird


RGB

-  Red: Banda 3
-  Green: Banda 2
-  Blue: Banda 1

Parâmetros do Segmentador:

Similaridade: 85
Escala: 100

Escala: 1:2.000




Sistema de Coordenadas: WGS 1984 UTM Zona 23S
Projeção: Transverse Mercator
Datum: WGS 1984
Falso Leste: 500.000,0000
Falso Norte: 10.000.000,0000
Meridiano Central: -45,0000
Fator de Escala: 0,9996
Latitude de Origem: 0,0000
Unidade: Metro

52°7'30"W 52°6'0"W 52°4'30"W





Legenda


 Segmentação Multiresolution

OLI/Landsat-8

RGB

 Red: Banda 4

 Green: Banda 3

 Blue: Banda 2

Parâmetros do Segmentador:

Escala: 100

Forma: 0,1

Compacidade: 0,3

Escala: 1:50.000

 0 0,5 1 2 3 Kilometros

Sistema de Coordenadas: WGS 1984 UTM Zone 22S

Projeção: Transverse Mercator

Datum: WGS 1984

Falso leste: 500.000,0000

Falso norte: 10.000.000,0000

Meridiano Central: -51,0000

Fator de Escala: 0,9996

Unidade: Metro

15°4'30"S

15°6'0"S

15°7'30"S




52°7'30"W

52°6'0"W

52°4'30"W



Legenda

 Segmentação Bins - Crescimento por Regiões

OLI/Landsat-8


RGB

-  Red: Banda 4
-  Green: Banda 3
-  Blue: Banda 2

Parâmetros do Segmentador:

Similaridade: 0,0015
Área Mínima: 100

Escala: 1:50.000



Sistema de Coordenadas: WGS 1984 UTM Zone 22S
Projeção: Transverse Mercator
Datum: WGS 1984
Falso leste: 500.000,0000
Falso norte: 10.000.000,0000
Meridiano Central: -51,0000
Fator de Escala: 0,9996
Unidade: Metro

15°4'30"S

15°6'0"S

15°7'30"S



52°7'30"W

52°6'0"W

52°4'30"W





Legenda


 Segmentação Meanshift

OLI/Landsat-8

RGB

 Red: Banda 4

 Green: Banda 3

 Blue: Banda 2


Parâmetros do Segmentador:

Spatial:5

Range : 280

Área Mínima:100

Escala: 1:50.000

 0 0,5 1 2 3
Kilometros

Sistema de Coordenadas: WGS 1984 UTM Zone 22S

Projeção: Transverse Mercator

Datum: WGS 1984

Falso leste: 500.000,0000

Falso norte: 10.000.000,0000

Meridiano Central: -51,0000

Fator de Escala: 0,9996

Unidade: Metro

15°4'30"S

15°6'0"S

15°7'30"S



52°7'30"W

52°6'0"W

52°4'30"W


15°4'30"S

15°6'0"S

15°7'30"S





Legenda


 Segmentação Algoritmo Proposto

OLI/Landsat-8

RGB

 Red: Banda 4

 Green: Banda 3


 Blue: Banda 2

Parâmetros do Segmentador:

Similaridade: 480

Escala:200

Escala: 1:50.000



Sistema de Coordenadas: WGS 1984 UTM Zone 22S
Projeção: Transverse Mercator
Datum: WGS 1984
Falso leste: 500.000,0000
Falso norte: 10.000.000,0000
Meridiano Central: -51,0000
Fator de Escala: 0,9996
Unidade: Metro

52°7'30"W

52°6'0"W

52°4'30"W





Legenda


 Segmentação MRS

MUX/CBERS-4

RGB

 Red: Banda 1

 Green: Banda 2

 Blue: Banda 3


Parâmetros do Segmentador

Escala: 24

Forma: 0,1

Compacidade: 0,9

Escala 1:50.000

 Kilometros
0 0,5 1 2

Sistema de Coordenadas: SIRGAS 2000 UTM Zone 22S

Projeção: Transverse Mercator

Datum: SIRGAS 2000

Falso Leste: 500.000,0000

Falso Norte: 10.000.000,0000

Meridiano Central: -51,0000

Fator de Escala: 0,9996

Latitude de Origem: 0,0000

15°4'30"S

15°6'0"S

15°7'30"S



52°7'30"W

52°6'0"W

52°4'30"W





Legenda


 Segmentação Meanshift

MUX/CBERS-4

RGB

 Red: Banda 1

 Green: Banda 2

 Blue: Banda 3


Parâmetros do Segmentador

Spatial Radius: 5

Range Radius: 3

Área Mínima: 200

Escala 1:50.000



Sistema de Coordenadas: SIRGAS 2000 UTM Zone 22S

Projeção: Transverse Mercator

Datum: SIRGAS 2000

Falso Leste: 500.000,0000

Falso Norte: 10.000.000,0000

Meridiano Central: -51,0000

Fator de Escala : 0,9996

Latitude de Origem: 0,0000

15°4'30"S

15°6'0"S

15°7'30"S



52°7'30"W

52°6'0"W

52°4'30"W





Legenda


 Segmentação Bins

MUX/CBERS-4

RGB

 Red: Banda 1

 Green: Banda 2


 Blue: Banda 3

Parâmetros do Segmentador

Área Mínima: 40

Similaridade: 0,0015

Escala 1:50.000



Sistema de Coordenadas: SIRGAS 2000 UTM Zone 22S

Projeção: Transverse Mercator

Datum: SIRGAS 2000

Falso Leste: 500.000,0000

Falso Norte: 10.000.000,0000

Meridiano Central: -51,0000

Fator de Escala : 0,9996

Latitude de Origem: 0,0000

15°4'30"S

15°6'0"S

15°7'30"S



52°7'30"W

52°6'0"W

52°4'30"W



Legenda

Segmentação Algoritmo
Proposto

MUX/CBERS-4

RGB

Red: Banda 1

Green: Banda 2


Blue: Banda 3

Parâmetros do Segmentador

Similaridade: 8

Escala: 150

Escala 1:50.000



Sistema de Coordenadas: SIRGAS 2000 UTM Zone 22S

Projeção: Transverse Mercator

Datum: SIRGAS 2000

Falso Leste: 500.000,0000

Falso Norte: 10.000.000,0000

Meridiano Central: -51,0000

Fator de Escala : 0,9996

Latitude de Origem: 0,0000

15°4'30"S

15°6'0"S

15°7'30"S

