



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

sid.inpe.br/mtc-m21c/2019/03.29.13.33-TDI

SEGMENTAÇÃO DE IMAGENS DE SENSORIAMENTO REMOTO BASEADA EM SÉRIES TEMPORAIS E DTW

Wanderson Santos Costa

Tese de Doutorado do Curso de Pós-Graduação em Computação Aplicada, orientada pelos Drs. Leila Maria Garcia Fonseca, e Thales Sehn Körting, aprovada em 28 de fevereiro de 2019.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3T2SPDL>>

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 INTELLECTUAL DO INPE - CEPPII (PORTARIA Nº 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/2019/03.29.13.33-TDI

SEGMENTAÇÃO DE IMAGENS DE SENSORIAMENTO REMOTO BASEADA EM SÉRIES TEMPORAIS E DTW

Wanderson Santos Costa

Tese de Doutorado do Curso de Pós-Graduação em Computação Aplicada, orientada pelos Drs. Leila Maria Garcia Fonseca, e Thales Sehn Körting, aprovada em 28 de fevereiro de 2019.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3T2SPDL>>

INPE
São José dos Campos
2019

Dados Internacionais de Catalogação na Publicação (CIP)

Costa, Wanderson Santos.

C823s Segmentação de imagens de sensoriamento remoto baseada em séries temporais e DTW / Wanderson Santos Costa. – São José dos Campos : INPE, 2019.

xxvi + 97 p. ; (sid.inpe.br/mtc-m21c/2019/03.29.13.33-TDI)

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

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

1. Segmentação multitemporal. 2. Processamento de imagens. 3. Sensoriamento remoto. 4. Dynamic Time Warping 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/).

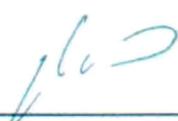
This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

Aluno (a): **Wanderson Santos Costa**

Título: "SEGMENTAÇÃO DE IMAGENS DE SENSORIAMENTO REMOTO BADEADA EM SÉRIES TEMPORAIS E DTW"

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

Dr. Rafael Duarte Coelho dos Santos



Presidente / INPE / SJC Campos - SP

() Participação por Vídeo - Conferência

Aprovado () Reprovado

Dra. Leila Maria Garcia Fonseca

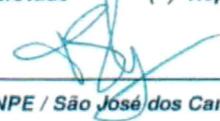


Orientador(a) / INPE / SJC Campos - SP

() 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. Patrick Nigri Happ



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

Participação por Vídeo - Conferência

Aprovado () Reprovado

Dr. Jorge Antonio Silva Centeno



Convidado(a) / UFPR / Curitiba - PR

() Participação por Vídeo - Conferência

Aprovado () Reprovado

Este trabalho foi aprovado por:

() maioria simples

unanimidade

São José dos Campos, 28 de fevereiro de 2019

“Curiosity is its own reason. Aren’t you in awe when you contemplate the mysteries of eternity, of life, of the marvelous structure behind reality? And this is the miracle of the human mind — to use its constructions, concepts, and formulas as tools to explain what man sees, feels and touches. Try to comprehend a little more each day. Have holy curiosity.”

ALBERT EINSTEIN
em “Einstein and the Poet. (Fourth conversation -
1954)”

*A meus pais **Valdenira e Valdercio.***

AGRADECIMENTOS

Agradeço à Dra. Leila Maria Garcia Fonseca e ao Dr. Thales Sehn Körting. Muito obrigado pela orientação, por todas as ideias, pela dedicação, pela paciência e confiança depositadas.

Aos meus pais e meu irmão, pelo incentivo e amor incondicionais.

Ao Fábio, pela amizade, por todo o suporte e por não me deixar desaminar nos momentos difíceis.

A todos os amigos que conheci pela CAP, especialmente aos mais próximos: Felipe, Marluce, Ivana, Pedro e Sandy.

Aos amigos de Sergipe, pelos longos anos de amizade e por entenderem meus momentos de ausência, em especial à Tâmara.

Aos doutores Fernando Ramos e Aline Soterroni, pela amizade, confiança e conselhos nas etapas finais do doutorado.

Aos membros da banca examinadora, por todos os comentários e sugestões.

Ao Instituto Nacional de Pesquisas Espaciais, pela oportunidade de estudo e utilização de suas instalações.

À Dra. Margareth Simões, ao Patrick Kuchler, à EMBRAPA e ao projeto GeoABC (CAPES/COFECUB 845/15) pela auxílio na coleta e disponibilização de dados.

À CAPES e à FAPESP, pelo auxílio financeiro.

Agradeço a todos que contribuíram direta e indiretamente para a conclusão deste trabalho. Muito obrigado!

RESUMO

A disponibilidade de uma grande quantidade de dados de sensores remotos com diferentes resoluções temporais e espaciais tem tornado cada vez mais acessível e detalhada a observação da Terra. Dentro deste contexto, o uso de segmentadores eficientes em aplicações de sensoriamento remoto apresenta um papel importante neste cenário, ao buscar regiões homogêneas no domínio espaço-tempo e, conseqüentemente, reduzir o conjunto de dados. Além disso, a segmentação multitemporal pode trazer uma nova maneira de interpretação dos dados, ao produzir regiões contíguas no tempo. Portanto, este trabalho descreve um algoritmo de segmentação multitemporal baseado em séries temporais obtidas a partir de imagens ópticas de sensoriamento remoto. A distância *Dynamic Time Warping* foi utilizada como critério de homogeneidade na segmentação e quatro estudos de caso foram realizados para avaliar o método proposto. Nesta avaliação são usadas séries temporais de índices de vegetação NDVI e EVI geradas a partir de imagens MODIS, Landsat-8 e Landsat-7. Outros critérios de homogeneidade foram avaliados. As avaliações qualitativa e quantitativa demonstraram o potencial do método de segmentação proposto.

Palavras-chave: Segmentação multitemporal. Processamento de imagens. Sensoriamento remoto. *Dynamic Time Warping*.

SEGMENTATION OF REMOTE SENSING IMAGES BASED ON TIME SERIES AND DTW

ABSTRACT

The availability of a large amount of remote sensing data with different temporal and spatial resolutions has increasingly made Earth observation more accessible and detailed. In this context, the use of efficient remote sensing image segmenters in remote sensing applications plays an important role in this scenario when searching for homogeneous regions in space-time domain and, consequently, reducing the dataset. In addition, multitemporal segmentation can bring a new way of interpreting data, producing contiguous regions in time. Therefore, this thesis has the objective the development of a multitemporal segmentation algorithm based on time series from remote sensing optical images. The Dynamic Time Warping distance was used as the homogeneity criterion and four case studies were performed to evaluate the proposed method. In this evaluation, time series of vegetation indices NDVI and EVI were used, generated from MODIS, Landsat-8 and Landsat-7 images. NDVI and EVI vegetation indices from these sensors were used to create the time series. Other homogeneity criteria were evaluated. The qualitative and quantitative evaluations demonstrated the potential of the proposed segmentation method.

Keywords: Multitemporal Segmentation. Image Processing. Remote Sensing. Dynamic Time Warping.

LISTA DE FIGURAS

	<u>Pág.</u>
1.1 Linha temporal da maioria dos sensores ópticos/multiespectrais até 2015.	2
2.1 Etapas fundamentais de um sistema de processamento de imagens.	5
2.2 Ocorrência de super-segmentação e sub-segmentação em uma imagem.	7
2.3 Histograma de intensidade que pode ser dividido por um limiar T único.	9
2.4 Técnica de divisão e junção de regiões. (a) <i>Quadtree</i> correspondente. (b) Imagem particionada.	11
2.5 Algoritmo <i>Watershed</i> . Simulação de inundação através dos mínimos locais. O conjunto de linhas de contenção criado ao final do algoritmo define o contorno das regiões da imagem segmentada.	15
2.6 Sobreposição de dois objetos resultantes da segmentação em imagens em tempos diferentes (t_1 e t_2), com erro de registro em uma das imagens. Caso alguma imagem apresente erro de registro, ocorrerão inconsistências na formação da região sobreposta, prejudicando a análise.	17
2.7 Objetos de interesse e a resolução espacial das imagens. Em baixa resolução (a), os pixels são maiores que os objetos, gerando regiões com mais de um alvo. Com resolução média (b), os pixels e o tamanho dos objetos podem ser da mesma ordem, podendo ser aplicadas técnicas de estratégia pontual para detectar os objetos. Em imagens de alta resolução (c), a segmentação é necessária para reunir grupos de pixels para formação de objetos.	17
2.8 Tipologia das mudanças geométricas dos objetos.	18
3.1 Exemplo de uma série temporal para o pixel $p(x, y)$	22
3.2 Séries temporais do índice EVI2 (original e filtrado) para o pixel selecionado na imagem (em vermelho).	26
3.3 Apesar de as duas séries apresentarem formas similares, elas não estão alinhadas com relação ao eixo do tempo. Neste caso, a medida DTW permite o cálculo de uma distância mais intuitiva a partir do alinhamento dinâmico em relação ao tempo, gerando uma resposta melhor se comparada à distância Euclidiana.	27

3.4	Exemplo de preenchimento da matriz de distâncias acumuladas. A diferença absoluta foi utilizada como medida δ	29
3.5	Exemplo do funcionamento do cálculo para obtenção do melhor caminho.	29
3.6	Alinhamento de duas séries (azul e vermelho) por meio da DTW. (a) definição do caminho ótimo (em verde). (b) O alinhamento resultante (em verde).	30
3.7	Detalhe das restrições locais comumente utilizadas.	31
3.8	Ilustração de caminhos para um par de séries de tamanhos 9 e 7, respectivamente. (a) Caminho que satisfaz as três condições impostas. (b) A condição de limite é violada. (c) A condição de monotonicidade é violada. (d) A condição de continuidade é violada.	31
3.9	Restrições globais para busca do caminho ótimo. Apenas a área em cinza é considerada em cada caso. (a) Banda de Sakoe-Chiba. (b) Paralelogramo de Itakura.	32
4.1	Fluxograma da metodologia proposta. O algoritmo utiliza uma sequência de imagens de um mesmo local como entrada, seleciona as sementes e faz o crescimento de regiões com base na comparação da distância DTW da semente e seus vizinhos. O resultado final é obtido e comparado com mapas de referência para obtenção de índices de qualidade.	36
4.2	Exemplos de sequências de imagens MODIS (à esquerda) e Landsat-8 (à direita) que podem ser utilizados como dados de entrada do algoritmo. Neste exemplo, cada pixel corresponde a um valor do índice de vegetação NDVI.	37
5.1	Área do Estudo de Caso 1 (Região de Santo Antônio de Goiás - Goiás). Imagem NDVI Landsat-8 OLI.	44
5.2	Sequência de 44 imagens NDVI (Landsat-8 OLI) utilizadas no Estudo de Caso 1 (T_1, T_2, \dots, T_{44}). Pode-se notar que algumas imagens contêm alto percentual de cobertura de nuvens (regiões mais escuras, como por exemplo T_1, T_2 e T_3).	45
5.3	Polígonos (contornos em amarelo) fornecidos pela EMBRAPA. Os polígonos rotulados ($F_1, P_1, P_2, P_3, P_4, P_5, A_1, A_2, A_3$ e A_4) foram utilizados como referência. Os polígonos estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2).	46

5.4	Resultado da segmentação (imagem superior) com o método proposto. Os segmentos (contornos em azul) estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2). Área ampliada (imagem inferior) contendo os polígonos de referência (contornos em amarelo) e os segmentos obtidos pelo algoritmo (contornos em azul).	47
5.5	Resultado da segmentação (imagem superior) utilizando a distância de Manhattan como critério de homegeneidade. Os segmentos (contornos em azul) estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2). Área ampliada (imagem inferior) contendo os polígonos de referência (contornos em amarelo) e os segmentos obtidos pelo algoritmo (contornos em azul).	49
5.6	Resultado da segmentação (imagem superior) utilizando a distância Euclidiana como critério de homegeneidade. Os segmentos (contornos em azul) estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2). Área ampliada (imagem inferior) contendo os polígonos de referência (contornos em amarelo) e os segmentos obtidos pelo algoritmo (contornos em azul).	50
5.7	Imagem NDVI, T_{21} , da sequência de imagens utilizada como dados de entrada (a) com alta presença de nuvens (com destaque na área pontilhada em amarelo). Os polígonos preenchidos em amarelo ilustram segmentos que foram gerados por influência da cobertura de nuvens, utilizando as distâncias DTW (b), Manhattan (c) e Euclidiana (d) como critério de homogeneidade. Os contornos em azul representam os segmentos obtido em cada teste.	52
5.8	Resultados utilizando limiar de área $A = 7200 \text{ m}^2$ para as distâncias DTW (a), de Manhattan (b) e Euclidiana (c). Os segmentos (contornos em azul) estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2).	53
5.9	Resultado da segmentação do Estudo de Caso 1 utilizando a distância DTW com a restrição global da janela de busca de Sakoe-Chiba. Os segmentos (contornos em azul) estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2).	54
5.10	Resultado da segmentação do Estudo de Caso 1 utilizando a distância DTW com a restrição global da janela de busca de Itakura. Os segmentos (contornos em azul) estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2).	55

5.11	Resultado da segmentação para cada época de safra/inverno. Os segmentos (contornos em azul) estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2).	56
5.12	Área do Estudo de Caso 2. Imagem NDVI Landsat-8 OLI.	57
5.13	Sequência de 27 imagens NDVI (Landsat-8 OLI) utilizadas no Estudo de Caso 2 (T_1, T_2, \dots, T_{27}).	58
5.14	Polígonos (contornos em vermelho) fornecidos pela EMBRAPA e utilizados como referência. Os polígonos estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2).	59
5.15	Resultado da segmentação utilizando o DTW como critério de homogeneidade. Os segmentos (contornos em amarelo) estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2).	61
5.16	Resultado da segmentação utilizando a distância de Manhattan como critério de homogeneidade. Os segmentos (contornos em amarelo) estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2).	61
5.17	Resultado da segmentação utilizando a distância Euclidiana como critério de homogeneidade. Os segmentos (contornos em amarelo) estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2).	62
5.18	Resultados utilizando limiar de área $A = 60000 \text{ m}^2$ para as distâncias DTW (a), de Manhattan (b) e Euclidiana (c) para comparação com os polígonos de referência (d) (contornos em vermelho). Os segmentos (contornos em amarelo) estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2).	64
5.19	Resultado da segmentação do Estudo de Caso 2 utilizando a distância DTW com a restrição global da janela de busca de Sakoe-Chiba. Os segmentos (contornos em amarelo) estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2).	65
5.20	Resultado da segmentação do Estudo de Caso 2 utilizando a distância DTW com a restrição global da janela de busca de Itakura. Os segmentos (contornos em amarelo) estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2)	65
5.21	Área do Estudo de Caso 3. Imagem EVI Landsat-8 OLI. Os polígonos em vermelho foram utilizados como referência.	66
5.22	Sequência de 46 imagens EVI (Landsat-8 OLI) utilizadas no Estudo de Caso 3 (T_1, T_2, \dots, T_{46}).	67

5.23	Resultado da segmentação utilizando a distância DTW como critério de homogeneidade para os 15 polígonos. Os segmentos (contornos em branco) e os polígonos de referência (em vermelho) estão sobrepostos em uma imagem EVI Landsat-8 OLI.	69
5.24	Resultado da segmentação utilizando a distância de Manhattan como critério de homogeneidade para os 15 polígonos. Os segmentos (contornos em branco) e os polígonos de referência (em vermelho) estão sobrepostos em uma imagem EVI Landsat-8 OLI.	70
5.25	Resultado da segmentação utilizando a distância Euclidiana como critério de homogeneidade para os 15 polígonos. Os segmentos (contornos em branco) e os polígonos de referência (em vermelho) estão sobrepostos em uma imagem EVI Landsat-8 OLI.	70
5.26	Boxplot das métricas analisadas para as 15 segmentações do Estudo de Caso 3. Os pontos marcados em X representam o valor médio de cada métrica para cada experimento.	73
5.27	Área do Estudo de Caso 4. Primeira imagem NDVI Landsat-8 OLI da sequência de dados de entrada.	74
5.28	Sequência de 85 imagens NDVI (Landsat-8 OLI) utilizadas no Estudo de Caso 4 (T_1, T_2, \dots, T_{85}).	75
5.29	Resultado da segmentação utilizando a distância DTW como critério de homogeneidade para o Estudo de Caso 4. Os segmentos (contornos em vermelho) estão sobrepostos em uma imagem NDVI Landsat-8 OLI.	77
5.30	Localização da área de estudo do exemplo de aplicação da metodologia. Imagem Landsat-8 (R4G3B2).	79
5.31	Resultado da segmentação (contornos em vermelho) para o exemplo de aplicação da metodologia. Os segmentos resultantes foram sobrepostos em uma imagem Landsat-8 (R4G3B2). A área ampliada à direita indica que o método proposto distinguiu regiões de áreas urbanas (centro), de vegetação nativa e de agricultura. . .	80
5.32	Conjunto de 92 imagens NDVI (T_1, T_2, \dots, T_{92}) com correção atmosférica utilizadas como dados de entrada para o exemplo de aplicação da metodologia.	81

LISTA DE TABELAS

	<u>Pág.</u>
4.1 Observações entre a imagem de referência e a imagem segmentada.	40
5.1 Descrição da cobertura do solo para cada safra/inverno no período analisado.	44
5.2 Tempo computacional de cada distância analisada no Estudo de Caso 1.	54
5.3 Descrição do uso do solo de cada polígono rotulado durante o período analisado.	60
5.4 Tempo computacional de cada distância analisada no Estudo de Caso 2.	63
5.5 Sumário dos resultados quantitativos para cada referência do Estudo de Caso 3.	72
5.6 Tempo computacional de cada distância analisada no Estudo de Caso 4.	76
5.7 Tempo computacional dos Estudos de Caso 1, 2 e 4 utilizando a distância DTW como critério de homogeneidade.	77

LISTA DE ABREVIATURAS E SIGLAS

SPOT	–	<i>Satellite Pour l’Observation de la Terre</i>
HRV	–	<i>High Resolution Visible</i>
MODIS	–	<i>Moderate-Resolution Imaging Spectroradiometer</i>
DTW	–	<i>Dynamic Time Warping</i>
PDI	–	Processamento Digital de Imagens
NOAA	–	<i>National Oceanic and Atmospheric Administration</i>
AVHRR	–	<i>Advanced Very-High-Resolution Radiometer</i>
NDVI	–	<i>Normalized Difference Vegetation Index</i>
EVI	–	<i>Enhanced Vegetation Index</i>
EVI2	–	<i>Enhanced Vegetation Index 2</i>
OBDTW	–	<i>Open Boundary Dynamic Time Warping</i>
TWDTW	–	<i>Time-Weighted Dynamic Time Warping</i>
ETM	–	<i>Enhanced Thematic Mapper</i>
OLI	–	<i>Operational Land Imager</i>
RAM	–	<i>Random Access Memory</i>
DDA	–	Dia Do Ano
EMBRAPA	–	Empresa Brasileira de Pesquisa Agropecuária
ILPF	–	Integração Lavoura-Pecuária-Floresta

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
2 SEGMENTAÇÃO DE IMAGENS DE SENSORIAMENTO REMOTO	5
2.1 Detecção de descontinuidades	8
2.2 Segmentação baseada em similaridade	8
2.2.1 Limiarização	8
2.2.2 Segmentação baseada em regiões	10
2.2.2.1 Divisão e junção de regiões	10
2.2.2.2 Crescimento de regiões	10
2.2.2.3 <i>Mean-shift</i>	14
2.2.2.4 Detecção de bacias (<i>Watershed</i>)	14
2.3 Segmentação e multitemporalidade	15
3 SÉRIES TEMPORAIS DE IMAGENS DE SATÉLITES	21
3.1 Análise da cobertura vegetal	23
3.2 <i>Dynamic Time Warping</i>	26
4 METODOLOGIA	35
4.1 Dados de entrada	35
4.2 Segmentador espaço-temporal	36
4.3 Avaliação de resultados da segmentação	38
5 RESULTADOS E DISCUSSÕES	43
5.1 Estudo de Caso 1: Região Supervisionada pela EMBRAPA - Santo Antônio de Goiás	43
5.2 Estudo de Caso 2: Fazenda Gamada - Mato Grosso	57
5.3 Estudo de Caso 3: Área de sobreposição de imagens Landsat-8 em São Paulo	66
5.4 Estudo de Caso 4: Análise do Tempo Computacional	74
5.5 Estudo de Caso 5: Análise da segmentação em imagens MODIS	78
6 CONSIDERAÇÕES FINAIS	83

REFERÊNCIAS BIBLIOGRÁFICAS 85

1 INTRODUÇÃO

O volume e a diversidade de dados de satélites e outros sensores de observação da Terra têm aumentado muito nos últimos 30 anos (KUENZER et al., 2014). Estes dados têm sido utilizados em várias aplicações na área de sensoriamento remoto, tais como o monitoramento do meio ambiente, o planejamento e gerenciamento urbano, a gestão de recursos naturais e análises de mudança no uso e cobertura do solo (ZHANG et al., 2017).

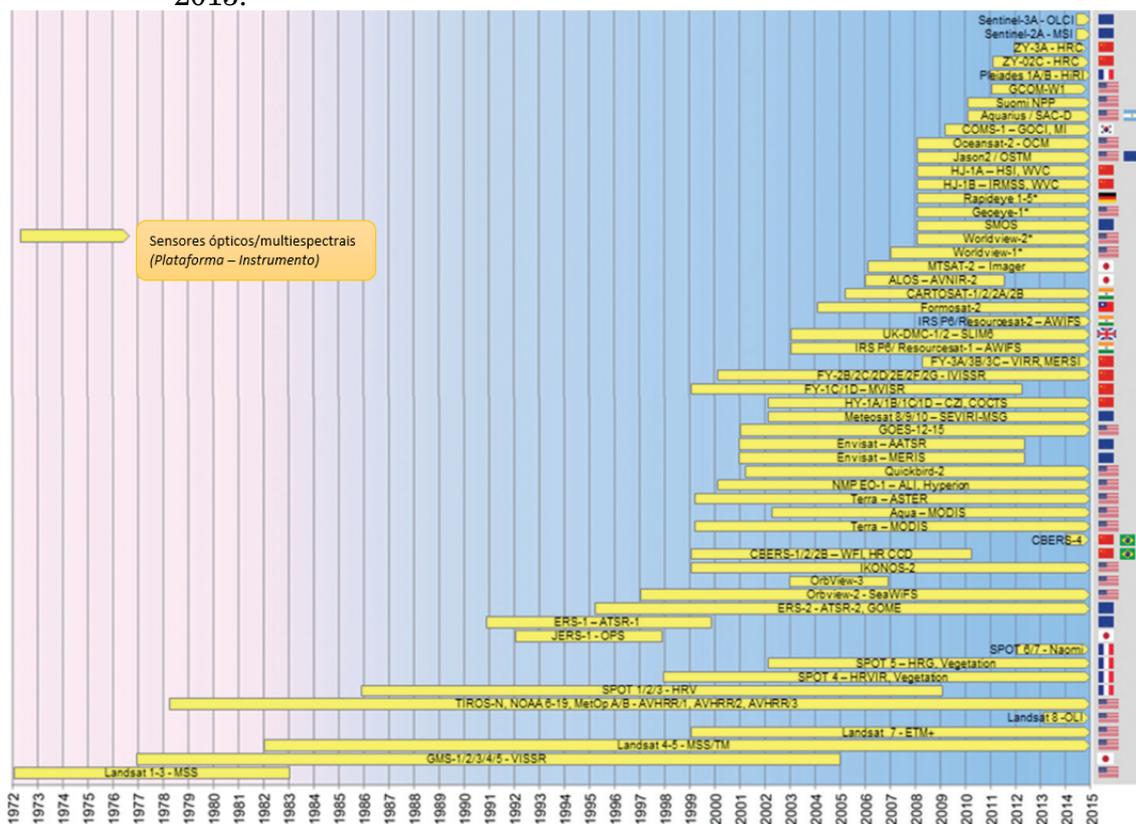
As mudanças no uso e cobertura do solo alteram o balanço energético e os ciclos biogeoquímicos do planeta, contribuindo para as mudanças climáticas e, conseqüentemente, afetam as propriedades da superfície terrestre (SONG et al., 2018). A análise de mudanças do solo, como o monitoramento das florestas tropicais, depende predominantemente de sensores ópticos de sensoriamento remoto devido à facilidade de processamento e à disponibilidade desde a época de 1970 (REICHE et al., 2016). Na Figura 1.1, estão citados os principais sensores ópticos utilizados para observação da Terra que podem ser utilizados em estudos que envolvem dados temporais.

Se a análise de imagens de sensoriamento remoto utilizar apenas estratégias pontuais (com operadores pixel a pixel), informações inerentes aos objetos da imagem, tais como forma e área, não serão aproveitadas. Com o objetivo de explorar estas informações, as imagens são segmentadas para particionar as imagens em regiões cujos pixels apresentem propriedades similares (GONZALEZ; WOODS, 2006; BLASCHKE, 2010). Neste caso, as regiões identificadas são tratadas como objetos, a partir dos quais podem ser extraídos atributos que são utilizados na análise das imagens (SCHIEWE, 2002). Com efeito, o resultado do processo de segmentação reduz consideravelmente o volume de dados a ser analisado.

Em termos de qualidade e desempenho, particionar uma imagem em regiões é um desafio, uma vez que bons resultados têm um alto custo computacional (WASSENBERG et al., 2009). O desenvolvimento de algoritmos deve balancear os recursos computacionais disponíveis para considerar fatores como contexto, vizinhança e escala. Conseqüentemente, novas soluções para contornar estes problemas são necessárias.

A informação temporal é essencial na análise da cobertura da vegetação e os processos de mudança (NOVO-FERNÁNDEZ et al., 2018). A componente

Figura 1.1 - Linha temporal da maioria dos sensores ópticos/multiespectrais até 2015.



Fonte: Adaptada de Kuenzer et al. (2014).

temporal integrada com as propriedades espaciais e espectrais das imagens pode resultar em uma fonte rica de informação que, se adequadamente explorada, permite revelar padrões complexos e importantes no estudo do monitoramento ambiental e análise da dinâmica do uso e cobertura do solo (BORIAH,). Dados como séries temporais de imagens de satélites oferecem novas perspectivas para o entendimento das mudanças oceânicas, terrestres e atmosféricas através da determinação dos fatores que causam estas mudanças e da previsão de mudanças futuras (PETITJEAN et al., 2012). Coleções de séries temporais de imagens de satélite podem ser analisadas para documentar mudanças no solo, enquanto que a resolução espacial fornece os detalhes necessários para analisar a maioria das mudanças causadas tanto por distúrbios naturais quanto antrópicos (NOVO-FERNÁNDEZ et al., 2018; GÓMEZ et al., 2016).

Com o aumento contínuo de imagens de satélite com alta resolução espacial

e temporal, novas técnicas de segmentação de imagens de sensoriamento remoto são necessárias para uma análise eficiente (THOMPSON; LEES, 2014; KHALI et al., 2019). No entanto, existe na literatura um registro de poucos estudos que têm adaptado os métodos baseados em objetos para aplicações com dados multitemporais.

A maioria dos métodos espaço-temporais propostos na literatura realizam a segmentação de cada passo de tempo de forma independente, comparando as mudanças dos objetos após a etapa de segmentação (KHALI et al., 2019; GUTTLER et al., 2017; ZHANG et al., 2017; XIAO et al., 2017; GÓMEZ et al., 2011; DURO et al., 2013; BLASCHKE, 2005; NIEMEYER et al., 2008; PAPE; FRANKLIN, 2008). Alguns trabalhos que incluem as propriedades temporais no processo de segmentação utilizam um número reduzido de imagens multitemporais e não fazem uso de séries temporais de imagens (DESCLÉE et al., 2006; BONTEMPS et al., 2008; DRĂGUȚ et al., 2010; DRĂGUȚ et al., 2014).

Dentro deste contexto, este trabalho tem como objetivo o desenvolvimento de um algoritmo de segmentação de imagens de sensoriamento remoto baseado na análise espaço-temporal. Por meio da adaptação da técnica de segmentação baseada em crescimento de regiões (ADAMS; BISCHOF, 1994) e do uso de séries temporais de sequências de imagens, as propriedades temporais são consideradas na etapa de segmentação. A técnica proposta visa superar as limitações dos algoritmos de detecção de mudanças que utilizam o modelo de segmentação clássico (HARALICK; SHAPIRO, 1985), nos quais as imagens são segmentadas individualmente, havendo a necessidade de analisar o domínio temporal com alguma técnica de pós-processamento.

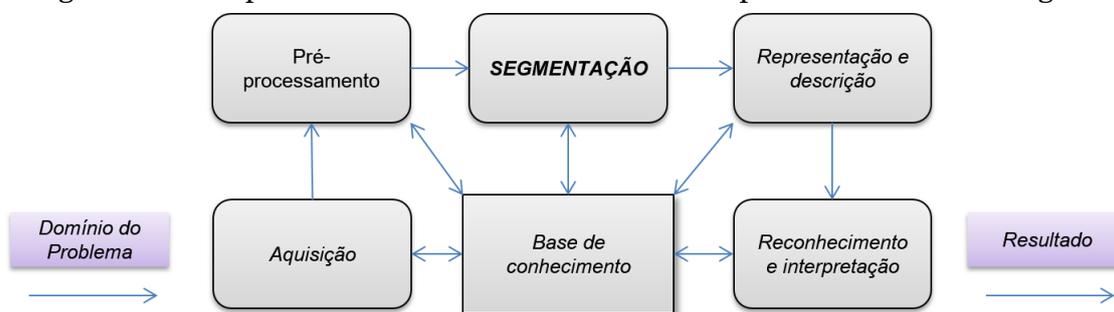
A proposta do método está fundamentada na hipótese de que é possível aprimorar o critério de homogeneidade da segmentação de imagens ópticas, considerando o domínio temporal, além das propriedades espaciais e espectrais. O algoritmo proposto tem como contribuição a melhoria no critério de homogeneidade com base em uma distância mais apropriada ao contexto de séries temporais, uma vez que as medidas utilizadas nos segmentadores tradicionais são baseadas no espaço euclidiano.

2 SEGMENTAÇÃO DE IMAGENS DE SENSORIAMENTO REMOTO

Segundo Gonzalez e Woods (2006), uma imagem pode ser definida como uma função $f(x, y)$, na qual x e y são as coordenadas espaciais, e a amplitude de f na posição (x, y) é denominada de *intensidade* ou *nível de cinza* da imagem. Cada elemento de uma imagem digital é chamado de *pixel*.

As principais etapas de um sistema de *Processamento Digital de Imagens* (PDI) são representadas na Figura 2.1.

Figura 2.1 - Etapas fundamentais de um sistema de processamento de imagens.



Fonte: Adaptada de Gonzalez e Woods (2006).

Na fase de aquisição, um sensor capta uma faixa do espectro eletromagnético e gera, por meio de um processo físico, um sinal elétrico proporcional ao nível de energia recebida. Em seguida, o sinal elétrico é convertido para a forma digital. Na fase de pré-processamento a imagem digital é processada para realçar alvos de interesse e/ou corrigir algum defeito proveniente de sua aquisição. Na etapa de segmentação, a imagem é particionada em regiões ou objetos de interesse à aplicação. Em seguida, um conjunto de atributos (por exemplo, tamanho, posição, forma e textura) que represente e descreva estes objetos são extraídos. Este conjunto de atributos é o conhecimento usado para identificar a classe deste objeto. Na fase de reconhecimento e interpretação, métodos de reconhecimento de padrões são usadas para associar um rótulo a cada objeto, com base nos seus atributos. Além de todas as etapas, vale ressaltar a importância da base de conhecimento, uma vez que o conhecimento sobre o problema a ser resolvido deve guiar o funcionamento de cada etapa e permitir a realimentação entre elas (GONZALEZ; WOODS, 2006).

A etapa de segmentação de imagens digitais é uma tarefa básica e crítica na análise de imagens, na qual a imagem é particionada em regiões de maneira que os elementos de imagem pertencentes a cada objeto sejam similares em relação a um ou mais atributos (HARALICK; SHAPIRO, 1985). Seja R toda a região espacial ocupada por uma imagem e P um predicado lógico que mede a homogeneidade de uma região. A segmentação de uma imagem pode ser definida como um processo que particiona R em n sub-regiões, R_1, R_2, \dots, R_n , utilizando um predicado P , tal que (ZUCKER, 1976; GONZALEZ; WOODS, 2006):

$$\text{a) } \bigcup_{i=1}^n R_i = R.$$

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, todo pixel deve estar contido em uma região. A condição (b) define que os pixels de uma determinada região R_i devem estar conexos a partir de um critério (4- ou 8-conectividade, por exemplo). A terceira condição indica que as regiões devem ser disjuntas. Já a condição (d) determina que todos os pixels em uma região segmentada devem satisfazer as propriedades impostas pelo predicado P . A condição (e) define que duas regiões R_i e R_j adjacentes devem apresentar respostas diferentes em relação ao predicado P (GONZALEZ; WOODS, 2006).

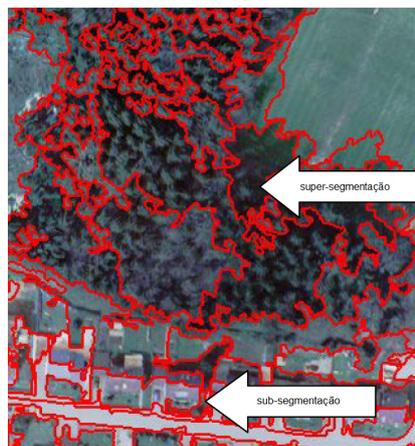
O processo de segmentação pode reduzir consideravelmente o volume de dados a ser analisado. Suponha um recorte de uma sequência de imagens contendo 5000×5000 pixels com resolução espacial de 250 m, coletadas em um intervalo de 15 dias. Um ano de aquisições destas imagens equivalem a 24 imagens, o que totaliza um montante de 600 milhões de pontos a serem analisados. O resultado de uma segmentação que agrupa em média 2000 pixels por região, por exemplo, vai reduzir o conjunto de dados para em torno de 300 mil segmentos, o que representará uma redução de 99,95% no volume de dados a ser analisado.

É importante ressaltar que os algoritmos de segmentação geralmente não resultam em uma partição perfeita da imagem, sendo uma das tarefas

mais difíceis do processamento de imagens (GONZALEZ; WOODS, 2006). No processo de segmentação, pode-se observar a ocorrência de dois fenômenos: a super-segmentação (do inglês, *over-segmentation*), na qual o processo de segmentação divide um objeto de interesse em vários segmentos; e a sobre-segmentação (do inglês, *under-segmentation*), em que são gerados segmentos que contêm mais de um objeto de interesse (SCHIEWE, 2002; COMANICIU; MEER, 1997).

Ao aplicar métodos de segmentação em dados de sensoriamento remoto, observa-se que estes dois fenômenos podem ocorrer dentro de uma única imagem, dependendo da heterogeneidade dos objetos que são levados em consideração. Com isso, níveis diferentes de generalização podem ser obtidos dependendo da aplicação (SCHIEWE, 2002). Na Figura 2.2, são ilustrados exemplos de super-segmentação e sobre-segmentação de regiões na imagem. A região arbórea da parte central da imagem foi subdividida em vários segmentos (super-segmentação), enquanto que na parte inferior da imagem diferentes construções urbanas estão sendo representadas por um único segmento (sub-segmentação).

Figura 2.2 - Ocorrência de super-segmentação e sub-segmentação em uma imagem.



Fonte: Adaptada de Schiewe (2002).

Os algoritmos convencionais de segmentação baseiam-se em dois princípios: o da descontinuidade, que detecta mudanças abruptas nos níveis de cinza; e o da similaridade, que agrupa os pixels que apresentam propriedades similares de acordo com um conjunto de critérios pré-determinados (GONZALEZ; WOODS, 2006). A seguir, os dois princípios são apresentados.

2.1 Detecção de descontinuidades

Nos métodos baseados em detecção de descontinuidades, a partição da imagem é efetuada com base nas mudanças bruscas dos níveis de cinza. As descontinuidades encontradas em uma imagem podem ser em formato de pontos, linhas ou as bordas (contornos) de um objeto. As técnicas geralmente correspondem a operadores de gradiente nas imagens e apresentam bons resultados em imagens com alto contraste entre as regiões (CHENG et al., 2001). Dentre os operadores mais utilizados estão os operadores de Roberts, Sobel, Prewitt e Canny (DASS; DEVI, 2012).

Segundo Bins et al. (1996), a abordagem por detecção de linhas e bordas apresenta desvantagens para alguns tipos de aplicações. A presença de pequenas lacunas nos limites das bordas permite que regiões dissimilares sejam unidas na segmentação, além de ser um processo sensível a variações locais de intensidade, o que gera falhas nos contornos gerados dos objetos.

De acordo com Cheng et al. (2001), a detecção de bordas não é o resultado da segmentação em si, uma vez que as técnicas desta categoria apresentam dificuldade em identificar contornos fechados. Com isso, é necessário aplicar outros algoritmos de pós-processamento para fechar as bordas (GONZALEZ; WOODS, 2006; CHENG et al., 2001). Além disso, o ruído presente nas imagens pode criar bordas adicionais falsas, resultando em uma super-segmentação (SCHIEWE, 2002). Ademais, ao tentar diminuir o nível de ruído com algum filtro, há a chance de criar lacunas nos limites das bordas, uma vez que o nível de detalhes da imagem é reduzido, fazendo com que muitas bordas não sejam detectadas ou não produzam regiões fechadas (KANG et al., 2009; VARSHNEY et al., 2009).

2.2 Segmentação baseada em similaridade

Métodos baseados em similaridade particionam a imagem em regiões, cujos elementos são semelhantes de acordo com um conjunto de critérios predefinidos. Os métodos de limiarização, divisão e junção de regiões e crescimento de regiões estão inclusos nesta categoria.

2.2.1 Limiarização

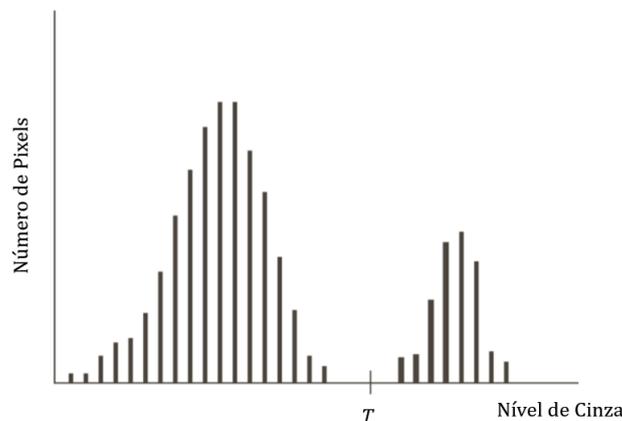
A limiarização é uma das técnicas mais simples de segmentação. A técnica baseia-se na diferença dos níveis de cinza que compõe diferentes

objetos de uma imagem. A segmentação é realizada a partir da observação do histograma da imagem, onde os pixels são agrupados conforme sua intensidade, considerando um limiar T .

Supõe-se que, ao observar o histograma, os objetos são facilmente detectados através de um algoritmo de busca por picos e vales, em que cada pico seja equivalente a uma região que se expande até seus respectivos vales (CHENG et al., 2001). Em uma imagem limiarizada, atribui-se um valor fixo para todos os pixels da mesma região. Por exemplo, para uma imagem $f(x, y)$, que apresenta um histograma como o ilustrado na Figura 2.3, a imagem $g(x, y)$ segmentada, pode ser definida como:

$$g(x, y) = \begin{cases} 1 & \text{se } f(x, y) > T \\ 0 & \text{se } f(x, y) \leq T \end{cases} \quad (2.1)$$

Figura 2.3 - Histograma de intensidade que pode ser dividido por um limiar T único.



Fonte: Adaptada de Gonzalez e Woods (2006).

Embora seja simples e de baixo custo computacional, a técnica não é eficaz ao tratar imagens com histogramas que não apresentam picos ou com vales muito amplos. E como a determinação de um objeto é baseada principalmente na similaridade das cores, a limiarização não é eficiente ao tentar separar objetos que apresentem sombras e diferenças de textura ou iluminação. Além disso, não são levadas em consideração as propriedades espaciais da imagem (CHENG et al., 2001).

2.2.2 Segmentação baseada em regiões

Nesta subseção, são descritos algoritmos de segmentação baseados em encontrar as regiões de forma direta.

2.2.2.1 Divisão e junção de regiões

Uma alternativa baseada em similaridade consiste na técnica de *divisão e junção de regiões*. Na etapa de *divisão*, a segmentação inicia-se com regiões formadas por uma grande quantidade de pixels da imagem e, recursivamente, as regiões não-homogêneas são subdividas em áreas menores. Em geral, a imagem inteira pode ser considerada como a região inicial. O processo de subdivisão finaliza quando todas as regiões satisfizerem o critério de homogeneidade (GONZALEZ; WOODS, 2006).

Caso apenas a etapa de divisão de regiões fosse utilizada, a partição final eventualmente poderia apresentar regiões adjacentes apresentando propriedades similares. Para minimizar este problema, na etapa final desta técnica é realizada a *junção* de regiões adjacentes cujos pixels combinados satisfaçam ao predicado P , isto é, duas regiões adjacentes R_i e R_j são unidas somente se $P(R_i \cup R_j) = \text{VERDADEIRO}$. O algoritmo termina quando nenhuma união for mais possível.

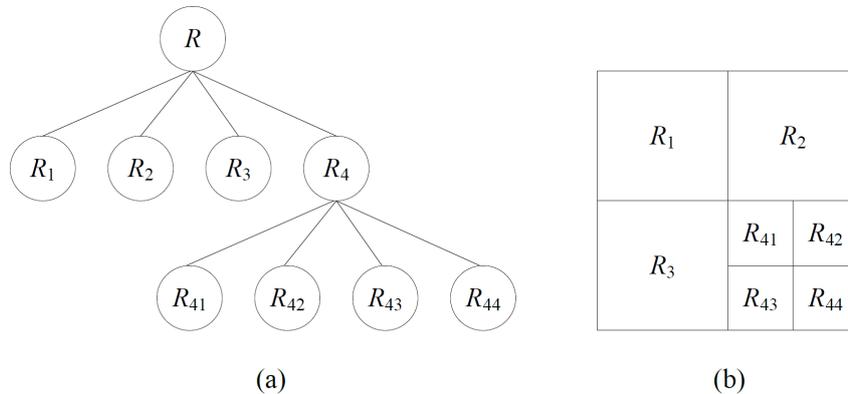
Uma técnica comum para divisão da imagem em sub-regiões homogêneas utiliza a representação *quadtree* (Figura 2.4), que se resume a uma estrutura hierárquica baseada na decomposição recursiva e regular da imagem em quadrantes, de modo que, para qualquer região R_i , $P(R_i) = \text{VERDADEIRO}$. Se o predicado P for FALSO para qualquer quadrante, este deve ser subdividido em sub-quadrantes e assim por diante.

Em contrapartida, o método é baseado na representação em quadrantes. Com isso, os segmentos resultantes tendem a imitar a estrutura de dados usada para representar a imagem, podendo gerar regiões quadradas (CHENG et al., 2001).

2.2.2.2 Crescimento de regiões

Embasada nas cinco condições expostas no início deste capítulo, a segmentação baseada em *crescimento de regiões* é uma abordagem iterativa simples que agrupa pixels ou sub-regiões em regiões maiores a partir de

Figura 2.4 - Técnica de divisão e junção de regiões. (a) *Quadtree* correspondente. (b) Imagem particionada.



Fonte: Gonzalez e Woods (2006).

um critério predefinido para o crescimento. O processo define um conjunto de pixels denominados *sementes*. Cada semente, no início, é uma região. Cada região cresce à medida que outros pixels que possuem propriedades similares são agregados a cada semente (ADAMS; BISCHOF, 1994). Ao utilizar, por exemplo, a diferença de intensidades como medida de similaridade, o predicado P empregado para incluir um pixel em uma das regiões verifica se o módulo da diferença entre os níveis de cinza e o da semente é menor que um limiar T , de modo que:

$$P(R) = \begin{cases} \text{VERDADEIRO} & \text{se } |p(x, y) - p(x_s, y_s)| \leq T \\ \text{FALSO} & \text{caso contrário} \end{cases}, \quad (2.2)$$

onde $p(x_s, y_s)$ representa a semente e $p(x, y)$ representa os pixels conexos à semente por alguma vizinhança. Qualquer pixel que satisfaça esta propriedade é então agregado à região.

Genericamente, o algoritmo de crescimento de regiões pode ser expresso a partir das seguintes etapas:

- a) Determinar a quantidade e localização das sementes na imagem.
- b) Comparar uma semente com os pixels vizinhos e determinar se eles são similares, utilizando uma medida de similaridade. Em caso afirmativo, os pixels vizinhos que satisfazem o critério de crescimento são agregados à região e a propriedade utilizada para comparação

dos pixels é atualizada.

- c) Continuar o crescimento da região examinando todos os vizinhos até não restar nenhuma região que possa ser agregada. Rotular o fragmento obtido como uma região completa.
- d) Realizar o crescimento de regiões para a próxima semente não rotulada e repetir o processo até que todos os pixels estejam rotulados.

Embora seja uma abordagem eficiente para muitas aplicações, esta estratégia apresenta algumas desvantagens. Uma delas é o alto custo computacional (SINGH *et al.*, 1999). Outro problema consiste na escolha das sementes. Diferentes conjuntos de sementes produzem diferentes resultados na segmentação. Além disso, há a dependência da ordem de processamento das sementes, o que é particularmente evidente quando as regiões adjacentes são pequenas ou apresentam níveis de intensidade semelhantes (BINS *et al.*, 1996; MEHNERT; JACKWAY, 1997).

A fim de reduzir estas desvantagens ou adaptar-se ao problema de interesse de cada aplicação, várias pesquisas utilizam modificações do algoritmo de crescimento de regiões criado por Adams e Bischof (1994). Por exemplo, Mehnert e Jackway (1997) propuseram uma modificação na técnica para reduzir a dependência da ordem em que as sementes são processadas, enquanto que Shih e Cheng (2005) adaptaram o algoritmo para tratar imagens coloridas (utilizando as bandas do vermelho, verde e azul) a partir da seleção automática de sementes.

Bins *et al.* (1996) exploraram o problema da dependência da ordem do crescimento das regiões para segmentação em imagens de sensoriamento remoto com coberturas agrícolas e florestais. A segmentação foi feita baseada na semelhança entre os pixels vizinhos e a menor área permitida pelo algoritmo para uma região, de forma que a cada iteração do algoritmo é definido um conjunto de sub-imagens, e o par mais semelhante de regiões espacialmente adjacentes é unido em cada sub-imagem. Já Baatz e Schäpe (2000) elaboraram uma técnica com o objetivo de minimizar a heterogeneidade média dos segmentos gerados. Além da escolha de um limiar definido pelo usuário, cada pixel recebe um peso associado à heterogeneidade da região ao qual ele pertence. Para que uma possível junção aconteça,

escolhe-se o pixel para a qual o grau de heterogeneidade seja mínimo para a união, caso este valor esteja abaixo de um determinado limiar.

Segundo [Oliveira \(2002\)](#), a definição de limiares de área e similaridade na segmentação baseada em regiões é um passo fundamental do algoritmo, devido a sua influência direta na precisão do produto final. O limiar de área considera o tamanho mínimo das regiões que serão individualizadas pelo algoritmo. Com relação à similaridade, geralmente se a diferença do valor do pixel ou a diferença do valor médio de um conjunto de pixels vizinhos for menor que o valor do limiar de similaridade, os pixels são unidos em uma só região. Estes valores permitem ao usuário controlar o resultado da segmentação de uma forma interativa, dependendo de seu objetivo e região de estudo.

Além disso, relata-se que não há um valor de limiar ideal, uma vez que este depende do tipo da imagem, da aplicação, do período em que o dado foi coletado e dos propósitos da pesquisa. De forma geral, a determinação dos limiares é atingida após vários testes entre as combinações possíveis do algoritmo. Os testes prosseguem até o momento em que o resultado da segmentação seja satisfatório para um determinado objetivo.

O valor do limiar de similaridade geralmente é fornecido manualmente pelo usuário no algoritmo de segmentação. Com efeito, se um valor muito baixo for atribuído, o processo de crescimento irá gerar regiões super-segmentadas, enquanto que segmentos representando diferentes classes serão unidos incorretamente caso seja utilizado um limiar de similaridade alto como parâmetro do segmentador. Dessa forma, tanto a escolha do limiar de similaridade quanto do limiar de área tem grande dependência da aplicação e dos dados ([BINS et al., 1996](#)).

Para aceitação ou rejeição dos limiares, os resultados da segmentação em geral são comparados visualmente com um mapa temático ou com algumas amostras de segmentos, o qual é previamente definido mediante alguma fotointerpretação. Os resultados também são geralmente comparados por meio da sobreposição da imagem segmentada com as bandas usadas para sua geração ([OLIVEIRA, 2002](#)).

2.2.2.3 *Mean-shift*

Um outro método baseado em regiões é a segmentação *mean-shift* (COMANICIU; MEER, 1997). A segmentação é feita através de uma técnica de homogenização local, na qual cada pixel é substituído pela média dos pixels em uma janela de busca, cujo valor está dentro de um intervalo de distância pré-definido. De forma geral, a técnica utiliza três entradas: uma medida de distância entre pixels, sendo usada geralmente a distância Euclidiana ou a distância de Manhattan (diferença absoluta); um raio r , de forma que todos os pixels dentro de r , medidos de acordo com a distância escolhida, sejam levados em consideração para o cálculo; e um valor de diferença, de modo que para todos os pixels dentro do raio r , apenas os pixels que apresentem valores menores ou iguais a esta diferença sejam considerados no cálculo da média.

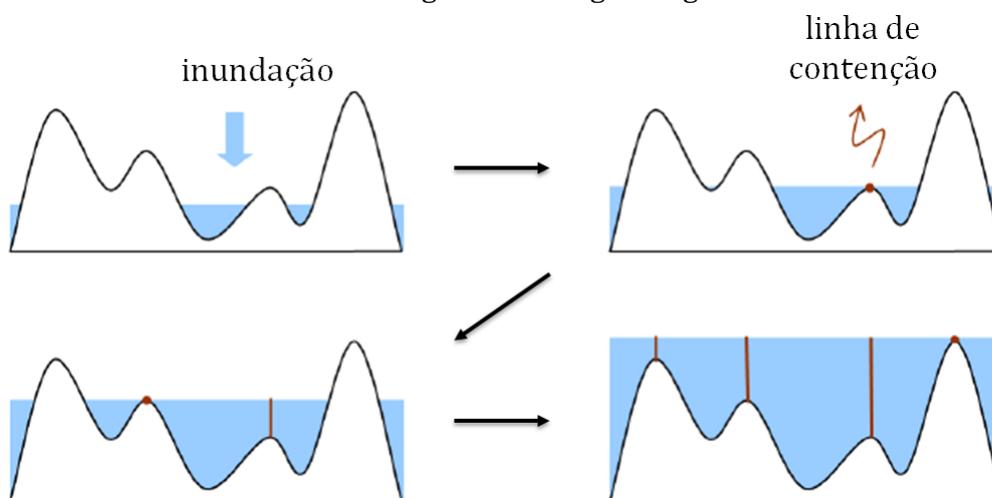
Para cada pixel analisado, é definido um raio r ao redor do pixel e calculada a média dos pixels dentro deste raio. Em seguida, o centro do raio é deslocado para a média dos valores e o algoritmo continua até convergir. Apesar de ter um custo computacional baixo e ser não supervisionado, a técnica apresenta problemas ao utilizar um alto número de dimensões, gerando regiões super-segmentadas (COMANICIU; MEER, 2002; TAO et al., 2007).

2.2.2.4 *Detecção de bacias (Watershed)*

Uma outra técnica baseada em similaridade é a segmentação por detecção de bacias (*Watershed*) (BEUCHER, 1992). O método é uma abordagem matemática morfológica que deriva de uma simulação de inundação. A imagem pode ser interpretada como uma superfície topográfica, em que os valores dos pixels equivalem a valores de altitude ou elevação dos pontos. Com isso, o conjunto de pixels da imagem forma uma superfície composta por vales e picos com diversas elevações. A Figura 2.5 ilustra a simulação de inundação realizada pelo algoritmo.

Um processo de imersão simula a inundação da superfície por meio de perfurações localizadas nas regiões mais baixas da superfície (os mínimos locais). À medida que a água penetra nessas regiões, os vales são inundados de forma gradativa, formando bacias de retenção. Quando as águas de duas bacias vizinhas entram em contato cria-se uma linha de contenção. A inundação continua até que toda a superfície esteja sob a água, de modo que exista uma linha de contenção delimitando cada bacia de retenção. Ao

Figura 2.5 - Algoritmo *Watershed*. Simulação de inundação através dos mínimos locais. O conjunto de linhas de contenção criado ao final do algoritmo define o contorno das regiões da imagem segmentada.



final da segmentação, o conjunto de linhas de contenção criado para evitar o transbordamento das águas entre as bacias define o contorno dos objetos da imagem. Apesar do baixo custo computacional, a segmentação *Watershed* tem como principal problema a super-segmentação da imagem (ROERDINK; MEIJSTER, 2000).

2.3 Segmentação e multitemporalidade

Em geral, a detecção de mudanças é uma área que tem sido amplamente estudada nos campos da estatística e reconhecimento de sinais. Contudo, a maioria das técnicas destes campos não são bem adaptadas para tratar grandes conjuntos de dados de observação da Terra com altas dimensões espaciais e temporais. O estudo das mudanças da cobertura do solo tem grande papel nos estudos da observação da Terra devido a seus impactos na análise do clima local, do balanço de radiação, da hidrologia e da biodiversidade (SONG et al., 2018).

Com o aumento do número de imagens multitemporais e de múltiplas resoluções em sensoriamento remoto, há a necessidade de explorar novos conceitos e técnicas que façam uso da dimensão temporal em suas análises (KHALI et al., 2019). Grande parte das técnicas de segmentação tem dado atenção à alta resolução espacial das imagens em comparação com os métodos para aplicações no domínio temporal e em detecção de mudanças (THOMPSON;

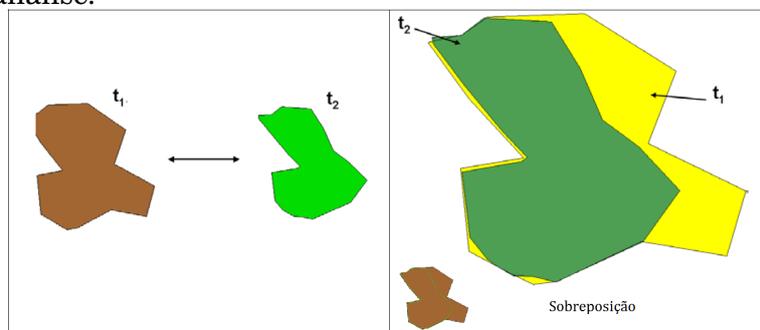
LEES, 2014). Técnicas tradicionais de mineração de dados não levam em consideração a correlação espacial e temporal presentes neste tipo de dado (BORIAH et al., 2008).

A análise de imagens que tem sido aplicada em estudos multitemporais utiliza a dimensão temporal para detectar padrões e mudanças no uso e cobertura do solo, caracterizando diferenças relativas nos objetos entre datas discretas (DEY et al., 2010; CHANT; KELLY, 2009; DURO et al., 2013; GÓMEZ et al., 2011). A maioria dos métodos propostos na literatura realiza a análise das mudanças de cobertura comparando duas imagens a partir de dois sucessivos passos de tempo (KHALI et al., 2019). Esta abordagem consiste na definição de objetos em uma primeira imagem para então compará-los sobre uma segunda imagem (BLASCHKE, 2005; PAPE; FRANKLIN, 2008; DURO et al., 2013). Pape e Franklin (2008), por exemplo, utilizaram esta estratégia identificando os objetos em uma imagem Landsat-7 ETM e comparando as diferenças temporais para estes objetos utilizando imagens MODIS. Neste caso, a análise das mudanças consistia numa simples diferença entre imagens, pela qual valores menores que um limiar eram considerados inalterados no tempo enquanto que valores acima deste limiar eram considerados modificados.

Um fator que deve ser considerado ao utilizar esta abordagem é o registro das imagens, que tem um grande impacto na análise e interpretação dos resultados. Apesar de simples, esta primeira abordagem pode ser problemática, uma vez que até mesmo erros sutis no registro dos objetos identificados na segmentação podem levar a grandes erros cumulativos (BLASCHKE, 2005). Por exemplo, na Figura 2.6 é ilustrado que pequenos erros no registro entre elas têm forte influência na análise dos objetos envolvidos. Além disso, ao segmentar imagens independentemente e comparar as regiões resultantes, existe a possibilidade de que sejam produzidas pequenas regiões secundárias indesejadas, criadas a partir da delimitação inconsistente da mesma região ao decorrer do tempo (BLASCHKE, 2005; DURO et al., 2013).

Blaschke (2010) também relata a importância de considerar a resolução espacial das imagens utilizadas para comparação dos objetos resultantes da segmentação. O tamanho da região de interesse deve ser significativamente maior que a resolução espacial da imagem para que uma região com características homogêneas entre os pixels seja detectada. Na Figura 2.7 são exibidas situações que podem ocorrer entre objetos numa imagem, ao

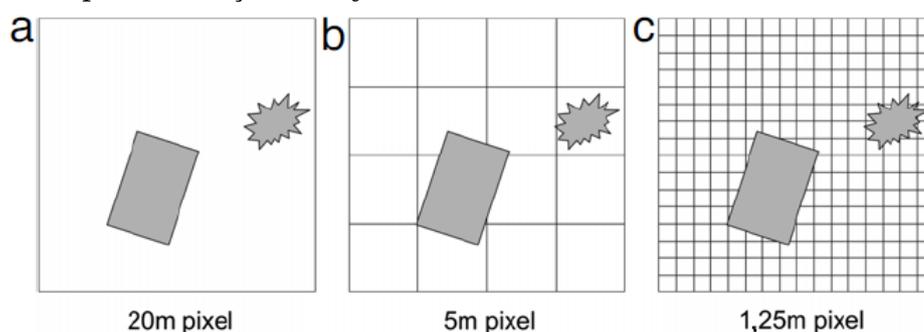
Figura 2.6 - Sobreposição de dois objetos resultantes da segmentação em imagens em tempos diferentes (t_1 e t_2), com erro de registro em uma das imagens. Caso alguma imagem apresente erro de registro, ocorrerão inconsistências na formação da região sobreposta, prejudicando a análise.



Fonte: Adaptada de Blaschke (2005).

considerar a resolução espacial das imagens adotadas para estudo.

Figura 2.7 - Objetos de interesse e a resolução espacial das imagens. Em baixa resolução (a), os pixels são maiores que os objetos, gerando regiões com mais de um alvo. Com resolução média (b), os pixels e o tamanho dos objetos podem ser da mesma ordem, podendo ser aplicadas técnicas de estratégia pontual para detectar os objetos. Em imagens de alta resolução (c), a segmentação é necessária para reunir grupos de pixels para formação de objetos.



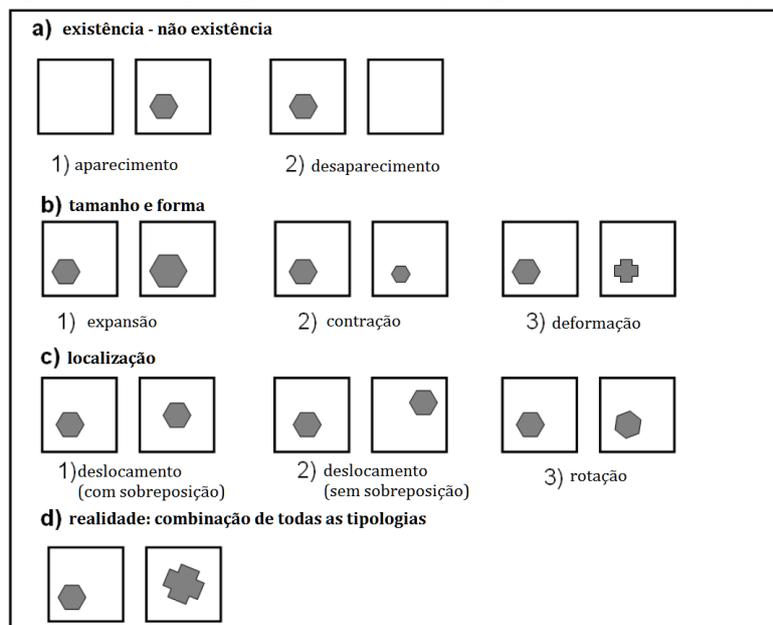
Fonte: Adaptada de Blaschke (2010).

Uma outra abordagem para tratar dados multitemporais consiste em realizar a segmentação das imagens gerando uma segmentação por instante de tempo, para depois comparar as mudanças nos objetos ao decorrer do tempo (KHALI et al., 2019; NIEMEYER et al., 2008; GÓMEZ et al., 2011; GUTTLER et al., 2017). Os trabalhos de Zhang et al. (2017) e Xiao et al. (2017), por exemplo, produziram

um resultado de segmentação através da análise sucessiva de segmentos gerados a cada passo de tempo que apresentavam alguma correspondência espacial entre eles, observando a diferença e sobreposição das mudanças geométricas dos segmentos detectados.

Já em relação ao tamanho do objeto alvo comparado à resolução do pixel, segundo Blaschke (2005), a identificação e comparação de objetos entre duas imagens de uma mesma área em um determinado período pode ser feita em dois passos: a geração dos objetos em cada uma das imagens e a comparação dos objetos resultantes. Na Figura 2.8 são ilustradas as mudanças que podem ocorrer entre objetos que devem ser levadas em consideração ao se realizar a comparação destes em duas datas diferentes.

Figura 2.8 - Tipologia das mudanças geométricas dos objetos.



Fonte: Adaptada de Blaschke (2005).

Em outros estudos, o tempo é incluído como um fator adicional dentro do processamento de segmentação, juntamente com as características espaciais e espectrais das imagens. Porém, grande parte dos trabalhos que empregam este tipo de segmentação tem utilizado um número limitado de imagens multitemporais (DESCLÉE et al., 2006; DRĂGUȚ et al., 2010; DRĂGUȚ et al., 2014) e não fazem uso de séries temporais de imagens de alta resolução temporal (DEY et al., 2010). Desclée et al. (2006), por exemplo, combinaram o

uso de segmentação multitemporal, diferença de imagens e análise de sinais multiespectrais em três imagens multiespectrais SPOT-HVR, utilizando uma imagem por ano para detectar regiões de florestas que sofreram alguma mudança. Para cada um dos 3 anos, foram utilizadas as bandas verde, vermelho e infravermelho próximo. Utilizando o algoritmo implementado por [Baatz e Schäpe \(2000\)](#), os autores definiram os objetos em uma única operação a partir de 9 bandas formadas a partir do empilhamento das bandas de cada uma das 3 imagens.

Vale ressaltar que a maioria das análises baseada em objetos realiza inferências sobre a natureza das mudanças após o processamento das imagens. Ou seja, o entendimento das mudanças dos fenômenos é inferido através da quantificação do número e da magnitude das diferenças observadas nos objetos após a mudança. No entanto, uma caracterização direta das mudanças de um fenômeno necessita que as observações sejam feitas durante o processo da mudança ([THOMPSON; LEES, 2014](#)), o que pode ser explorado por meio de imagens de alta resolução temporal.

A detecção de mudanças baseadas em séries temporais apresenta vantagens se comparada com a observação pura de sequências de imagens, uma vez que as séries levam em consideração informações sobre a dinâmica temporal e as mudanças na paisagem, em vez de apenas observar a diferença entre duas ou mais imagens coletadas em datas diferentes ([BORIAH,](#)). O uso de imagens multitemporais possibilita descrever a evolução da cobertura da vegetação no decorrer do tempo. A interpretação destas evoluções permite que a dinâmica da cobertura do solo em diferentes escalas seja caracterizada, sejam elas mudanças repentinas ou até diferenças mais sutis na dinâmica anual/sazonal da cobertura da vegetação ([BONTEMPS et al., 2008](#); [LAMBIN; LINDERMAN, 2006](#)).

O algoritmo proposto neste trabalho é baseado em séries temporais de imagens ópticas de sensoriamento de alta resolução temporal. O domínio temporal é considerado dentro do processamento de segmentação, em vez de utilizar interseções de objetos derivados de segmentações independentes para cada passo de tempo ou alguma técnica de pós-processamento para analisar as propriedades temporais da imagem. Uma descrição de séries temporais de satélite e do critério de homogeneidade utilizado no algoritmo proposto estão descritos a seguir.

3 SÉRIES TEMPORAIS DE IMAGENS DE SATÉLITES

O método de segmentação proposto nesta tese baseia-se no uso de séries temporais para criação das partições. Antes de detalhá-lo, será apresentada uma descrição sobre séries temporais de imagens de satélites. A técnica *Dynamic Time Warping*, usada como medida de similaridade entre duas séries temporais, e utilizada no método proposto, é descrita na Seção 3.2.

Vários pesquisadores têm estudado as mudanças do uso e cobertura do solo nos diferentes biomas, e o processamento e a análise de imagens de satélites têm papel fundamental na detecção destas mudanças (BORIAH,). O extenso montante de dados de sensoriamento remoto, combinado com informações dos modelos de ecossistema, oferecem uma boa oportunidade para predição e entendimento do comportamento dos ecossistemas terrestres.

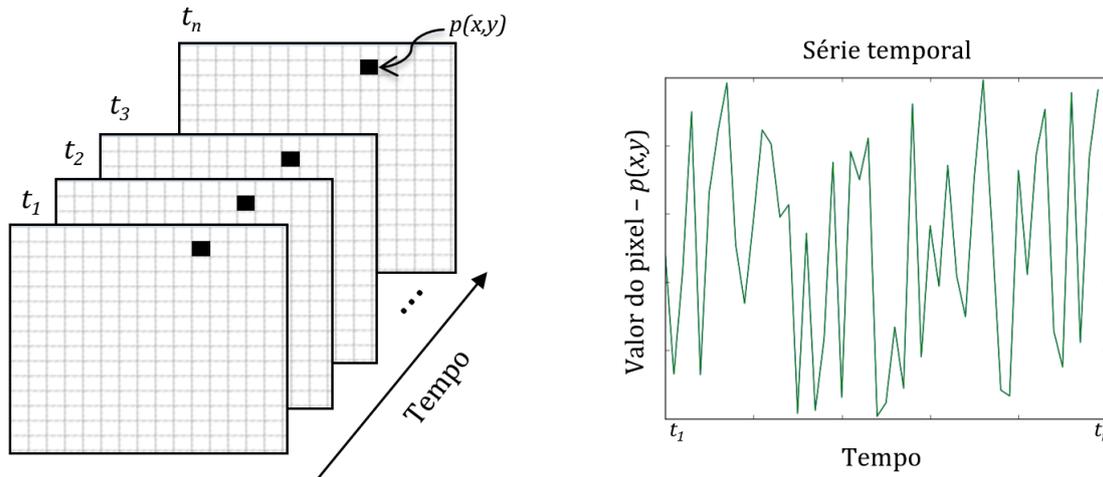
Com isso, a detecção de mudanças baseadas em séries temporais apresenta vantagens se comparada com a observação pura de sequências de imagens, uma vez que as séries levam em consideração informações sobre a dinâmica temporal e as mudanças na paisagem, em vez de apenas observar a diferença entre duas ou mais imagens coletadas em datas diferentes (BORIAH et al., 2008).

Os satélites de observação da Terra apresentam uma aquisição repetitiva de dados, fornecendo um conjunto contínuo e consistente de informações acerca do uso e cobertura do solo de todo o planeta (LAMBIN; LINDERMAN, 2006). Como os satélites revisitam um mesmo lugar periodicamente, as imagens obtidas podem ser calibradas de forma que uma determinada localização possa ser comparada em tempos diferentes. Com isso, séries temporais podem, por exemplo, ser extraídas a partir de imagens de satélites para análise de detecção de mudanças.

Uma série temporal pode ser definida como qualquer conjunto de observações ordenadas no tempo em intervalos regulares. Ao observar uma série temporal procura-se pesquisar o mecanismo gerador da série e buscar periodicidades relevantes nos dados. Além disso, pode-se traçar o seu comportamento, verificando características mais relevantes e suas possíveis relações com outras séries ou até realizar previsões de curto prazo que possam ser estimadas a partir de dados já existentes e de outras séries relacionadas (MORETTIN; TOLOI, 2006). Na Figura 3.1 é ilustrada a criação de uma série

temporal de imagens de satélites para uma dada localização do pixel (x, y) numa sequência de imagens adquiridas em datas diferentes, t_1, \dots, t_n . Para cada localização do pixel nas coordenadas (x, y) , pode-se observar uma série temporal que representa a variação do valor $p(x, y)$ no decorrer do tempo.

Figura 3.1 - Exemplo de uma série temporal para o pixel $p(x, y)$.



Dados de sensoriamento remoto têm se tornado a principal fonte para aplicação de detecção de mudanças e observação do uso e cobertura do solo. Dentre as diversas fontes de dados existentes, séries temporais de imagens de sensoriamento remoto têm grande importância no estudo dos fenômenos dinâmicos e na interpretação de suas evoluções no decorrer do tempo (BOULILA et al., 2011). Sensores como o AVHRR (*Advanced Very High Resolution Radiometer*) a bordo do satélite NOAA (*National Oceanic and Atmospheric Administration*); o Vegetation a bordo do SPOT (*Satellite Pour l'Observation de la Terre*); e o MODIS (*Moderate Resolution Imaging Spectroradiometer*), a bordo dos satélites Terra (EOS-AM1) e Aqua (EOS-PM1) têm sido responsáveis pela construção de grandes conjuntos de dados de séries temporais. Estes sensores adquirem imagens em um intervalo quase diário, característica importante para que possam observar mudanças no uso e cobertura do solo. Contudo, um grande montante de dados de séries temporais têm sido gerado ao longo dos últimos anos, o que força a comunidade de sensoriamento remoto a repensar estratégias de processamento para análise e visualização de séries temporais a partir de imagens de satélites (FREITAS et al., 2011).

Produtos extraídos a partir do sensor MODIS e do programa Landsat representam dois dos conjuntos de dados mais utilizados para gerar séries temporais em estudos de detecção de mudanças (GÓMEZ et al., 2016). Os satélites do programa Landsat adquirem imagens desde 1972 (COHEN; GOWARD, 2004). Atualmente, os sensores Landsat-7 e Landsat-8 estão ativos, gerando imagens com resolução temporal de 16 dias e resolução espacial de 30 m. O sensor MODIS consegue fornecer imagens com intervalos diários, embora a resolução espacial de seus produtos varie de 250 m a 1 km.

Dentre os vários estudos que envolvem análise de detecção de mudanças, pesquisas com séries temporais de imagens ópticas de satélite têm sido utilizadas, por exemplo, para caracterização das mudanças do uso do solo (ZHU; WOODCOCK, 2014), identificação da natureza das mudanças (OLTHOF; FRASER, 2014), detecção de mudanças nas componentes de tendência e sazonalidade das séries (LUNETTA et al., 2006; VERBESSELT et al., 2010; VERBESSELT et al., 2012), detecção de degradação de florestas (SHIMABUKURO et al., 2014), e classificação de culturas agrícolas (XIAO et al., 2005; WARDLOW et al., 2007; PETITJEAN et al., 2012; PETITJEAN; WEBER, 2014).

É importante salientar que algumas condições devem ser satisfeitas antes de utilizar alguma técnica de detecção de mudanças baseada em séries temporais. Segundo Lu et al. (2004), é necessário que o registro e a calibração atmosférica e radiométrica sejam precisos, e que seja feita a seleção de imagens do mesmo sensor, com a mesma resolução radiométrica e espacial em datas próximas, a fim de eliminar os efeitos de fontes externas, tais como diferenças na fenologia e na geometria de aquisição de dados. Além disso, é fundamental que fatores que ocasionem ruídos também sejam levados em consideração, a exemplo de falhas nos dados e cobertura de nuvens.

3.1 Análise da cobertura vegetal

Na análise e caracterização da cobertura vegetal, por exemplo, utilizam-se índices de vegetação para o monitoramento sazonal e interanual dos parâmetros biofísicos, fenológicos e estruturais da vegetação (HUETE et al., 2002), a partir dos quais séries temporais podem ser geradas e empregadas nos estudos. Segundo Tucker et al. (2005), os índices de vegetação representam medidas das condições espaciais, espectrais e radiométricas da vegetação. Os índices estão altamente correlacionados com a concentração de biomassa, a quantidade de clorofila e a absorção de energia da vegetação.

Os índices de vegetação produzidos através dos dados do sensor MODIS mais utilizados são o NDVI (*Normalized Difference Vegetation Index*) e o EVI (*Enhanced Vegetation Index*) (JUSTICE et al., 2002). O cálculo do NDVI baseia-se nas reflectâncias dos comprimentos de onda infravermelho próximo e vermelho (TUCKER, 1979):

$$\text{NDVI} = \frac{\rho_{NIR} - \rho_{red}}{\rho_{NIR} + \rho_{red}}, \quad (3.1)$$

onde ρ_{NIR} e ρ_{red} são as reflectâncias nas bandas do infravermelho próximo e do vermelho, respectivamente. Segundo Huete et al. (2002), a razão entre as bandas no cálculo do NDVI reduz algumas formas de ruído (diferenças de iluminação, sombras de nuvens e variações topográficas). Contudo, este índice possui baixa sensibilidade em regiões com alta concentração de biomassa e pode apresentar limitações relacionadas às variações do brilho do solo (JIANG et al., 2008).

O índice EVI, ao contrário do NDVI, apresenta sensibilidade em áreas com maior quantidade de biomassa verde, além de minimizar os efeitos das influências atmosféricas e do solo (JIANG et al., 2008). Utilizando três comprimentos de onda, o cálculo do EVI é definido por:

$$\text{EVI} = G \frac{\rho_{NIR} - \rho_{red}}{\rho_{NIR} + C_1 \times \rho_{red} - C_2 \times \rho_{blue} + L}, \quad (3.2)$$

onde G equivale a um fator de ganho, L corresponde ao fator de ajuste do solo, C_1 e C_2 são os coeficientes da resistência de aerossóis, que usam a reflectância na banda do azul (ρ_{blue}) para corrigir a influência dos aerossóis na banda do vermelho. No MODIS, os coeficientes geralmente utilizados para o cálculo do EVI são $G = 2,5$, $L = 1$, $C_1 = 6$ e $C_2 = 7,5$ (JIANG et al., 2008).

Para obter um índice com comportamento similar ao EVI, com a prerrogativa de não utilizar a banda azul, Jiang et al. (2008) propuseram o EVI2 (*Enhanced Vegetation Index 2*), sugerindo não só uma melhora na sensibilidade sob condições de elevada concentração de biomassa, assim como uma minimização da influência do solo. O índice é calculado utilizando a reflectância nas bandas do infravermelho próximo e do vermelho:

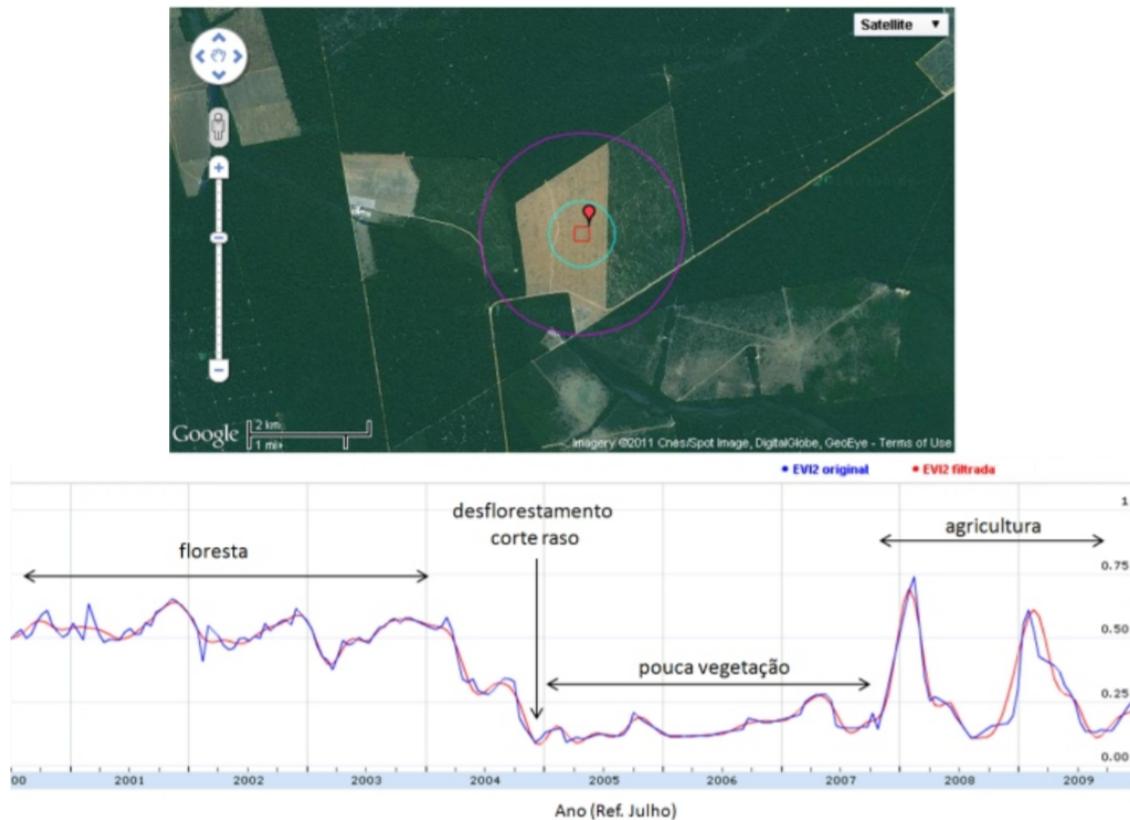
$$\text{EVI2} = 2,5 \frac{\rho_{NIR} - \rho_{red}}{\rho_{NIR} + 2,4 \times \rho_{red} + 1}. \quad (3.3)$$

Os índices de vegetação utilizados para a geração de séries temporais de imagens de satélite podem estar sujeitos à interferência de diversos ruídos. Este problema pode estar relacionado com a presença de nuvens, geometria de visada, falhas do detector, entre outros (HIRD; MCDERMID, 2009). Vários algoritmos de filtragem, a exemplo de filtros *wavelet*, de Savitzky-Golay e de Whittaker, têm sido testados e desenvolvidos para eliminar ou reduzir este problema (VUOLO et al., 2012). Todavia, é importante ressaltar que apesar de reduzir a interferência de ruídos e preencher lacunas na série temporal, a maioria dos algoritmos de filtragem podem alterar valores de pixels com informação útil que não sofreram influência de ruídos (ERASMI et al., 2006).

As séries temporais extraídas de índices de vegetação podem ser utilizadas para análise de sazonalidades para o monitoramento da cobertura vegetal. Na Figura 3.2, por exemplo, são ilustradas duas versões (original e com filtro *wavelet*) da mesma série temporal do valor do índice de vegetação EVI2 referente ao pixel em vermelho destacado na imagem.

Nota-se que a área apresentava cobertura florestal até o ano de 2004, quando começou a ser desmatada. Entre os anos de 2005 e 2007, quase nenhuma rebrota da vegetação ocorreu como indicado pelo baixo perfil de EVI2 neste período. No final dos anos 2007 e 2008, uma resposta espectral típica para culturas agrícolas pode ser observada pelo comportamento padrão de subida e descida dos valores do índice, devido ao crescimento, maturação, senescência e colheita da cultura.

Figura 3.2 - Séries temporais do índice EVI2 (original e filtrado) para o pixel selecionado na imagem (em vermelho).



Fonte: Adaptada de Freitas et al. (2011).

3.2 *Dynamic Time Warping*

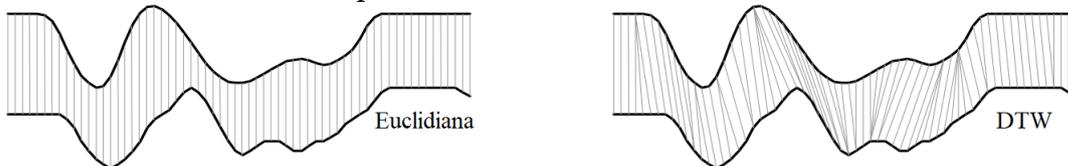
Ao estudar a detecção de mudanças em imagens de satélites no decorrer do tempo, o principal processo de análise consiste em comparar os dados com o intuito de estimar a similaridade entre eles. Em muitos casos, a medida de distância é utilizada como ferramenta de estimação da similaridade. Na análise dos resultados que envolvem dados temporais, a escolha da medida de distância tem papel fundamental, uma vez que ela define o modo de tratar a temporalidade dos dados (PETITJEAN et al., 2011).

O problema de reconhecer padrões em dados multitemporais é uma tarefa difícil. Uma vez detectados os padrões, podem ser estabelecidas relações que podem auxiliar no entendimento do comportamento dos dados (BERNDT; CLIFFORD, 1994). Dentre as medidas de distâncias conhecidas que podem

ser utilizadas para este fim, existe a chamada *Dynamic Time Warping* (DTW) é uma das mais utilizadas na comparação de séries temporais. O conceito de DTW foi introduzido por Sakoe e Chiba (1971) e Sakoe e Chiba (1978), sendo originalmente concebido para tratar problemas de reconhecimento automático de fala. A medida retorna um valor que corresponde ao alinhamento global ótimo entre duas séries temporais e é uma das mais utilizadas para quantificar a similaridade entre duas séries (não necessariamente do mesmo tamanho) (PETITJEAN et al., 2012; RATANAMAHATANA; KEOGH, 2004; WEBER et al., 2012).

Com a possibilidade de realinhar uma série com outra, de forma que cada elemento da primeira série esteja associado com, no mínimo, um elemento da segunda, a medida DTW é capaz de ressaltar similaridades que a distância Euclidiana não captura (PETITJEAN et al., 2011), conforme ilustrado na Figura 3.3. De acordo com Petitjean et al. (2012), a distância Euclidiana não é relevante na análise de séries temporais, uma vez que não leva em consideração a temporalidade dos dados, não conseguindo capturar similaridades flexíveis entre duas séries temporais. Por outro lado, o algoritmo DTW permite que duas séries temporais similares mas que estão fora de fase possam ser alinhadas de uma maneira não linear (RATANAMAHATANA; KEOGH, 2004; KEOGH; RATANAMAHATANA, 2005).

Figura 3.3 - Apesar de as duas séries apresentarem formas similares, elas não estão alinhadas com relação ao eixo do tempo. Neste caso, a medida DTW permite o cálculo de uma distância mais intuitiva a partir do alinhamento dinâmico em relação ao tempo, gerando uma resposta melhor se comparada à distância Euclidiana.



Fonte: Adaptada de Chu et al. (2002).

O algoritmo clássico de DTW utiliza programação dinâmica para encontrar o alinhamento entre as duas séries. A programação dinâmica, também conhecida como *Dividir e Conquistar*, é uma abordagem que divide um problema grande em problemas menores. Os resultados destes problemas

são calculados e em seguida agregados à solução atual. DTW apresenta uma abordagem *bottom up*, em que o resultado do subproblema é utilizado para resolver um dado problema progressivamente (GULZAR, 2015).

Sejam duas séries temporais A e B , onde $A = (a_1, a_2, \dots, a_n)$ e $B = (b_1, b_2, \dots, b_m)$. O primeiro passo para o cálculo da medida DTW entre duas séries é construir uma matriz Δ , de tamanho $n \times m$, onde cada elemento (i, j) da matriz corresponde a uma distância medida entre a_i e b_j . Essa distância, $\delta(a_i, b_j)$, pode ser calculada utilizando diferentes métricas, como a diferença absoluta $d(a_i, b_j) = |a_i - b_j|$, ou a distância Euclidiana.

Com os valores de δ calculados para cada par de pontos das séries A e B , constrói-se, a seguir, uma matriz D de distâncias acumuladas, também de tamanho $n \times m$. O primeiro elemento da matriz, $D(a_1, b_1)$, é preenchido com a distância $\delta(a_1, b_1)$. Em seguida, os elementos restantes da primeira linha (Equação 3.4) e da primeira coluna (Equação 3.5) da matriz D são calculados por meio das fórmulas:

$$D(a_1, b_j) = \delta(a_1, b_j) + D(a_1, b_{j-1}), \quad (3.4)$$

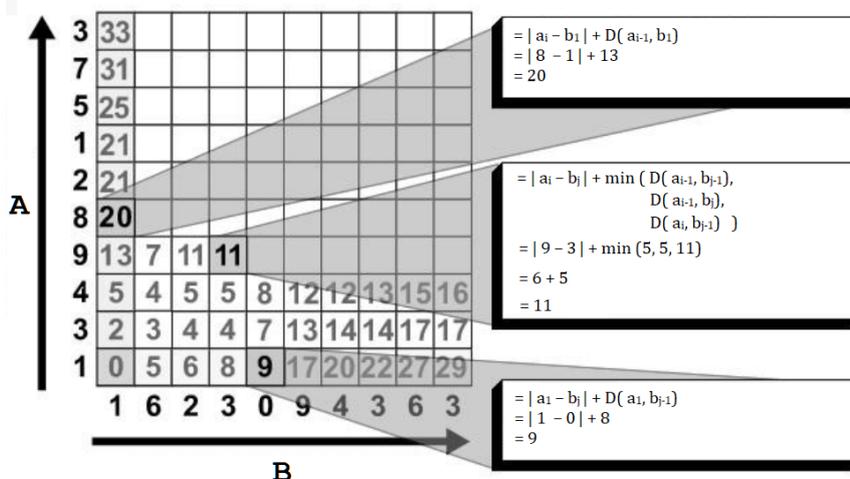
$$D(a_i, b_1) = \delta(a_i, b_1) + D(a_{i-1}, b_1), \quad (3.5)$$

Com a primeira linha e a primeira coluna preenchidas, calculam-se os valores dos elementos restantes da matriz D da esquerda para a direita e de baixo para cima, de modo que se soma o valor da distância δ dos elementos daquela posição de cada série com o menor valor dentre os elementos adjacentes anteriores à esquerda, abaixo e à diagonal (Equação 3.6). A Figura 3.4 ilustra um exemplo de preenchimento da matriz para o cálculo do DTW.

$$D(a_i, b_j) = \delta(a_i, b_j) + \min \begin{cases} D(a_{i-1}, b_{j-1}) \\ D(a_i, b_{j-1}) \\ D(a_{i-1}, b_j) \end{cases} . \quad (3.6)$$

Uma vez que a matriz esteja completamente preenchida, o seu último elemento, $D(a_n, b_m)$, contém o valor do melhor alinhamento entre as duas séries. Além disso, a matriz D pode ser utilizada para encontrar o melhor caminho entre os valores inicial e final da matriz que resulta no valor de

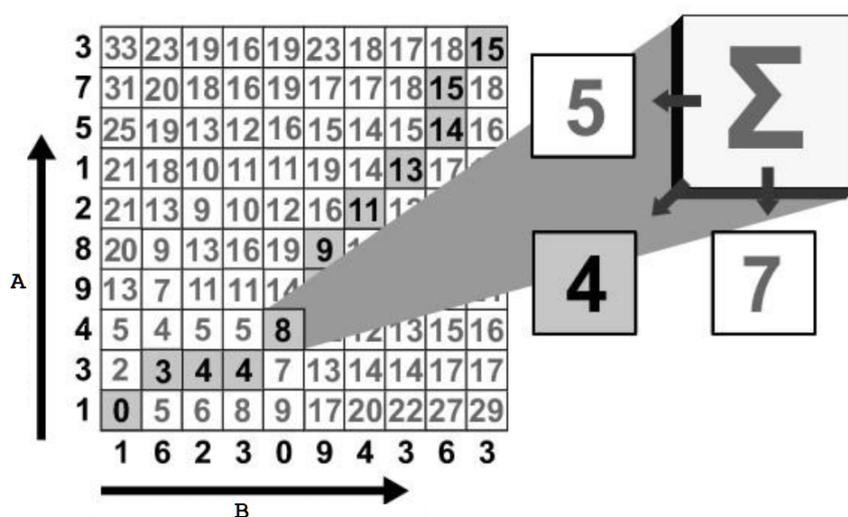
Figura 3.4 - Exemplo de preenchimento da matriz de distâncias acumuladas. A diferença absoluta foi utilizada como medida δ .



Fonte: Adaptada de Souza et al. (2009).

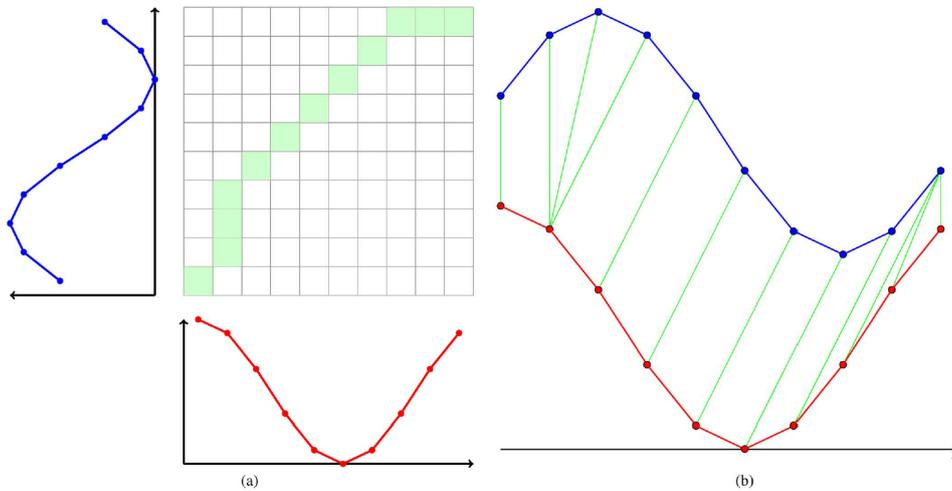
alinhamento ótimo. Para isso, a busca pelo caminho inicia-se a partir de $D(a_n, b_m)$ (elemento superior direito), adicionando sempre a célula da matriz com o menor valor dentre os elementos adjacentes à esquerda, abaixo e à diagonal, conforme ilustrado na Figura 3.5. O algoritmo acumula estes valores até alcançar o elemento inferior esquerdo ($D(a_1, b_1)$). O caminho ótimo entre duas séries e seu respectivo alinhamento estão ilustrados na Figura 3.6.

Figura 3.5 - Exemplo do funcionamento do cálculo para obtenção do melhor caminho.



Fonte: Adaptada de Souza et al. (2009).

Figura 3.6 - Alinhamento de duas séries (azul e vermelho) por meio da DTW. (a) definição do caminho ótimo (em verde). (b) O alinhamento resultante (em verde).

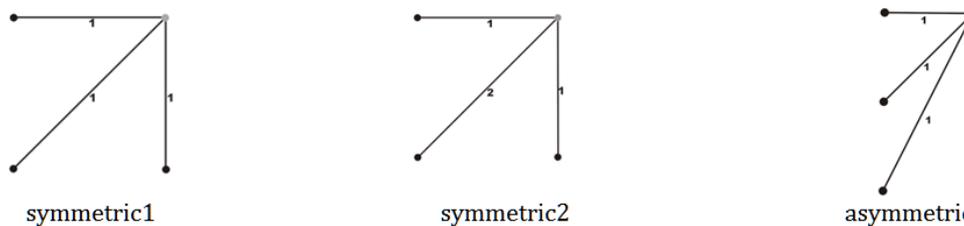


Fonte: Petitjean et al. (2012).

Algumas modificações no algoritmo clássico podem ser feitas para determinar a contribuição das células adjacentes para o próximo valor da matriz a ser calculado. Denominadas restrições locais, estas alterações definem o valor de $D(a_i, b_j)$ que será calculado progressivamente por todas as células da matriz através da programação dinâmica. A restrição local define quais células adjacentes que serão analisadas e o peso que cada uma possui (GULZAR, 2015). Na Figura 3.7 são exibidas as restrições locais mais utilizadas, chamadas *symmetric1*, *symmetric2* e *asymmetric*, sendo a medida *symmetric2* a restrição mais usada. De acordo com Gulzar (2015), a seleção da restrição local não é óbvia e depende do tipo de aplicação em que a medida DTW será aplicada.

O caminho para obtenção do alinhamento ótimo global retornado pela DTW deve satisfazer três condições, mesmo se alguma alteração for feito no algoritmo clássico: limite, monotonicidade e continuidade (MÜLLER, 2007). A condição de limite impõe que o caminho ótimo deve começar e terminar em células diagonais de cantos opostos na matriz. Já a condição de monotonicidade define que os pontos no melhor caminho devem ser monotonicamente espaçados no tempo, ou seja, o caminho percorrido pelo alinhamento nunca poderá voltar sobre si mesmo. Por último, a condição de continuidade determina que o caminho deve avançar entre células adjacentes, incluindo células diagonalmente adjacentes. A violação das três condições é exemplificada na Figura 3.8.

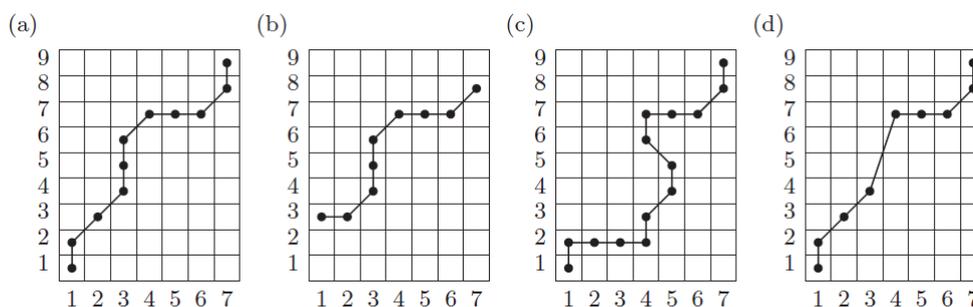
Figura 3.7 - Detalhe das restrições locais comumente utilizadas.



$$D(a_i, b_j) = \delta(a_i, b_j) + \min \begin{cases} D(a_{i-1}, b_{j-1}) \\ D(a_i, b_{j-1}) \\ D(a_{i-1}, b_j) \end{cases} \quad D(a_i, b_j) = \min \begin{cases} D(a_{i-1}, b_{j-1}) + 2 \times \delta(a_i, b_j) \\ D(a_i, b_{j-1}) + \delta(a_i, b_j) \\ D(a_{i-1}, b_j) + \delta(a_i, b_j) \end{cases} \quad D(a_i, b_j) = \delta(a_i, b_j) + \min \begin{cases} D(a_i, b_{j-1}) \\ D(a_{i-1}, b_{j-1}) \\ D(a_{i-2}, b_{j-1}) \end{cases}$$

Fonte: Adaptada de [Gulzar \(2015\)](#).

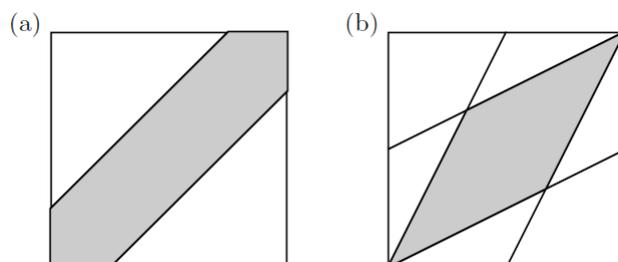
Figura 3.8 - Ilustração de caminhos para um par de séries de tamanhos 9 e 7, respectivamente. (a) Caminho que satisfaz as três condições impostas. (b) A condição de limite é violada. (c) A condição de monotonicidade é violada. (d) A condição de continuidade é violada.



Fonte: [Müller \(2007\)](#).

Além das condições e restrições locais supracitadas, existem restrições globais que podem ser empregadas no algoritmo com o objetivo de diminuir o custo computacional, visto que o algoritmo tem complexidade quadrática $\theta(n \times m)$. Tais restrições definem uma região do espaço a partir da qual a busca do caminho ótimo será realizada, prevenindo que o caminho afaste-se da diagonal da matriz. O caminho ótimo, por exemplo, pode ser limitado a uma certa largura ao redor da diagonal da matriz, denominada de banda Sakoe-Chiba ([SAKOE; CHIBA, 1978](#)). Outra restrição corresponde à janela de busca denominada paralelogramo de Itakura ([ITAKURA, 1975](#)), a qual permite maiores distorções entre o meio da matriz do que nas extremidades. Ilustrações das duas janelas de busca estão expostas na Figura 3.9.

Figura 3.9 - Restrições globais para busca do caminho ótimo. Apenas a área em cinza é considerada em cada caso. (a) Banda de Sakoe-Chiba. (b) Paralelogramo de Itakura.



Fonte: Adaptada de Müller (2007).

A medida DTW tem sido alvo de estudos para análise de séries temporais de imagens de satélites. Estudos como os de Petitjean et al. (2011), Petitjean et al. (2012) e Petitjean e Weber (2014) utilizaram a medida DTW para classificação de séries temporais de imagens do sensor FORMOSAT-2. A medida foi utilizada com o intuito de tratar problemas relacionados à amostras irregulares com cobertura de nuvens nas imagens. Nestes estudos, a medida DTW compara duas séries que apresentam tamanhos similares, com a ressalva de que o primeiro e o último ponto de ambas as séries estivessem alinhados. Os resultados mostraram que foi possível tratar a cobertura de nuvens por meio da medida DTW sem a necessidade de eliminar as imagens que apresentavam esta característica. Segundo os autores, a medida de similaridade DTW permitiu capturar distorções temporais ou irregularidades entre duas séries que representam a mesma classe de evolução, uma vez que foi possível comparar séries radiométricas com tamanhos similares.

Estudos recentes, como os de Maus et al. (2015), Maus (2016) e Maus et al. (2016), utilizaram a distância DTW para classificar séries temporais de imagens MODIS. O método de classificação proposto requer um conjunto de padrões temporais para cada classe de uso. Como as séries temporais utilizadas como padrões têm um tamanho muito menor do que a série temporal do sensor, os autores utilizaram uma modificação da distância DTW, chamada de Subsequência DTW, ou de OBDTW (*Open Boundary Dynamic Time Warping*), descrita em (MÜLLER, 2007). A medida OBDTW faz a busca de uma subsequência da série mais longa que tenha o melhor alinhamento com a série mais curta. Devido a esta diferença de tamanho entre as séries, a técnica OBDTW desconsidera a dimensão temporal e pode ocasionar alinhamentos de

fases inconsistentes, podendo alinhar padrões de períodos distantes.

Para evitar estas inconsistências temporais, os autores introduziram um custo na matriz Δ , baseado na data de cada pixel da imagem de satélite. Esta variação do OBDTW, chamada TWDTW (*Time-Weighted Dynamic Time Warping*), adiciona um custo temporal ω na matriz Δ , cujos elementos são então calculados como $\Delta_{i,j} = \delta(a_i, b_j) + \omega_{i,j}$. Para calcular o custo temporal, foram propostos um modelo linear e um modelo logístico. O modelo linear é calculado pela Equação 3.7:

$$\omega_{i,j} = g(t_i, t_j), \quad (3.7)$$

onde g é a diferença absoluta em dias entre as datas t_i e t_j dos pontos a_i e b_j das séries temporais. O modelo logístico é dado pela Equação 3.8.

$$\omega_{i,j} = \frac{1}{1 + e^{-\alpha(g(t_i, t_j) - \beta)}}, \quad (3.8)$$

onde α corresponde ao valor de declividade e β é o valor do ponto médio da curva sigmoide. A partir da definição desse conjunto de séries temporais padrões, um intervalo da série temporal do sensor MODIS é comparado com cada série temporal padrão por meio da DTW. O padrão que apresenta o menor valor da distância DTW é associado como a classe de uso e cobertura do solo para este intervalo da série temporal. Maus (2016) obteve os melhores resultados utilizando o modelo logístico com $\alpha = 0,1$ e $\beta = 100$.

De forma geral, os trabalhos que fizeram uso da medida DTW em imagens de satélites tinham o objetivo de aplicar a medida na etapa de *classificação* de imagens. O trabalho aqui proposto tem o intuito de utilizar a medida antes da etapa de *classificação*. Para isso, a medida DTW foi utilizada como critério de homogeneidade dentro do processo de *segmentação*. Cada segmento resultante da técnica corresponde a uma região com propriedades homogêneas durante o período de tempo analisado, conforme está exposto no Capítulo 4.

4 METODOLOGIA

Este trabalho tem como objetivo o desenvolvimento de um algoritmo de segmentação espaço-temporal que realiza a detecção de regiões homogêneas no espaço e no tempo. O algoritmo utiliza como entrada uma sequência de imagens ópticas de sensoriamento remoto de um determinado local durante um período de tempo.

A técnica proposta tem a finalidade de superar as limitações do modelo de segmentação clássico (HARALICK; SHAPIRO, 1985), no qual cada imagem é segmentada individualmente, de modo que cada passo temporal é feito de forma independente. Baseado nos conceitos clássicos de segmentação (Capítulo 2) e na análise e detecção de mudanças (Capítulo 2.3), com uso de séries temporais (Capítulo 3), o algoritmo é uma adaptação da técnica de segmentação baseada em crescimento de regiões (ADAMS; BISCHOF, 1994), com o intuito de aprimorar o critério de homogeneidade da segmentação de modo a considerar, além das propriedades espaciais e espectrais, o domínio temporal.

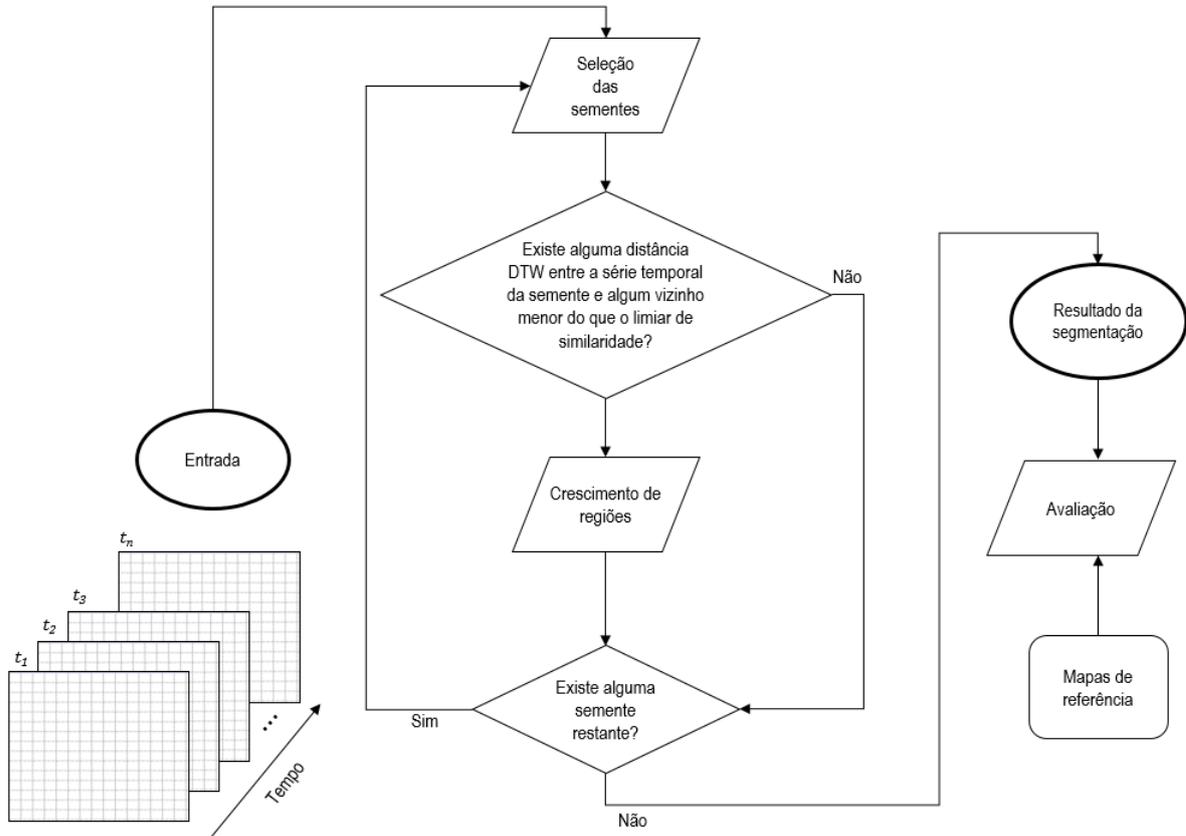
Para isso, séries temporais são extraídas de uma sequência de imagens de um mesmo local durante um determinado período de tempo. Cada série corresponde aos valores de um pixel ao longo do tempo. As séries temporais então são comparadas através da medida de distância DTW e, a partir desta etapa, é feito o crescimento de regiões observando os valores da distância DTW entre as sementes e as suas vizinhanças. A criação e análise da segmentação espaço-temporal está ilustrada na Figura 4.1.

4.1 Dados de entrada

Uma sequência de imagens de sensoriamento remoto de um mesmo local no decorrer do tempo é utilizada como entrada do algoritmo. Os exemplos e estudos de caso tratados neste trabalho utilizaram sequências de imagens MODIS, Landsat-7 e Landsat-8 OLI. Todas as imagens contidas nas séries temporais devem apresentar a mesma dimensão.

Além disso, para cada imagem, cada pixel corresponde a um índice de vegetação, de modo que cada coordenada (x, y) com mesma referência espacial possui um valor no tempo, sendo considerada uma série temporal independente por coordenada (pixel). Na Figura 4.2, são ilustrados dois exemplos de sequências de imagens (MODIS e Landsat-8) que podem ser

Figura 4.1 - Fluxograma da metodologia proposta. O algoritmo utiliza uma sequência de imagens de um mesmo local como entrada, seleciona as sementes e faz o crescimento de regiões com base na comparação da distância DTW da semente e seus vizinhos. O resultado final é obtido e comparado com mapas de referência para obtenção de índices de qualidade.



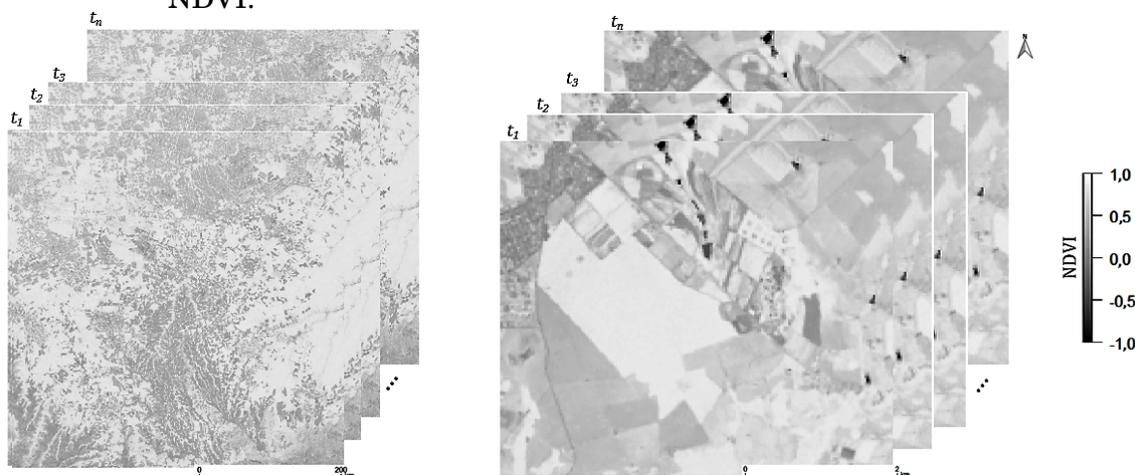
utilizados como dados de entrada do algoritmo.

É importante salientar os estudos de casos apresentados neste trabalho têm como foco aplicações na área de vegetação, observados segmentos em imagens que contêm pixels que representam cobertura de florestas, pastagens e culturas agrícolas. Por este motivo, foram utilizados índices de vegetação como valores das séries temporais. Contudo, a metodologia apresenta uma solução geral, podendo ser utilizada em outros tipos de aplicações.

4.2 Segmentador espaço-temporal

A partir da seleção da sequência de imagens como dado de entrada, são extraídas as séries temporais que serão utilizadas pelo segmentador espaço-

Figura 4.2 - Exemplos de seqüências de imagens MODIS (à esquerda) e Landsat-8 (à direita) que podem ser utilizadas como dados de entrada do algoritmo. Neste exemplo, cada pixel corresponde a um valor do índice de vegetação NDVI.



temporal. As séries temporais são utilizadas no cálculo da distância DTW entre a série temporal da semente e as séries temporais de sua vizinhança. O usuário determina o tamanho e a periodicidade das séries temporais a partir dos dados de entrada. Para cada rodada do algoritmo, o segmentador requer a definição de parâmetros: os limiares de similaridade (T) e área (A). De forma geral, a técnica de segmentação é expressa pelos seguintes passos:

- a) Definir o conjunto de sementes. Por padrão, a técnica define a localização das sementes de forma randômica. Contudo, dependendo da aplicação, há a possibilidade de definir as localizações e a quantidade de sementes.
- b) Calcular a distância DTW entre as séries temporais da semente e dos seus vizinhos. Se a diferença absoluta entre o valor do DTW da série temporal da semente e da série temporal for menor que o limiar de similaridade (T), a série temporal vizinha é considerada similar e o pixel vizinho à localização da semente é considerado integrante da mesma região da semente. Vale ressaltar que não há atualização do valor de T após este passo.
- c) Continuar examinando todos os vizinhos com a série temporal da semente até que nenhum vizinho similar seja encontrado.

- d) Rotular o segmento obtido como um região completa.
- e) Repetir o processo com a próxima semente não rotulada até que todos os pixels da imagem estejam rotulados.
- f) Eliminar as regiões que apresentam a área menor que o limiar de área (A). Estes segmentos são agregados ao segmento adjacente que contém a maior borda.

Após este processamento, o algoritmo retorna duas saídas: uma imagem em que cada pixel corresponde ao valor do rótulo atribuído pelo segmentador; e o arquivo vetorial (*shapefile*) resultante desta imagem. Todo o algoritmo foi escrito usando a linguagem R. Os segmentos gerados como saída da técnica representam regiões que apresentaram propriedades homogêneas durante o período de tempo analisado.

4.3 Avaliação de resultados da segmentação

Segundo Baatz e Schäpe (2000), nenhum resultado de segmentação, mesmo provado quantitativamente, irá convencer, se este não satisfizer a percepção do olho humano. De acordo com Nikhil e Sankar (1993), a segmentação é essencialmente um problema de percepção psicofísica e, portanto, não susceptível de uma solução puramente analítica. Além disso, qualquer algoritmo de segmentação deve ser complementado com informações semânticas e conhecimento prévio sobre as imagens processadas, não importando o modelo matemático adotado (YONG et al., 2004).

Neste trabalho, a determinação dos limiares foi atingida empiricamente por meio de comparação visual. Para aceitação ou rejeição dos limiares, os resultados da segmentação foram comparados visualmente por meio da sobreposição dos segmentos resultantes com uma imagem do mesmo local durante o período analisado. Os testes prosseguiram até o momento em que o resultado da segmentação foi satisfatório para cada estudo de caso, de forma que os limiares escolhidos não geraram uma imagem super ou sobre-segmentada com relação aos segmentos de interesse.

Quando existe um mapa de referência para o estudo de caso, pode-se avaliar a técnica através da comparação visual entre as regiões segmentadas e os polígonos de referência. Para fins de comparação, também foi avaliada a utilização de outros critérios de similaridade como a distância Euclidiana

e Manhattan. Os resultados utilizando as três distâncias são comparados visualmente com base nos mapas de referência.

Além disso, vale ressaltar que estimar o resultado de uma segmentação é uma tarefa difícil, uma vez que não existe até o momento uma técnica padrão de avaliação quantitativa (EECKHAUT et al., 2012). Entretanto, um conjunto de métricas proposto por Delves et al. (1992) foi utilizado em um dos estudos de caso (Seção 5.3) para quantificar a comparação espacial entre as regiões segmentadas geradas pelo algoritmo e os polígonos de referência. Delves et al. (1992) utilizaram estas métricas para avaliar imagens de satélite de abertura sintética. Duas métricas foram calculadas: *GShape* e *FITXY*. As métricas produzem valores no intervalo $[0, 0; 1, 0]$, onde 1, 0 indica o melhor valor.

Cada métrica é calculada individualmente para cada região. Considere uma imagem de referência com N segmentos e a imagem de segmentação a ser avaliada com M segmentos, ambas com l linhas e c colunas. Uma dada região na imagem de referência é indexada por i e um dado segmento na imagem de segmentação a ser avaliada, por f . Duas matrizes, G_f e Fit , ambas de tamanho $N \times M$, são construídas usando:

$$G_f(i, f) = \frac{Np(i \cap f)}{Np(i \cup f)} \quad (4.1)$$

$$Fit(i, f) = \frac{xd + yd + \frac{pd+id}{2}}{G_f(i, f)}, \quad (4.2)$$

onde:

$$xd = \frac{|\langle x_i \rangle - \langle x_f \rangle|}{c} \quad (4.3)$$

$$yd = \frac{|\langle y_i \rangle - \langle y_f \rangle|}{l} \quad (4.4)$$

$$pd = \frac{|N(i) - N(f)|}{N(i) + N(f)} \quad (4.5)$$

$$id = \frac{|\langle V_i \rangle - \langle V_f \rangle|}{\langle V_i \rangle + \langle V_f \rangle}. \quad (4.6)$$

A notação $\langle md_i \rangle$ representa a média da medida md em uma dada região i ; x_i e y_i indicam a localização de algum pixel dentro de i (coluna e linha, respectivamente). V_i e V_f correspondem ao valor do pixel na imagem de referência e na imagem a ser avaliada, respectivamente; e $Np(i)$ representa o número de pixels de i . Para cada região i , a variável $bestFit$ é atribuída à região f com o valor mais baixo de $Fit(i, f)$. Para cada $bestFit$, as métricas $GShape$ e $FITXY$ são calculadas:

$$GShape = \frac{Np(i \cap f)}{Np(i \cup f)} \quad (4.7)$$

$$FITXY = 1 - \frac{xd + yd}{2} \quad (4.8)$$

$Gshape$ avalia a similaridade da forma entre os polígonos de referência e os segmentos gerados pelo algoritmo. $FITXY$ leva em consideração o deslocamento entre o centro de gravidade da referência e do segmento gerado pelo método.

Outras métricas além das propostas por Delves et al. (1992) foram consideradas, também utilizadas em outros trabalhos envolvendo segmentação e detecção de mudanças (ZHANG et al., 2015; ZHANG et al., 2017; XIAO et al., 2017). As métricas usadas são: *Accuracy*, *Precision*, *Recall* e *F-Score*.

Sejam duas imagens, uma imagem de referência e uma imagem segmentada a ser analisada, ambas com valor 1 para os pixels pertencentes a um dado segmento e valor de pixel 0, caso contrário. Para o cálculo destas quatro métricas é necessário observar quatro comparações, expostas na Tabela 4.1.

Tabela 4.1 - Observações entre a imagem de referência e a imagem segmentada.

		Imagem Segmentada	
		Valor do pixel = 1	Valor do pixel = 0
Referência	Valor do pixel = 1	Verdadeiro Positivo (VP)	Falso Negativo (FN)
	Valor do pixel = 0	Falso Positivo (FP)	Verdadeiro Negativo (VN)

A partir dos valores de VP , FP , VN e FN , obtêm-se:

$$Accuracy = \frac{VP + VN}{VP + FP + VN + FN} \quad (4.9)$$

$$Precision = \frac{VP}{VP + FP} \quad (4.10)$$

$$Recall = \frac{VP}{VP + FN} \quad (4.11)$$

$$F-Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4.12)$$

A métrica *Accuracy* equivale à razão entre o número de pixels classificados corretamente e o número total de predições. Um valor alto na métrica *Precision* indica um número pequeno de falsos positivos, enquanto que um valor alto da métrica *Recall* indica uma pouca quantidade de falsos negativos. A métrica *F-Score*, a média harmônica entre *Precision* e *Recall* procura fazer o balanço entre estas duas métricas.

5 RESULTADOS E DISCUSSÕES

Para geração e análise dos resultados, cinco estudos de caso foram realizados. Em cada experimento foi utilizada uma sequência de imagens de um mesmo local no decorrer do tempo, nas quais cada pixel corresponde a um valor de índice de vegetação (NDVI ou EVI).

Os parâmetros da segmentação foram encontrados de forma empírica. Com relação à distância DTW, a restrição local *symmetric2* e a diferença absoluta como distância δ foram utilizadas em todos os estudos de caso. Os cinco estudos de caso foram realizados numa máquina com processador Intel(R) Core(TM) i7-6500U 2,50 GHz e memória RAM de 16 GB.

5.1 Estudo de Caso 1: Região Supervisionada pela EMBRAPA - Santo Antônio de Goiás

No primeiro estudo de caso, a área escolhida representa uma região localizada no estado de Goiás (GO), no município de Santo Antônio de Goiás, ilustrada na Figura 5.1. Uma sequência de 44 imagens NDVI obtidas a partir do sensor Landsat-8 OLI foi utilizada como entrada. As imagens foram coletadas entre o período de 12 de novembro de 2014 e 30 de setembro de 2016, com intervalo de 16 dias. Todas as imagens apresentam dimensão de 189×161 pixels com resolução espacial de 30 m (Figura 5.2).

Para avaliar os resultados da segmentação, foram utilizados 10 polígonos de uma base de referência da EMBRAPA (BRAZIL MINISTÉRIO DA AGRICULTURA, 2011), ilustrados na Figura 5.3. O subconjunto dos 10 polígonos foi escolhido porque eles representam regiões com propriedades homogêneas durante o período analisado, de acordo com informações fornecidas pela EMBRAPA.

O período analisado corresponde às épocas de safra 2014/2015, inverno de 2015, safra 2015/2016 e inverno de 2016. Durante estas épocas, o polígono $F1$ continha uma área de floresta, os polígonos $P1$, $P2$, $P3$, $P4$ e $P5$ apresentaram áreas de pasto e/ou agricultura, enquanto que os polígonos $A1$, $A2$, $A3$, $A4$ continham áreas irrigadas por sistemas de pivô central. A descrição da cobertura do solo de cada polígono está exibida na Tabela 5.1.

Figura 5.1 - Área do Estudo de Caso 1 (Região de Santo Antônio de Goiás - Goiás).
Imagem NDVI Landsat-8 OLI.

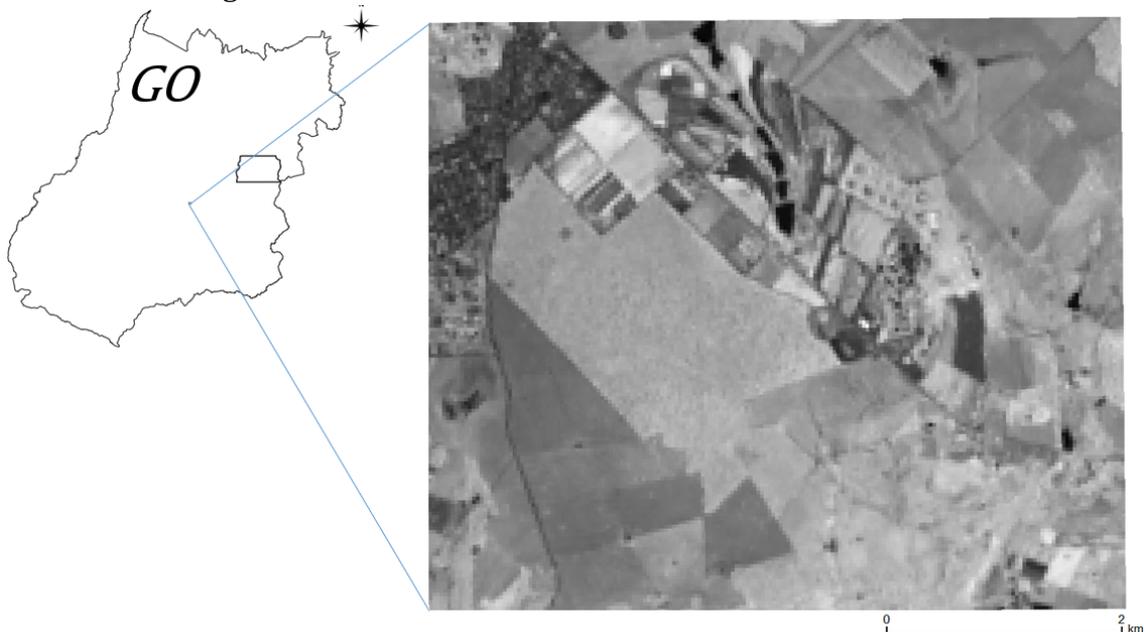


Tabela 5.1 - Descrição da cobertura do solo para cada safra/inverno no período analisado.

Rótulo	Safra (2014/2015)	Inverno (2015)	Safra (2015/2016)	Inverno (2016)
<i>F1</i>	floresta	floresta	floresta	floresta
<i>P1</i>	pasto	pasto	pasto	pasto
<i>P2</i>	pasto	pasto	pasto	pasto
<i>P3</i>	soja	pousio	arroz	pousio
<i>P4</i>	arroz	pousio	milho + <i>brachiaria</i>	pasto
<i>P5</i>	pasto	pasto	soja	pousio
<i>A1</i>	milho + <i>brachiaria</i>	pasto	soja	pousio
<i>A2</i>	arroz	pousio	milho + <i>brachiaria</i>	pousio
<i>A3</i>	soja	pousio	arroz	pasto
<i>A4</i>	pasto	pasto	soja	pousio

É importante salientar que o Estudo de Caso 1 é uma extensão do trabalho intitulado "*Segmentation of optical remote sensing images for detecting homogeneous regions in space and time*". O trabalho foi publicado nos anais do simpósio XVIII Brazilian Symposium on Geoinformatics - GEOINFO 2017

Figura 5.2 - Sequência de 44 imagens NDVI (Landsat-8 OLI) utilizadas no Estudo de Caso 1 (T_1, T_2, \dots, T_{44}). Pode-se notar que algumas imagens contêm alto percentual de cobertura de nuvens (regiões mais escuras, como por exemplo T_1, T_2 e T_3).

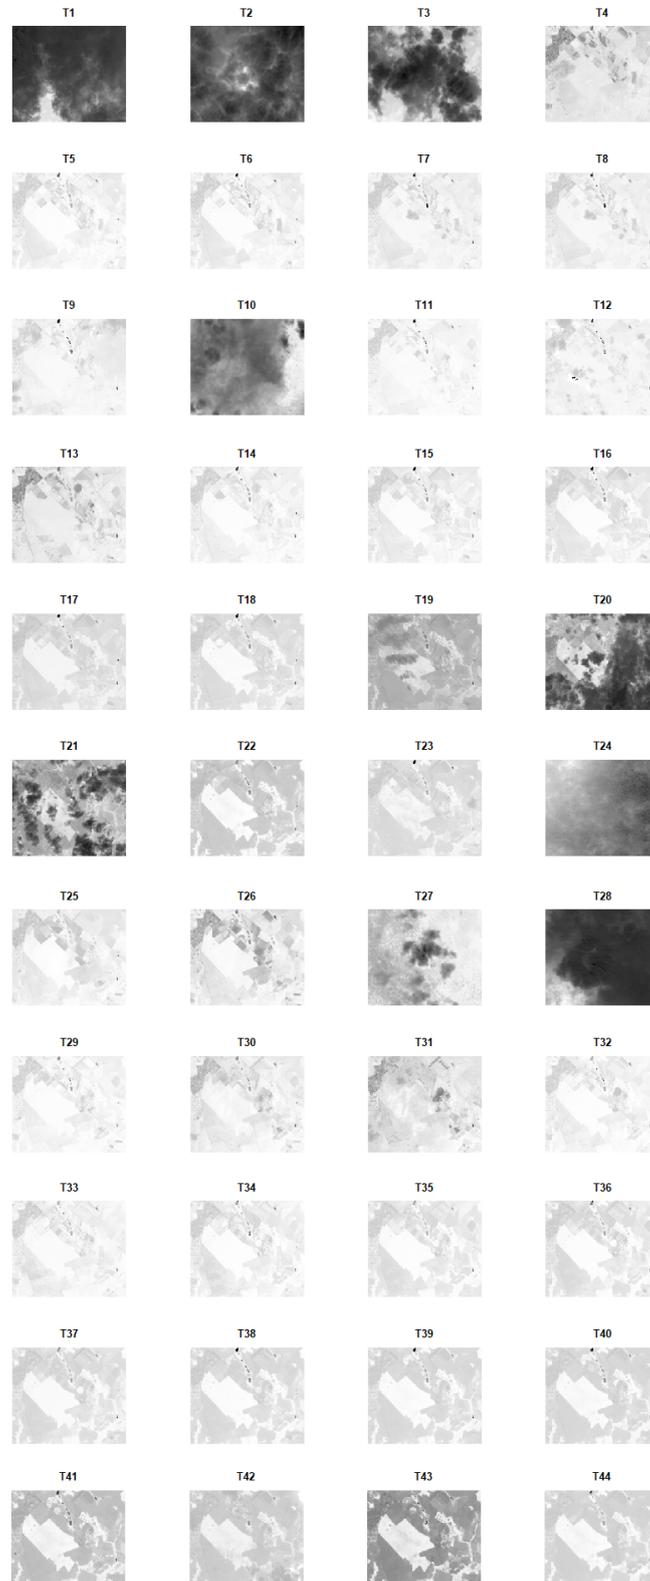
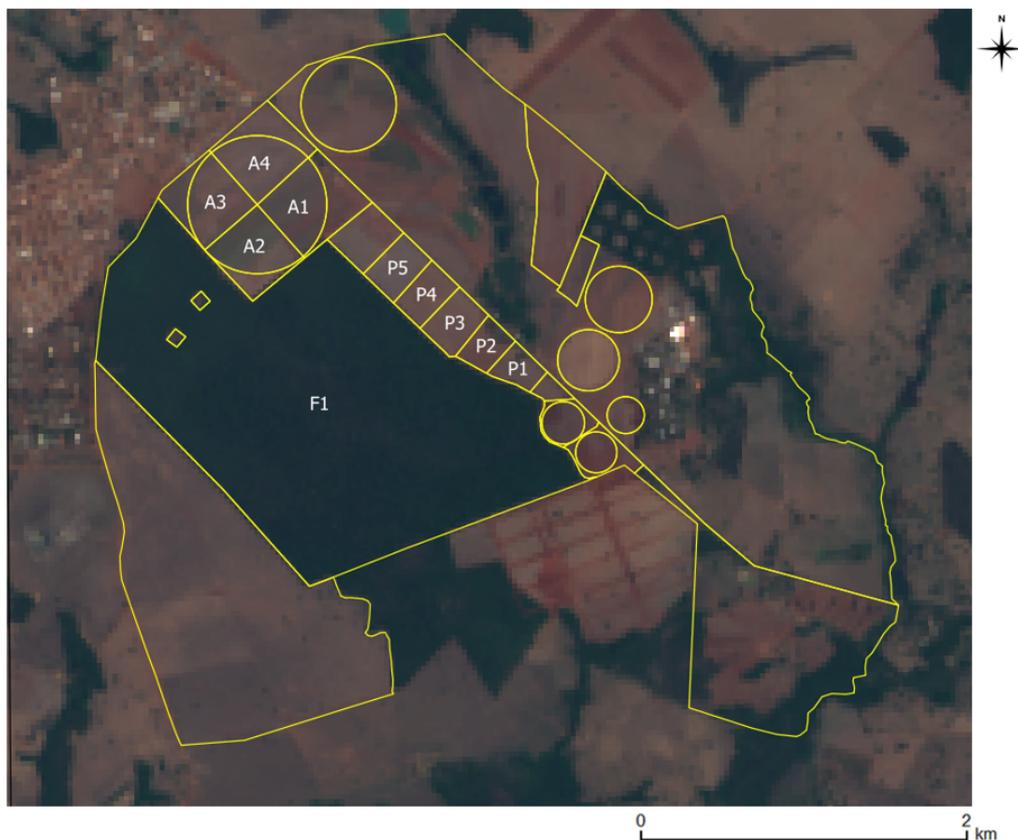


Figura 5.3 - Polígonos (contornos em amarelo) fornecidos pela EMBRAPA. Os polígonos rotulados (*F1*, *P1*, *P2*, *P3*, *P4*, *P5*, *A1*, *A2*, *A3* e *A4*) foram utilizados como referência. Os polígonos estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2).

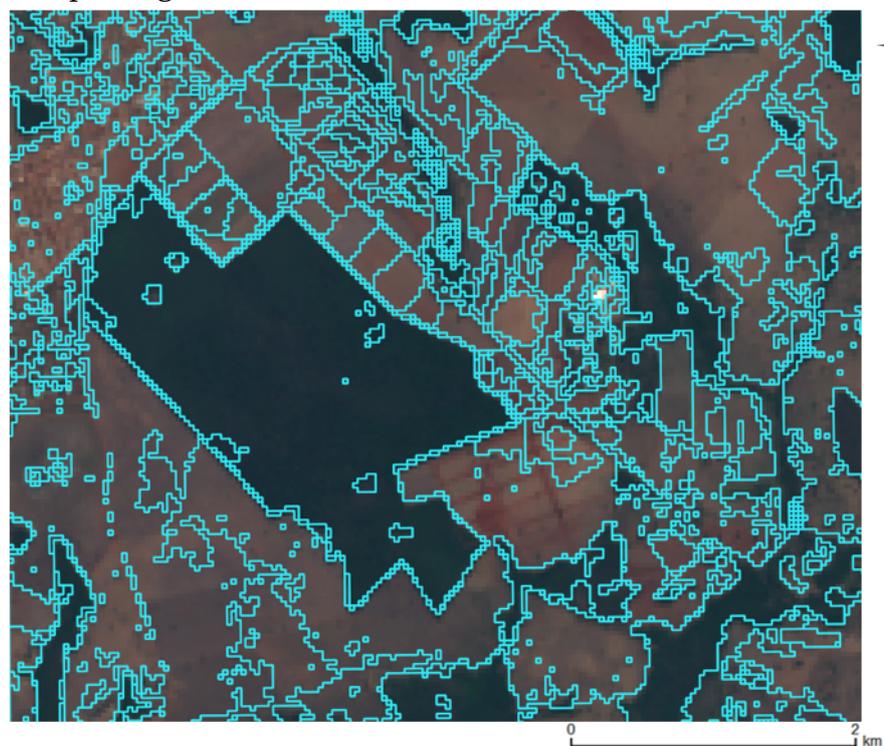


(COSTA et al., 2017) e no periódico *online* da Revista Brasileira de Cartografia - RBC (COSTA et al., 2018c).

Em todos os testes, o limiar de similaridade foi escolhido empiricamente de modo que áreas de agricultura, pasto e floresta pudessem ser visualmente representadas com o mínimo de confusão entre a separação destes alvos. Na Figura 5.4 é exibido o resultado da técnica utilizando a distância DTW como critério de homogeneidade, com o limiar de similaridade definido por 0,045. O tempo de processamento foi de 183 segundos. Neste resultado, polígonos de até 1 pixel foram considerados segmentos válido.

Baseando-se na fotointerpretação dos polígonos resultantes da segmentação e a referência fornecida pela EMBRAPA, o algoritmo foi capaz de separar e delinear alguns dos polígonos de referência analisados (6/10). Os resultados da segmentação foram sobrepostos em uma imagem Landsat-8 OLI (R4G3B2)

Figura 5.4 - Resultado da segmentação (imagem superior) com o método proposto. Os segmentos (contornos em azul) estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2). Área ampliada (imagem inferior) contendo os polígonos de referência (contornos em amarelo) e os segmentos obtidos pelo algoritmo (contornos em azul).



do dia 30 de setembro de 2016. Visualmente, os polígonos resultantes representam regiões de tamanho similar aos polígonos de referência $F1$, $P3$, $P4$ e $P5$. Apesar de o polígono resultante equivalente ao $P2$ apresentar um estreitamento da região em relação ao polígono de referência, pode-se observar que há uma área com presença de árvores dentro do polígono e o segmentador separou esta área do restante da região, reduzindo o tamanho do polígono em relação à referência.

Já o polígono resultante que seria correspondente à referência $P1$ apresentou comportamento similar ao polígono vizinho durante os dois anos analisados (ao observar visualmente as 44 imagens). Com isso, o segmentador considerou os dois polígonos como uma área única com propriedades homogêneas no período observado.

Casos semelhantes ocorreram com os polígonos $A1$ e $A4$. Como pode ser visto na Tabela 5.1, as duas áreas apresentam o mesmo tipo de uso de solo, diferindo apenas na safra 2014/2015. Dessa forma, o segmentador considerou as duas áreas como uma única região. Contudo, as referências $A2$ e $A3$ foram as que mais divergiram do resultado da segmentação, uma vez que foram separadas em duas regiões distintas cada.

Com o objetivo de comparar a eficiência da distância DTW em tratar dados temporais com ruído, o método proposto foi comparado com resultados de segmentação utilizando outros critérios. Os resultados da segmentação foram gerados utilizando a distância de Manhattan, ou diferença absoluta (Figura 5.5), e a distância Euclidiana (Figura 5.6) utilizando o mesmo conjunto de sementes.

Os limiares de similaridade também foram definidos de forma empírica. Os resultados expostos representam segmentos utilizando os valores de limiar 2,4 e 0,6 para a distância de Manhattan e Euclidiana, respectivamente. O tempo de processamento de cada teste foi de 158 segundos usando a distância de Manhattan e de 161 segundos para a distância Euclidiana. Visualmente, os polígonos resultantes representam regiões de tamanho similar aos polígonos de referência $P3$ e $P5$, em ambos os casos. Também, em ambos os casos, pode ser observada a mesma situação apontada nos polígonos $P1$ e $P2$ utilizando a distância DTW como critério de homogeneidade. Contudo, os polígonos de referência $F1$, $P4$, $A1$, $A2$, $A3$, $A4$ foram subdivididos em vários segmentos e visualmente apresentaram um pior desempenho na qualidade do resultado

Figura 5.5 - Resultado da segmentação (imagem superior) utilizando a distância de Manhattan como critério de homogeneidade. Os segmentos (contornos em azul) estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2). Área ampliada (imagem inferior) contendo os polígonos de referência (contornos em amarelo) e os segmentos obtidos pelo algoritmo (contornos em azul).

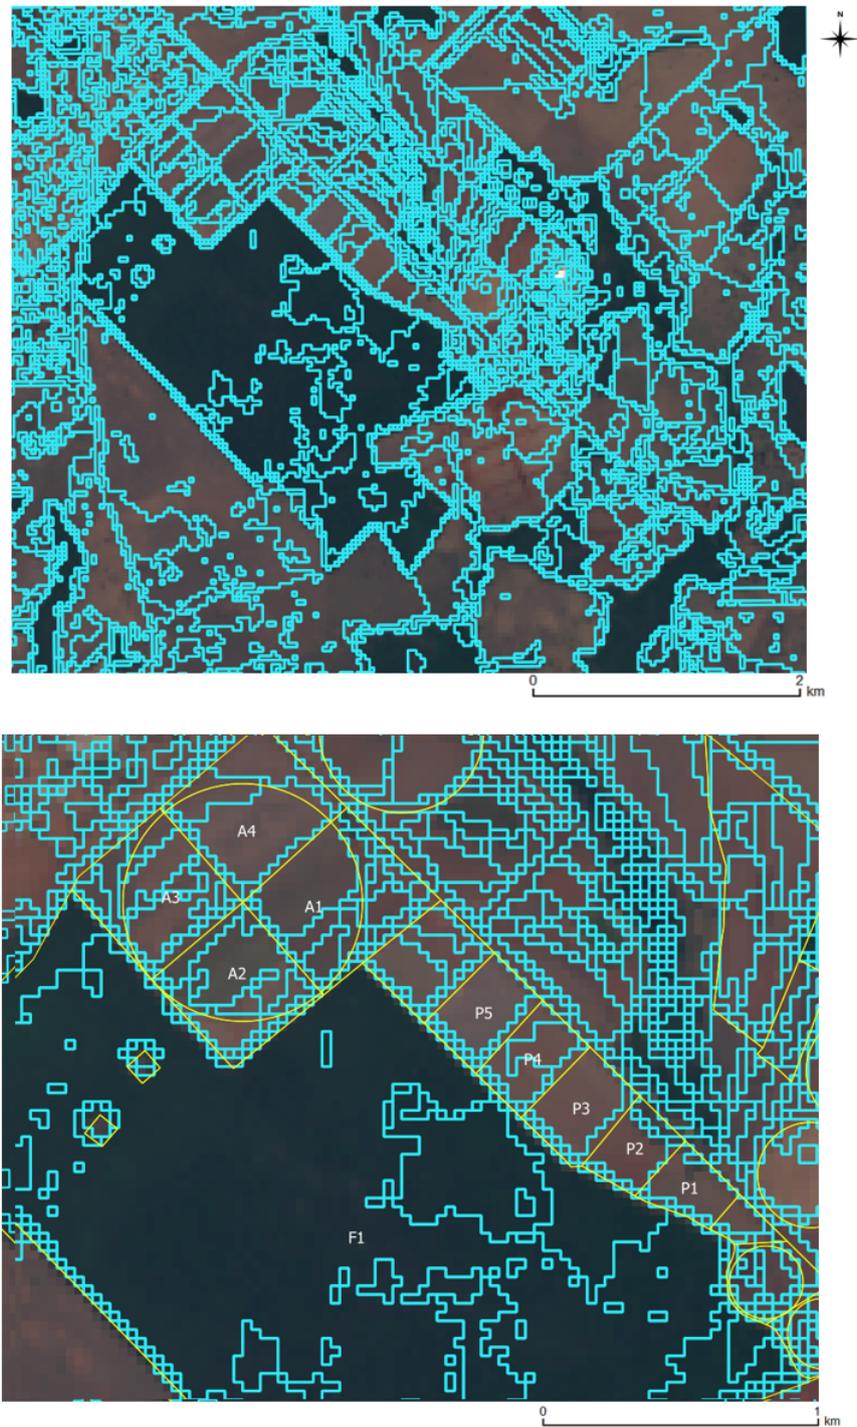
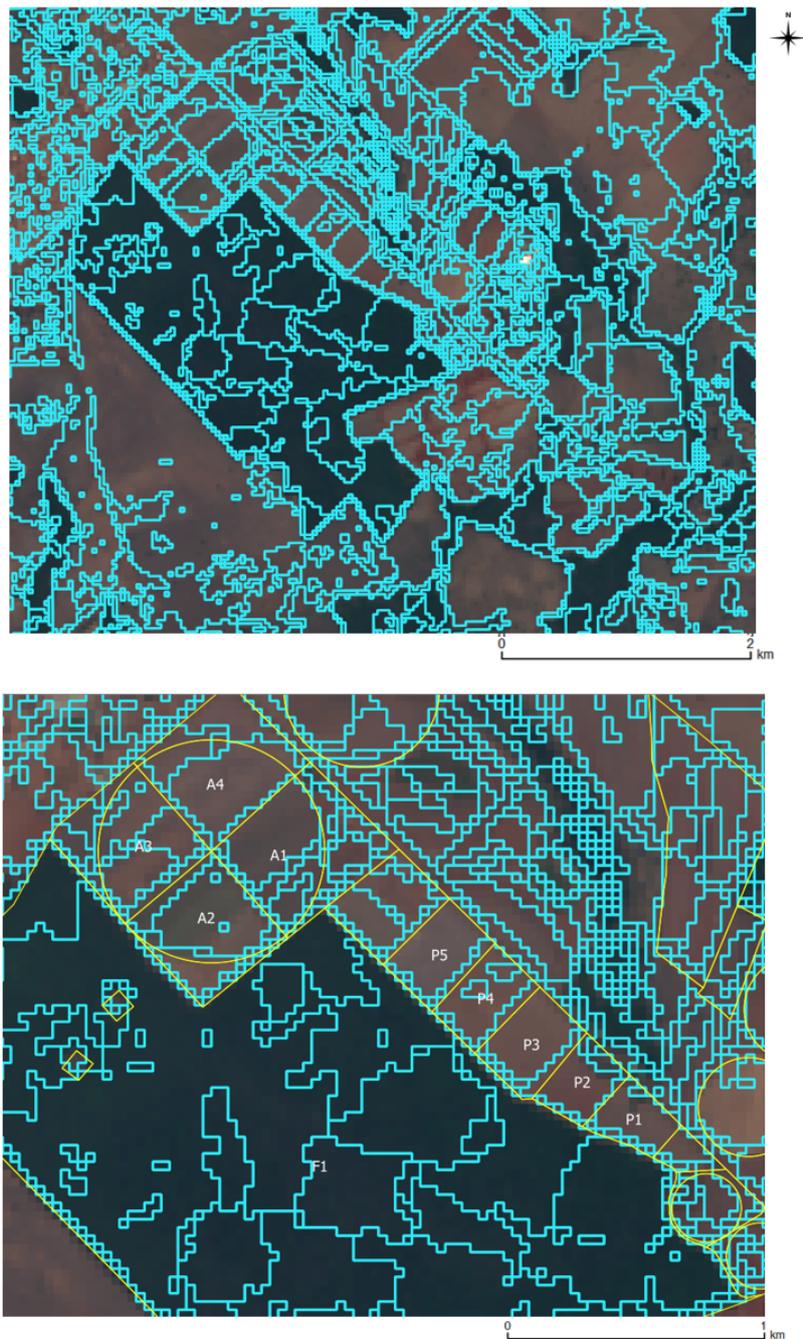


Figura 5.6 - Resultado da segmentação (imagem superior) utilizando a distância Euclidiana como critério de homogeneidade. Os segmentos (contornos em azul) estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2). Área ampliada (imagem inferior) contendo os polígonos de referência (contornos em amarelo) e os segmentos obtidos pelo algoritmo (contornos em azul).



se comparados com os resultados obtidos utilizando a distância DTW como critério de homogeneidade.

Além disso, para analisar a influência de ruídos em cada um dos três testes, pode ser observada, por exemplo, uma imagem da sequência que apresentou alta cobertura de nuvens (Figura 5.7). Os segmentos sobrepostos no polígono de referência $F1$ destacados em vermelho na Figura 5.7 são regiões que foram divididas por influência da presença de nuvens na imagem. Comparando os três resultados, a segmentação utilizando a distância DTW foi a que obteve menor interferência das nuvens, reforçando o potencial da medida DTW em tratar dados temporais com ruído.

Na Figura 5.8, são ilustrados os três resultados obtidos utilizando também o limiar de área mínima (A). Segmentos menores que 7200 m^2 ($A = 7200$) foram agrupados com o polígono vizinho de maior borda em comum. Mesmo com a redução do número de segmentos ao utilizar o limiar A , os resultados utilizando as distâncias de Manhattan e Euclidiana ainda contêm vários segmentos provenientes de cobertura de nuvens, claramente observados na sobreposição com a região de floresta (polígono de referência $F1$).

Além de todos testes acima citados, foram realizados mais dois experimentos modificando o cômputo da distância DTW. Os testes foram feitos aplicando as restrições globais correspondentes às janelas de busca Sakoe-Chiba e o paralelogramo de Itakura, descritas na Seção 3.2. As restrições globais foram aplicadas com o objetivo de reduzir o custo computacional do algoritmo. Nos resultados, ilustrados nas Figuras 5.9 e 5.10, foram utilizados o mesmo conjunto de sementes e o mesmo limiar de similaridade aplicados no teste exibido na Figura 5.4. O tempo de processamento foi de 178 e 176 segundos utilizando as janelas de busca de Sakoe-Chiba e Itakura, respectivamente. Na Tabela 5.1 são exibidos os tempos obtidos para todos os testes até então citados.

Ao utilizar as restrições locais, houve uma pequena redução do tempo computacional em relação ao resultado que utilizou o algoritmo clássico da distância DTW. No entanto, devido ao cômputo da matriz entre as duas séries temporais, todos os testes utilizando a medida DTW, seja ela adaptada ou não, apresentaram um tempo computacional maior que as distâncias de Manhattan e Euclidiana. Além disso, apesar de o tempo de processamento ser reduzido utilizando as restrições globais na distância DTW, há uma perda

Figura 5.7 - Imagem NDVI, T21, da sequência de imagens utilizada como dados de entrada (a) com alta presença de nuvens (com destaque na área pontilhada em amarelo). Os polígonos preenchidos em amarelo ilustram segmentos que foram gerados por influência da cobertura de nuvens, utilizando as distâncias DTW (b), Manhattan (c) e Euclidiana (d) como critério de homogeneidade. Os contornos em azul representam os segmentos obtido em cada teste.

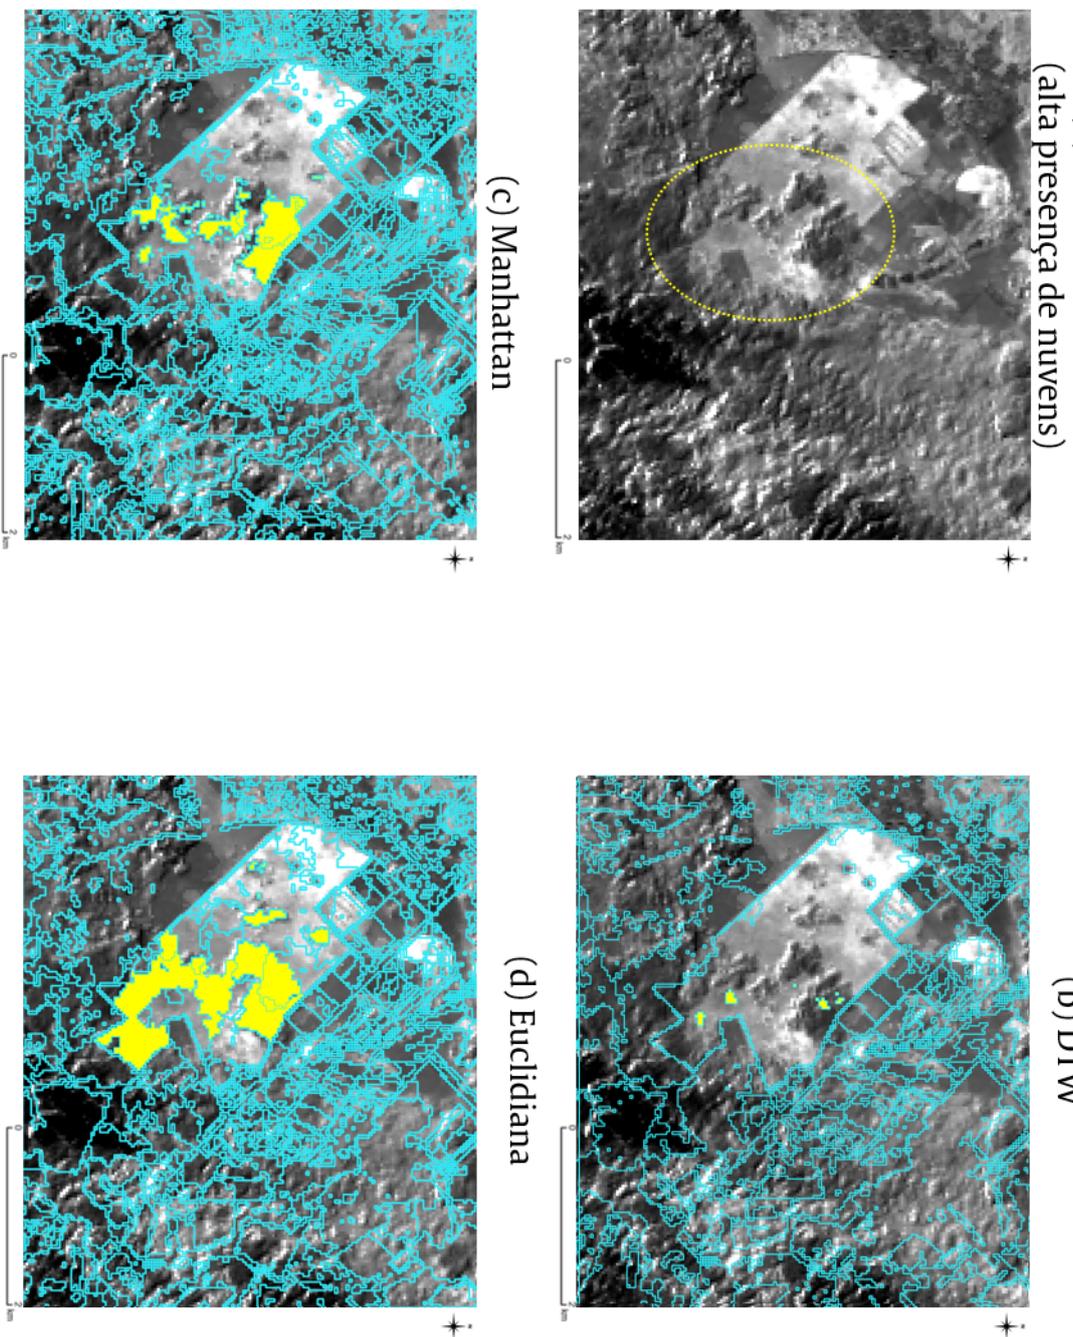


Figura 5.8 - Resultados utilizando limiar de área $A = 7200 \text{ m}^2$ para as distâncias DTW (a), de Manhattan (b) e Euclidiana (c). Os segmentos (contornos em azul) estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2).

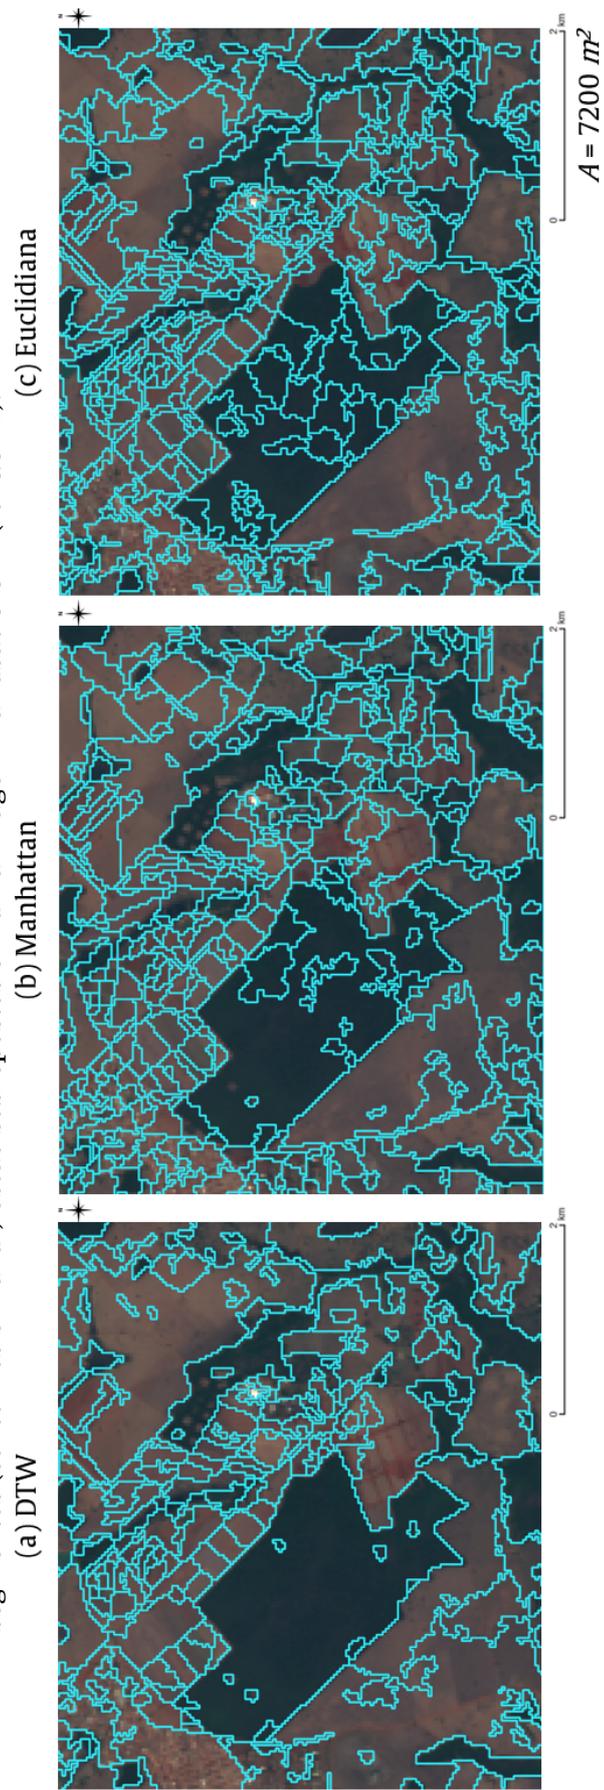


Tabela 5.2 - Tempo computacional de cada distância analisada no Estudo de Caso 1.

Distância	Tempo (s)
DTW	183
Manhattan	158
Euclidiana	161
DTW (Sakoe-Chiba)	178
DTW (Itakura)	176

notável na qualidade da segmentação utilizando qualquer uma das restrições em relação ao resultado utilizando a medida DTW clássica, como pode ser observado ao comparar os resultados das Figuras 5.4, 5.9 e 5.10.

Figura 5.9 - Resultado da segmentação do Estudo de Caso 1 utilizando a distância DTW com a restrição global da janela de busca de Sakoe-Chiba. Os segmentos (contornos em azul) estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2).

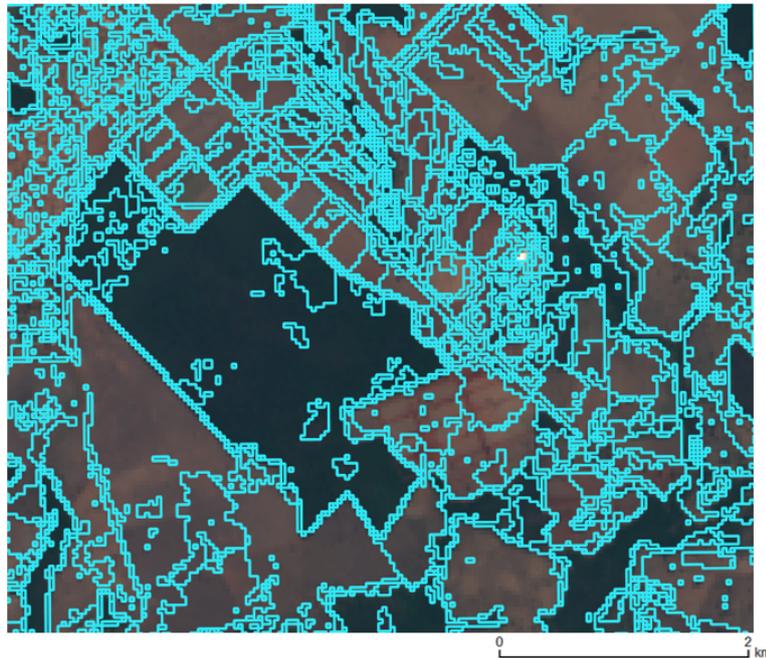
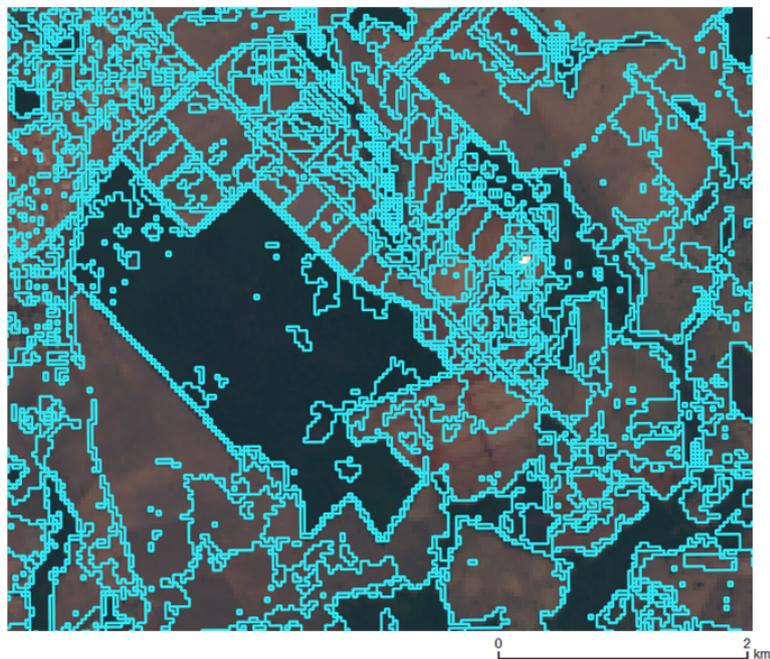


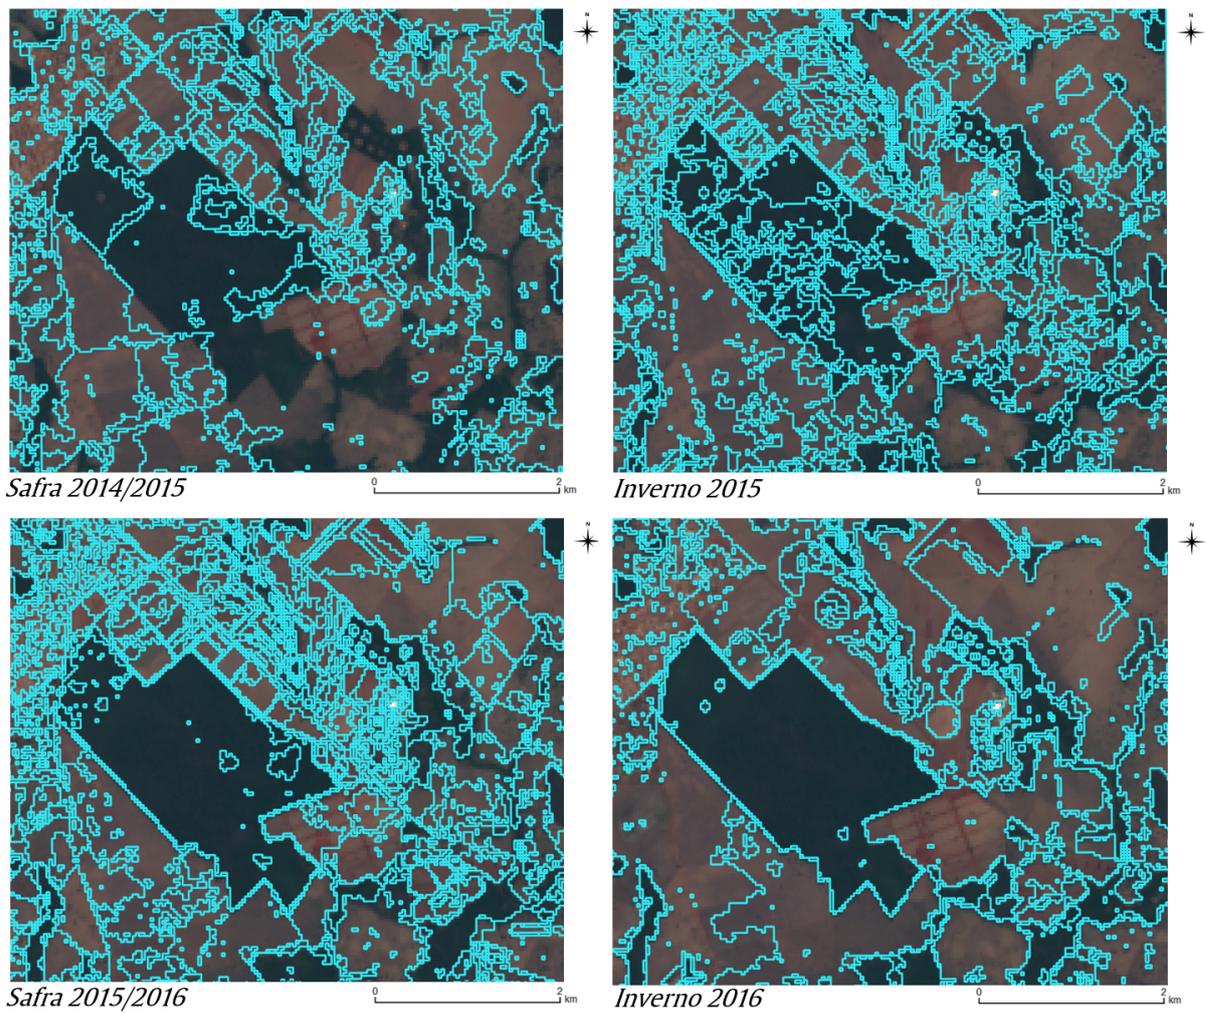
Figura 5.10 - Resultado da segmentação do Estudo de Caso 1 utilizando a distância DTW com a restrição global da janela de busca de Itakura. Os segmentos (contornos em azul) estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2).



Por fim, outros testes foram feitos observando o resultado do segmentador para cada época de safra/inverno. Os melhores resultados do segmentador para cada época podem ser vistos na Figura 5.11. Observando estes quatro resultados com os testes anteriores, nota-se que o segmentador apresenta um melhor resultado quando existe uma maior disponibilidade de imagens. Nestes últimos quatro testes, a baixa quantidade de amostras aliada à alta cobertura de nuvens reduziram a qualidade do resultado.

Vale salientar que neste estudo de caso, o conjunto de sementes foi definido aleatoriamente e o conjunto foi utilizado em todos os experimentos de forma a segmentar toda a imagem. Para utilizar uma medida quantitativa neste estudo, seria necessário aplicar uma abordagem diferente na metodologia, definindo sementes manualmente apenas para os 10 polígonos que continham a referência. No Estudo de Caso 3 foi aplicada uma abordagem diferente de forma que uma avaliação quantitativa também pudesse ser aplicada ao método proposto (ver Seção 5.3).

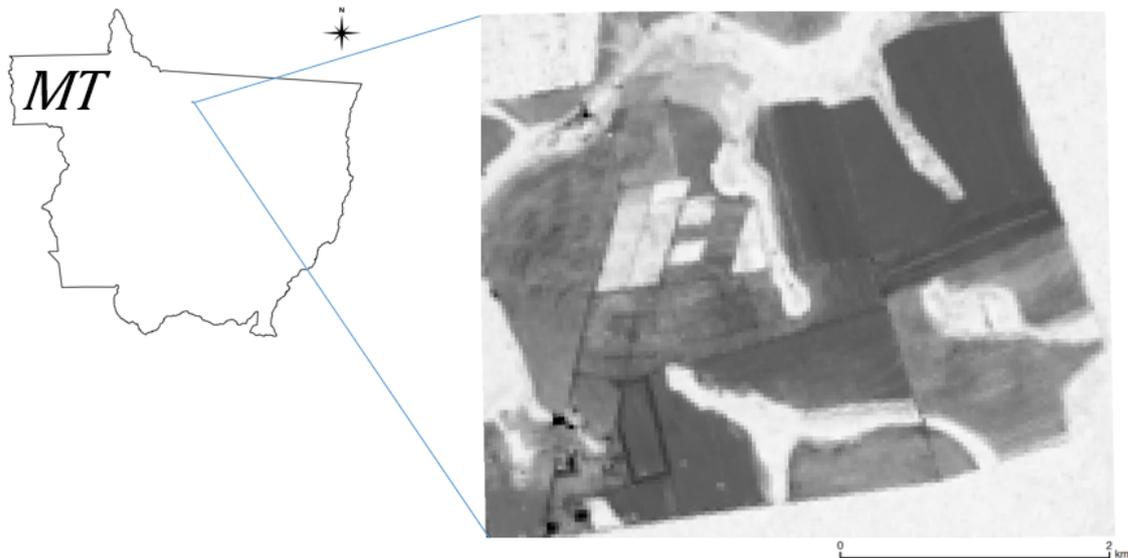
Figura 5.11 - Resultado da segmentação para cada época de safra/inverno. Os segmentos (contornos em azul) estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2).



5.2 Estudo de Caso 2: Fazenda Gamada - Mato Grosso

No segundo estudo de caso, uma região do Centro-oeste do Brasil foi utilizada para a avaliação da técnica de segmentação espaço-temporal. A área de estudo é uma região do estado do Mato Grosso (MT), localizada no município de Nova Canaã do Norte, ilustrada na Figura 5.12. Uma sequência de 27 imagens NDVI obtidas a partir do sensor Landsat-8 OLI foi utilizada. As imagens vão de 10 de abril de 2016 a 31 de maio de 2017, com resolução temporal de 16 dias. Todas as imagens tem dimensão de 155×132 pixels, com resolução espacial de 30 m (Figura 5.13).

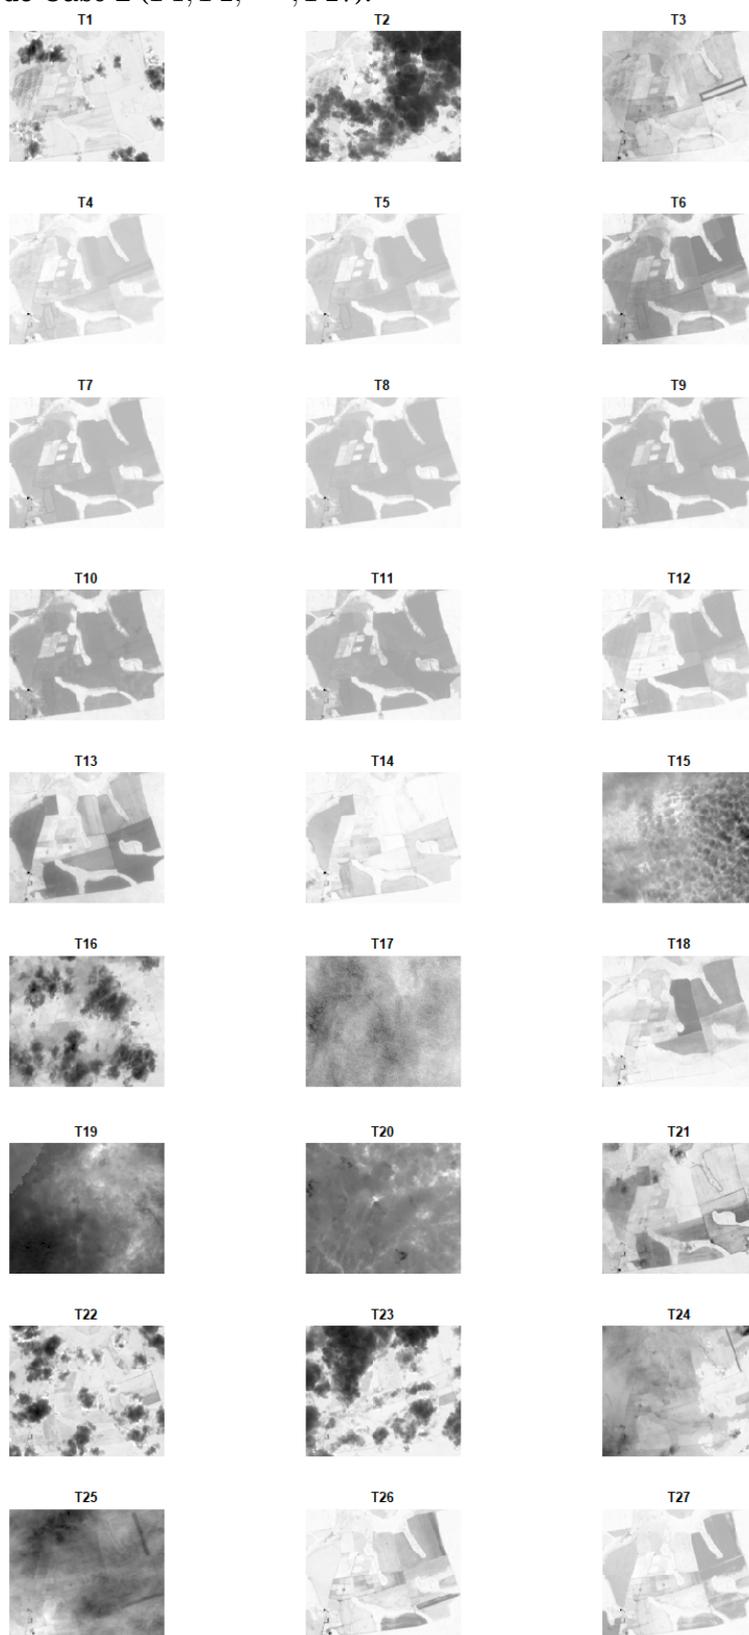
Figura 5.12 - Área do Estudo de Caso 2. Imagem NDVI Landsat-8 OLI.



Vale ressaltar que o Estudo de Caso 2 é baseado no artigo intitulado "A Case Study for a Multitemporal Segmentation Approach in Optical Remote Sensing Images" (COSTA et al., 2018a). O trabalho foi publicado nos anais da conferência *GEOProcessing 2018, The Tenth International Conference on Advanced Geographic Information Systems, Applications, and Services*.

O estudo foi conduzido na Fazenda Gamada, a qual é supervisionada pela EMBRAPA. As estações seca e chuvosa são bem definidas na região. A estação seca ocorre durante maio e agosto, enquanto que cerca de 95% da precipitação anual de chuva está concentrada entre setembro e abril. Durante o ano

Figura 5.13 - Sequência de 27 imagens NDVI (Landsat-8 OLI) utilizadas no Estudo de Caso 2 (T_1, T_2, \dots, T_{27}).



analisado, a fazenda continha áreas de vegetação nativa e pasto, além de regiões com vários tipos de culturas, tais como cana-de-açúcar, arroz, milho e soja.

Esta região foi escolhida para análise da técnica porque contém áreas com propriedades homogêneas no período descrito, de acordo com informações fornecidas pela EMBRAPA. Os talhões ilustrados na Figura 5.14 foram utilizados como polígonos de referência. A descrição do uso do solo de cada polígono está descrita na Tabela 6.3.

Figura 5.14 - Polígonos (contornos em vermelho) fornecidos pela EMBRAPA e utilizados como referência. Os polígonos estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2).



É importante ressaltar que, como exposto na Tabela 6.3, a fazenda continha regiões de sistemas ILPF (Integração Lavoura-Pecuária-Floresta). Na época analisada, a fazenda possuía rotação de culturas, consistindo em regiões de gramíneas intercambiáveis com soja, arroz + soja, milho + soja, cana de açúcar e vegetação nativa.

O limiar de similaridade foi escolhido empiricamente em todos os testes, de modo que áreas de ILPF, agricultura, pasto e vegetação nativa pudessem

Tabela 5.3 - Descrição do uso do solo de cada polígono rotulado durante o período analisado.

Rótulo	Uso do solo (Data da mudança do uso do solo)		
1	ILPF (todo o ano observado)		
2	capim (25/02/2016)	soja (24/10/2016)	milho (15/02/2017)
3	milho (22/01/2016)	soja (22/09/2016)	capim (15/01/2017)
4	milho (22/01/2016)	soja (18/08/2016)	milho (10/01/2017)
5	milho (10/02/2016)	soja (10/10/2016)	capim (10/02/2017)
6	milho (15/01/2016)	soja (15/10/2016)	milho (15/01/2017)

ser visualmente representadas com o mínimo de confusão entre a separação destas regiões. Na Figura 5.15 é ilustrado o resultado da segmentação utilizando a distância DTW como critério de homogeneidade. O limiar de similaridade definido por 0,061. O tempo de processamento foi de 143 segundos. O código para este resultado da implementação, assim como os dados de entrada e saída do algoritmo podem ser acessados *online*, disponível em <https://github.com/wscosta/segdtw>.

A região equivalente ao sistema ILPF (rotulada como 1) foi detectada pela método proposto. Porém, o segmento agregou duas áreas vizinhas, que segundo informações da EMBRAPA, também correspondem a áreas de sistema ILPF, mas que apresentam um espaçamento menor entre as culturas. Como as imagens Landsat-8 utilizadas apresentam resolução espacial de 30 m, a técnica não conseguiu detectar esta diferença entre os sistemas ILPF devido à baixa resolução espacial em relação a este tipo de detalhamento. Os segmentos sobrepostos aos polígonos rotulados como 3, 4, 5 e 6 apresentaram forma e tamanho similares aos polígonos de referência.

Figura 5.15 - Resultado da segmentação utilizando o DTW como critério de homogeneidade. Os segmentos (contornos em amarelo) estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2).

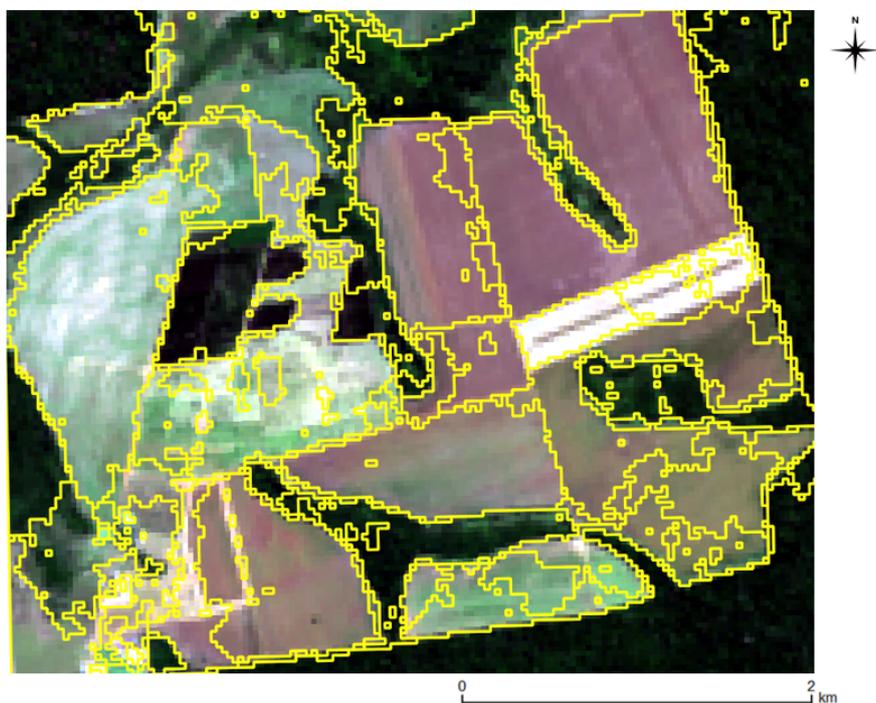


Figura 5.16 - Resultado da segmentação utilizando a distância de Manhattan como critério de homogeneidade. Os segmentos (contornos em amarelo) estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2).

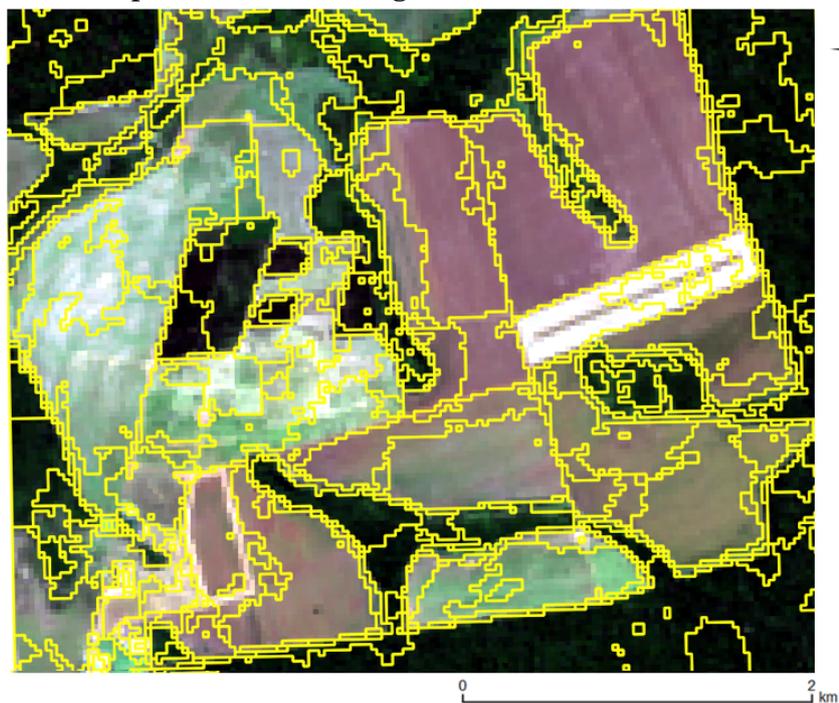
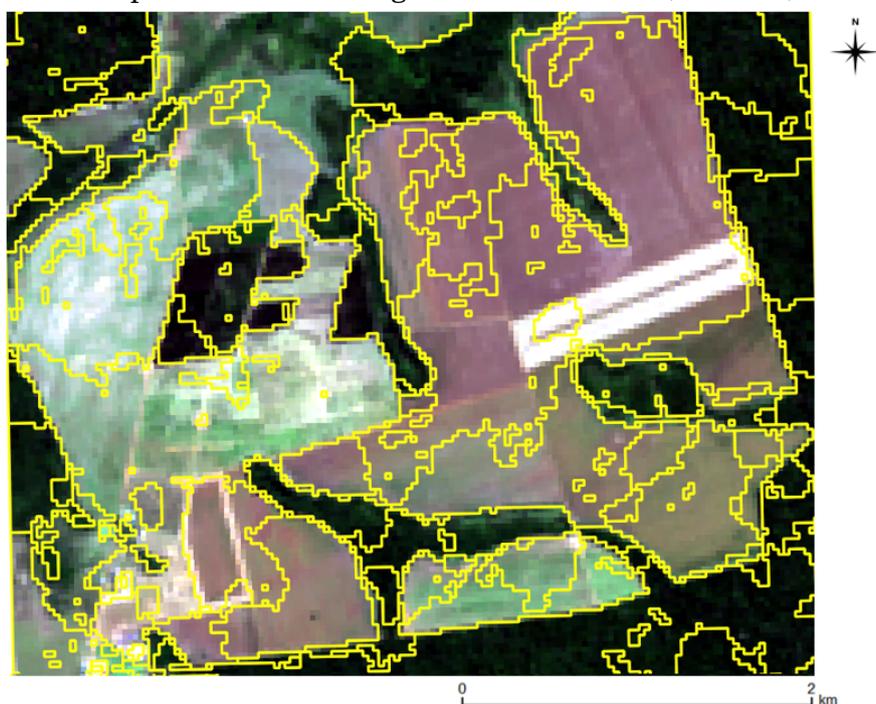


Figura 5.17 - Resultado da segmentação utilizando a distância Euclidiana como critério de homogeneidade. Os segmentos (contornos em amarelo) estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2).



Assim como elaborado no Estudo de Caso 1, testes utilizando as distâncias de Manhattan (Figura 5.16) e Euclidiana (Figura 5.17) foram reproduzidos neste estudo. O tempo de processamento para as distâncias de Manhattan e Euclidiana foram de 122 e 124 segundos, com limiares de similaridade definidos como 2,0 e 0,6, respectivamente.

Tanto no teste com a distância de Manhattan quanto na Euclidiana, o polígono de referência rotulado como 2 foi subdividido em vários segmentos. No teste com a distância de Manhattan, os polígonos de referência 3, 4, 5 e 6 foram separados em vários segmentos enquanto que, ao usar a distância Euclidiana, houve uma grande confusão no delineamento.

Ademais, o limiar de área A foi utilizado nestes três casos com o intuito de eliminar os polígonos que o algoritmo gera nas regiões de borda. Estes polígonos são criados devido à baixa resolução das imagens Landsat-8, que influencia os valores dos pixels em áreas de borda. O limiar de área foi definido por 60000 m^2 também com o objetivo de desconsiderar regiões pequenas

derivadas do ruído causado pela alta presença de nuvens na sequência de imagens. Na Figura 5.18, estão ilustrados os resultados utilizando o limiar de área para os três testes. Comparando os resultados, nota-se que a segmentação usando DTW teve o resultado com segmentos que mais se aproximam em termos de forma e tamanho em relação à referência.

Testes também foram produzidos utilizando a distância DTW com restrições globais, usando o mesmo limiar de similaridade e o mesmo conjunto de sementes reproduzido com a distância DTW clássica. Nas Figuras 5.19 e 5.20 estão exibidos os resultados usando as janelas de Sakoe-Chiba e Itakura. O tempo de processamento foi de 140 e 136 segundos, respectivamente.

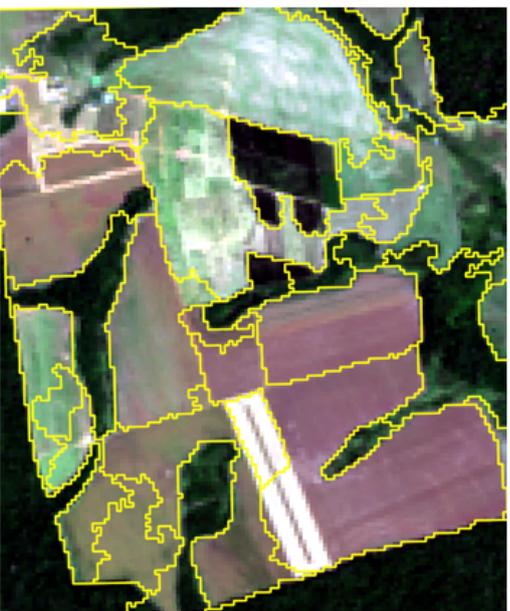
Na Tabela 6.4 são exibidos os tempos obtidos para todos os testes. Assim como no Estudo de Caso 1, a técnica com a distância DTW clássica apresenta um tempo de processamento maior do que todos os outros testes. Porém, o resultado apresenta visualmente maior qualidade nos segmentos em relação à referência.

Tabela 5.4 - Tempo computacional de cada distância analisada no Estudo de Caso 2.

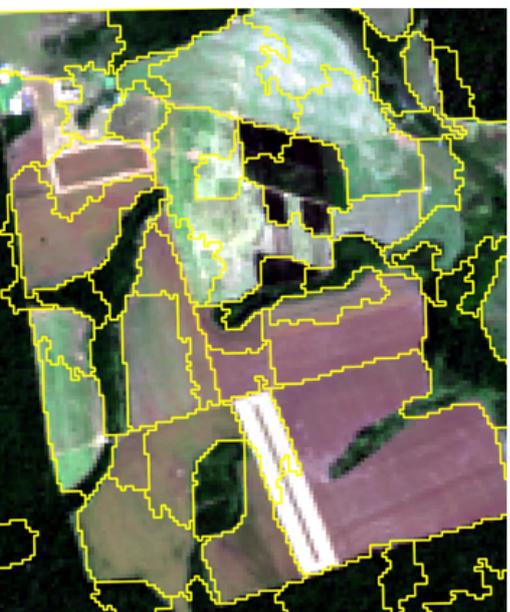
Distância	Tempo (s)
DTW	143
Manhattan	122
Euclidiana	124
DTW (Sakoe-Chiba)	140
DTW (Itakura)	136

Figura 5.18 - Resultados utilizando limiar de área $A = 60000 \text{ m}^2$ para as distâncias DTW (a), de Manhattan (b) e Euclidiana (c) para comparação com os polígonos de referência (d) (contornos em vermelho). Os segmentos (contornos em amarelo) estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2).

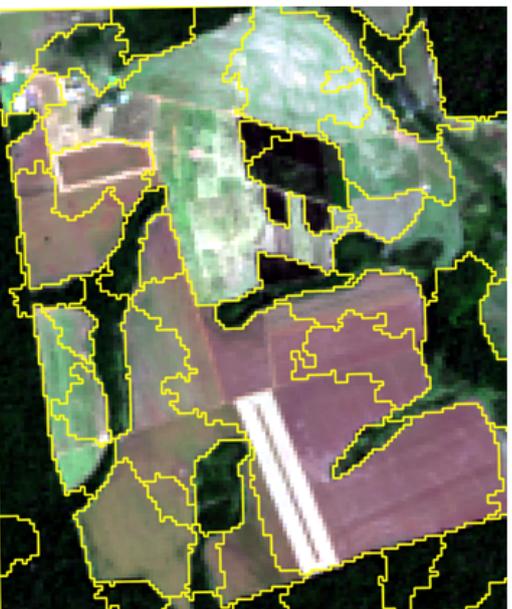
(a) DTW



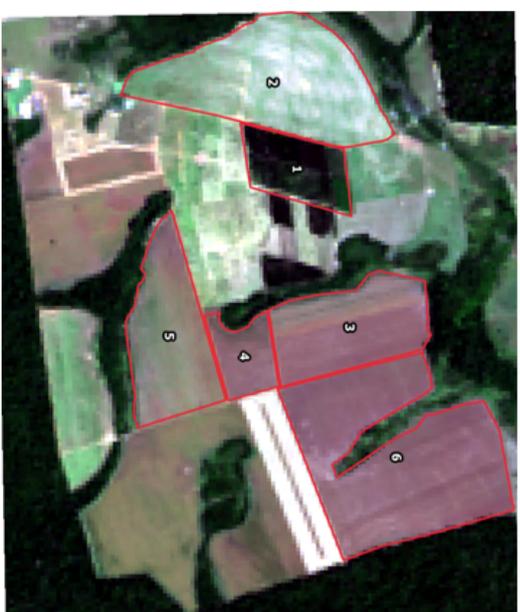
(b) Manhattan



(c) Euclidiana



(d) Referência



$A = 60000 \text{ m}^2$

Figura 5.19 - Resultado da segmentação do Estudo de Caso 2 utilizando a distância DTW com a restrição global da janela de busca de Sakoe-Chiba. Os segmentos (contornos em amarelo) estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2).

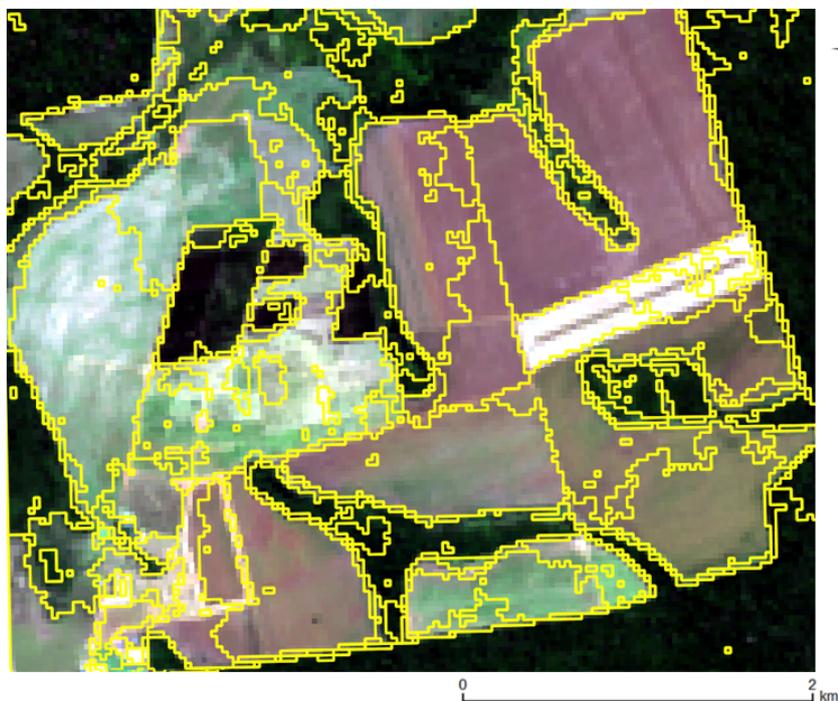
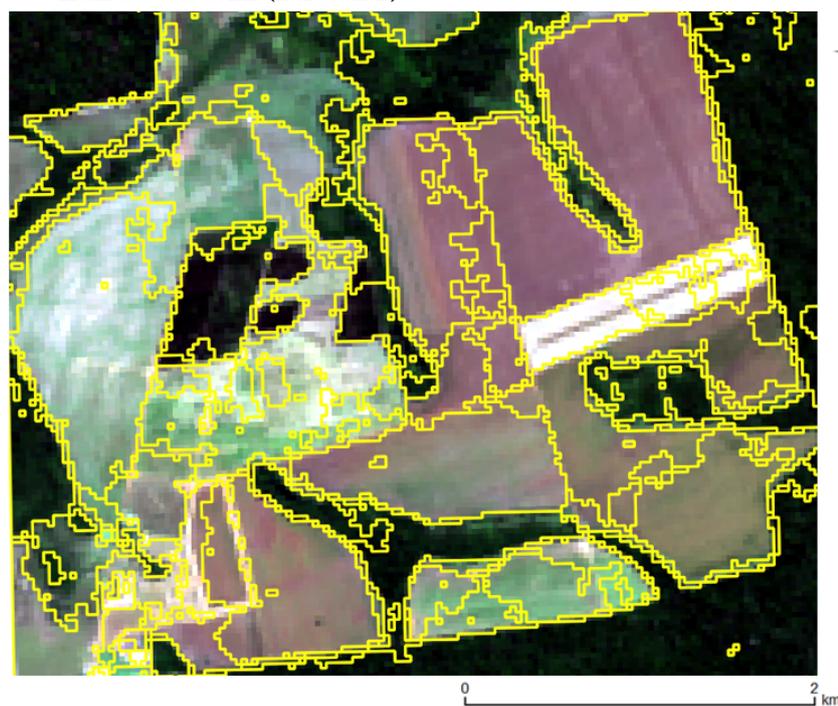


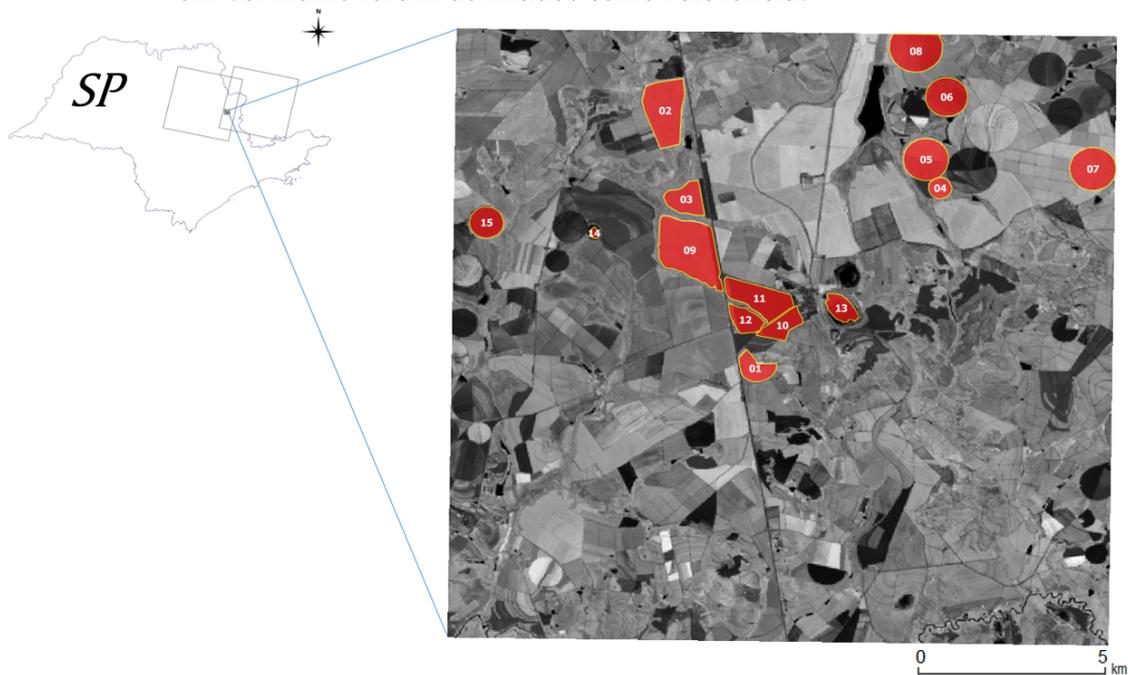
Figura 5.20 - Resultado da segmentação do Estudo de Caso 2 utilizando a distância DTW com a restrição global da janela de busca de Itakura. Os segmentos (contornos em amarelo) estão sobrepostos em uma imagem Landsat-8 OLI (R4G3B2)



5.3 Estudo de Caso 3: Área de sobreposição de imagens Landsat-8 em São Paulo

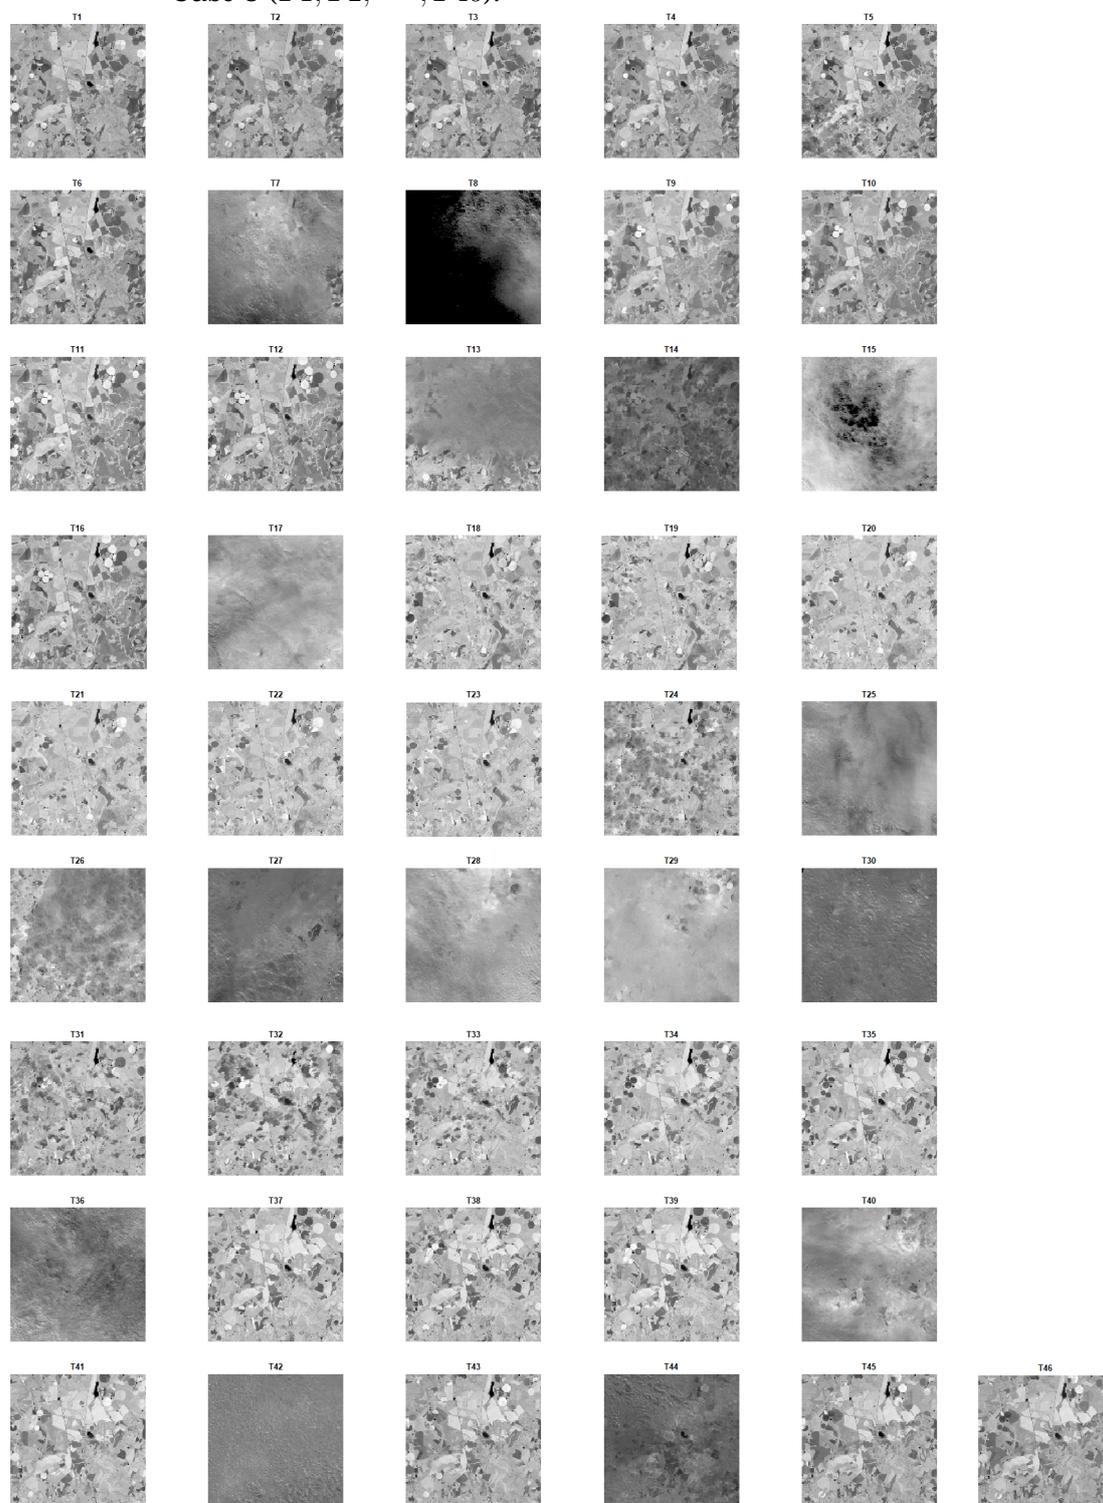
O terceiro estudo de caso foi conduzido em uma área de sobreposição de duas imagens Landsat-8 OLI (órbitas/pontos 219/75 e 220/75), fornecendo uma resolução temporal de 8 dias para os dados de entrada. A área de estudo está localizada em uma região centro-leste do estado de São Paulo (SP) (Figura 5.21). Foram utilizadas 46 imagens EVI entre julho de 2014 (Dia Do Ano - DDA 206) e julho de 2015 (DDA 229), com resolução espacial de 30 m (Figura 5.22).

Figura 5.21 - Área do Estudo de Caso 3. Imagem EVI Landsat-8 OLI. Os polígonos em vermelho foram utilizados como referência.



O Estudo de Caso 3 é uma extensão dos resultados do artigo intitulado "Spatio-Temporal Segmentation Applied to Optical Remote Sensing Image Time Series" (COSTA et al., 2018b). O trabalho foi publicado no periódico *IEEE Geoscience and Remote Sensing Letters*.

Figura 5.22 - Sequência de 46 imagens EVI (Landsat-8 OLI) utilizadas no Estudo de Caso 3 (T_1, T_2, \dots, T_{46}).

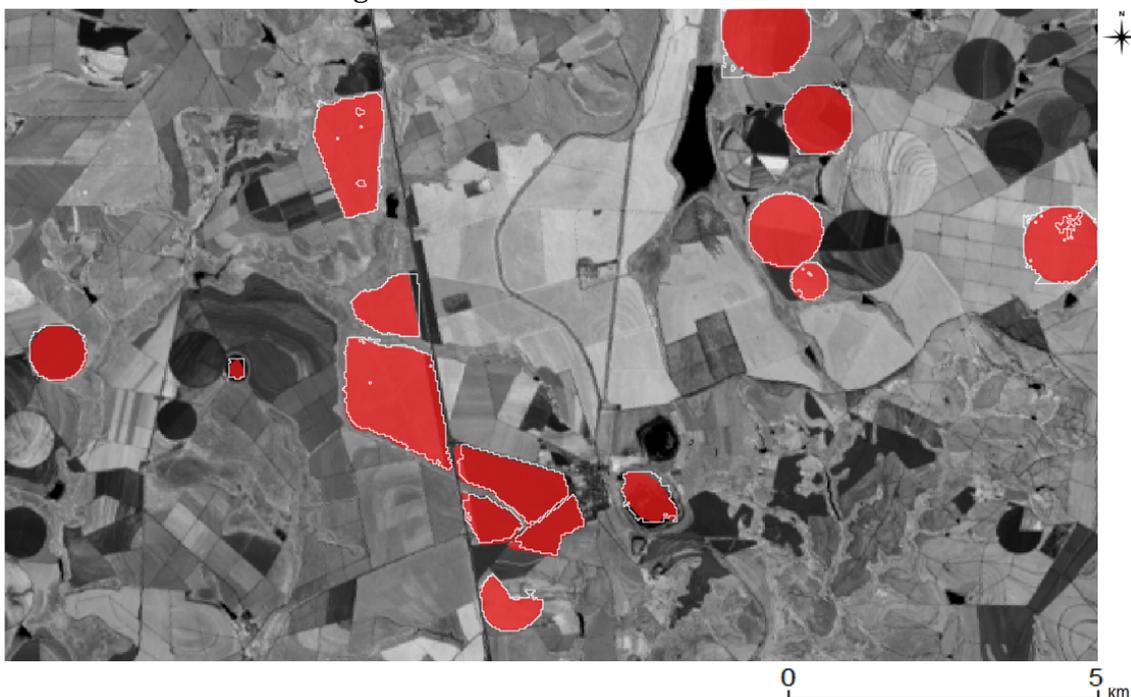


Foram utilizados 15 polígonos de referência baseados em alvos estáticos durante o ano da coleção de imagens de entrada. Os polígonos foram delineados por especialistas a partir de dados de campo e da foto-interpretção das imagens. As regiões representam culturas irrigadas por sistema de pivô (01, 04, 05, 06, 07, 08 e 15), áreas de silvicultura (02, 03, 09, 10, 11 e 12) e corpos d'água (13 e 14). Existem vários tipos de cultura durante o ano na região, tais como cana-de-açúcar, batata, milho e feijão, além de silvicultura. Geralmente, as culturas crescem em áreas irrigadas de maio a julho e são colhidas na primavera. As culturas de verão começam entre outubro e dezembro e a colheita ocorre de fevereiro a abril (BENDINI et al., 2016).

Para este estudo de caso, os segmentos foram analisados qualitativa e quantitativamente. Para isso, foram realizadas 15 segmentações independentes em vez de ser computada apenas uma segmentação para a imagem inteira. A partir do conjunto de imagens, ilustrado na Figura 5.22, foram criados 15 recortes de imagens para cada um dos polígonos de referência. Os recortes têm a dimensão do retângulo envolvente de cada referência. Os recortes foram considerados como dados de entrada independentes. Além disso, para cada segmentação foi definida apenas uma semente. A semente das 15 segmentações foi atribuída ao pixel referente ao centro do polígono de referência. O resultado é equivalente ao polígono criado a partir destas sementes. Com isso, para cada uma das 15 segmentações, o algoritmo irá gerar apenas um segmento por recorte de imagem.

Na Figura 5.23 estão expostos todos os resultados para a distância DTW. O limiar de similaridade para todos os segmentos foi definido empiricamente, neste caso para 0,06. O tempo de processamento deste estudo de caso não foi considerado para análise, visto que o algoritmo gerou as saídas em intervalos menores que milésimos de segundos. As Figuras 5.24 e 5.25 representam os resultados para as distâncias de Manhattan e Euclidiana, com limiares definidos para 3,5 e 0,7.

Figura 5.23 - Resultado da segmentação utilizando a distância DTW como critério de homogeneidade para os 15 polígonos. Os segmentos (contornos em branco) e os polígonos de referência (em vermelho) estão sobrepostos em uma imagem EVI Landsat-8 OLI.



Ao avaliar de forma qualitativa, os segmentos referentes aos polígonos 01, 03, 10, 12, 13 e 14 apresentaram formas semelhantes nos três testes. Visualmente, os segmentos resultantes referentes às áreas de pivô (01, 04, 05, 06, 07, 08 e 15), assim como os segmentos referentes às áreas de silvicultura 01, 09 e 11 apresentaram melhores resultados utilizando a distância DTW, ao observar a forma e o tamanho dos segmentos.

Em contrapartida, avaliar quantitativamente os resultados de uma segmentação é uma tarefa difícil, uma vez que não existe uma padronização de técnicas para este tipo de análise (EECKHAUT et al., 2012). Como os segmentos foram gerados de forma independente, um conjunto de métricas foi utilizado para quantificar a comparação entre os segmentos gerados pela técnica para cada uma das distâncias e a referência.

Figura 5.24 - Resultado da segmentação utilizando a distância de Manhattan como critério de homogeneidade para os 15 polígonos. Os segmentos (contornos em branco) e os polígonos de referência (em vermelho) estão sobrepostos em uma imagem EVI Landsat-8 OLI.

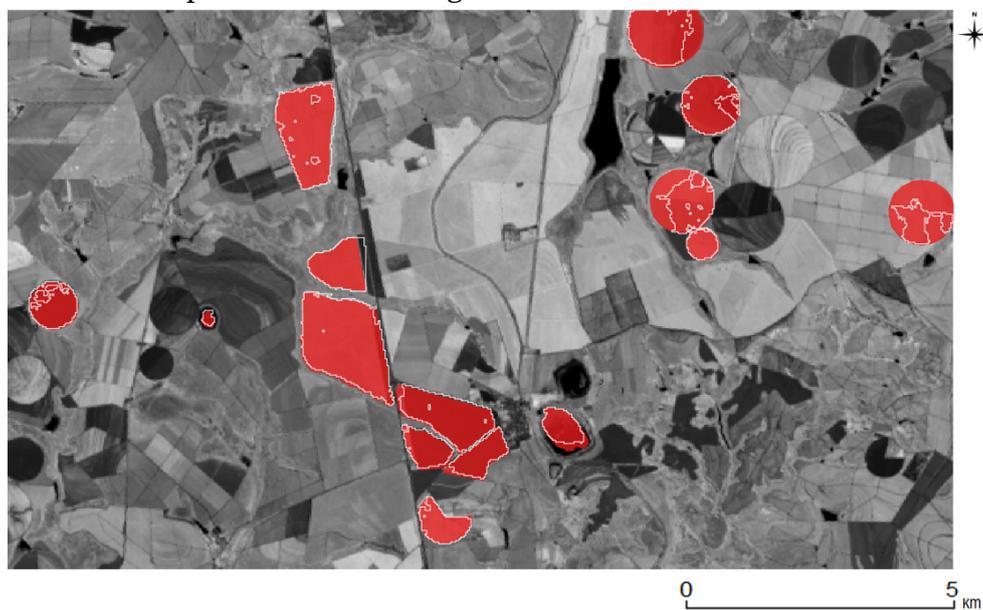
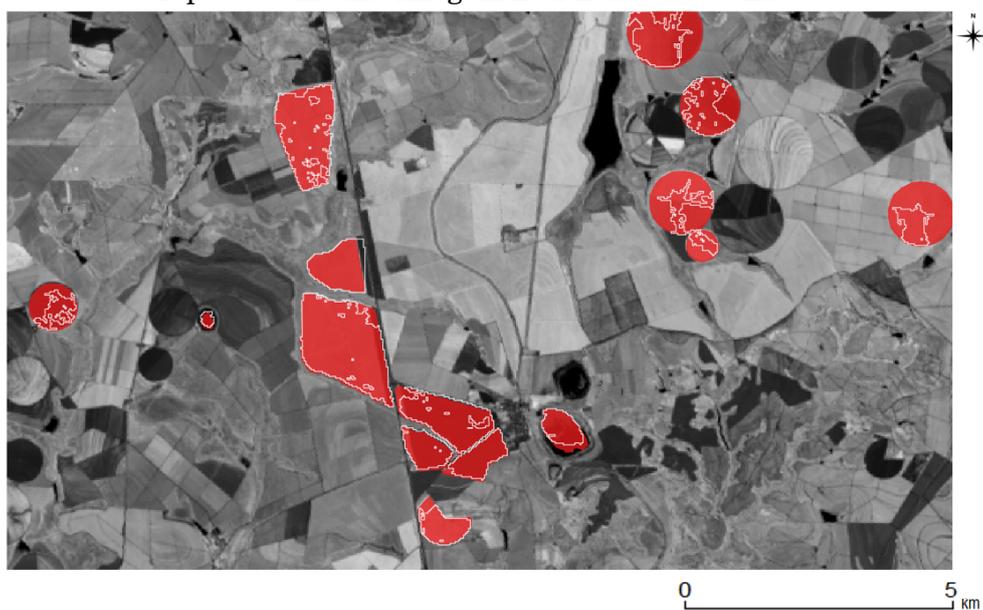


Figura 5.25 - Resultado da segmentação utilizando a distância Euclidiana como critério de homogeneidade para os 15 polígonos. Os segmentos (contornos em branco) e os polígonos de referência (em vermelho) estão sobrepostos em uma imagem EVI Landsat-8 OLI.



Duas métricas, (*GShape* e *FITXY*), propostas por Delves et al. (1992), além dos valores de *Accuracy*, *Precision*, *Recall* e *F-score* foram utilizadas na análise. Todas as métricas estão descritas na Seção 4.3 e variam de 0 a 1, onde 1 indica o melhor valor. A Tabela 5.5 contém os valores para todas as métricas para os três testes. Na Figura 5.26 estão ilustrados boxplots das métricas para comparação dos três testes.

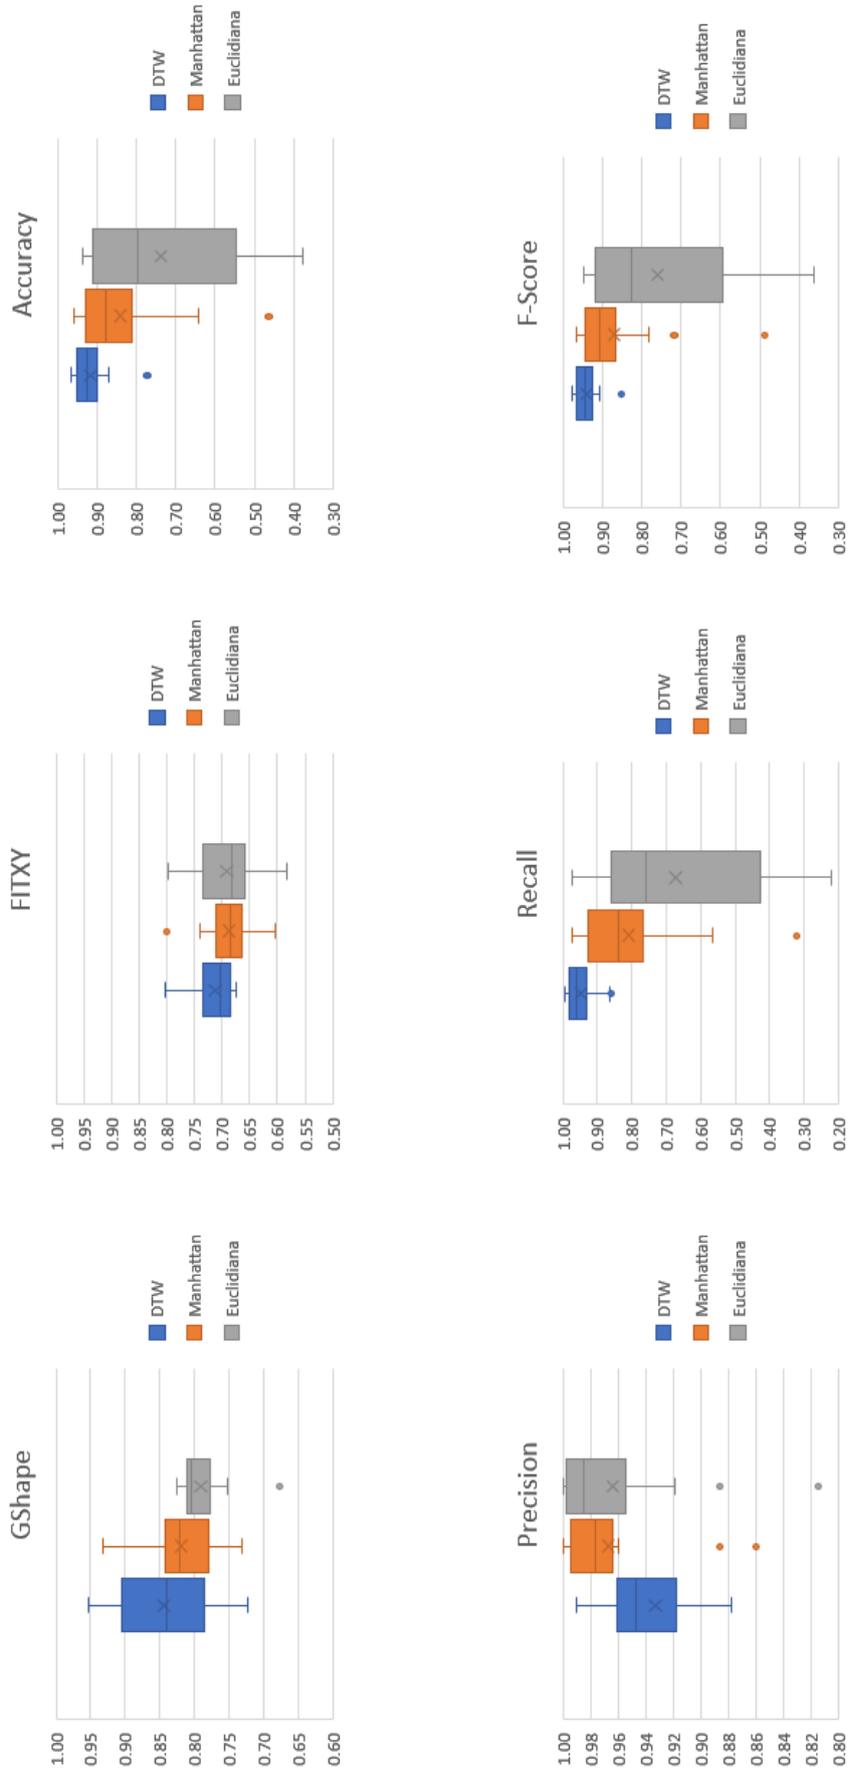
Analisando a média dos valores das métricas, a segmentação que utiliza a distância DTW apresenta a melhor média em todos os casos, com exceção para a métrica *Precision*. Na maioria dos casos, a segmentação com DTW apresentou valores maiores comparados com as técnicas utilizando as outras distâncias. Por exemplo, o valor de *GShape*, associado à comparação da forma dos polígonos, foi relativamente maior para os segmentos referentes a 01, 02, 04, 05, 06, 07, 09, 11 e 15. Com relação à métrica *FITXY*, os segmentos foram ligeiramente deslocados em relação à referência, o que reflete no decréscimo dos valores da métrica em todos os testes.

A segmentação usando DTW apresentou maior valor de *Accuracy* em todos os casos, com exceção dos segmentos referentes a 04 e 12, nos quais a técnica com distância de Manhattan obteve melhor resultado. Com relação à métrica *Precision*, apesar de os valores serem muito altos para as distâncias de Manhattan e Euclidiana (chegando até a 1 para os segmentos 07, 08 e 13), muitos dos segmentos gerados por esses dois testes são significativamente menores do que a referência e estão sobrepostos nela. Como estes segmentos estão totalmente sobrepostos à referência, o valor de *Precision* chega ao máximo. Para contornar este problema, calcula-se o *F-Score*, correspondente à média harmônica entre as medidas *Precision* e *Recall*, levando em consideração tanto os falsos positivos quanto os falsos negativos. Os valores médios obtidos de *Recall* e *F-Score* estão mais altos para a segmentação usando DTW, principalmente se comparados ao resultado médio da técnica ao usar a distância Euclidiana.

Tabela 5.5 - Sumário dos resultados quantitativos para cada referência do Estudo de Caso 3.

Métrica	Distância	01	02	03	04	05	06	07	08	09	10	11	12	13	14	15	Média
<i>GShape</i>	DTW	0,837	0,827	0,753	0,911	0,954	0,867	0,948	0,773	0,885	0,825	0,829	0,770	0,844	0,722	0,922	0,844
	Manhattan	0,823	0,813	0,753	0,819	0,883	0,830	0,933	0,764	0,847	0,826	0,814	0,769	0,844	0,731	0,837	0,819
	Euclidiana	0,804	0,806	0,752	0,805	0,813	0,802	0,761	0,802	0,825	0,813	0,774	0,808	0,677	0,807	0,813	0,791
<i>FITXY</i>	DTW	0,716	0,709	0,741	0,695	0,683	0,684	0,763	0,674	0,702	0,680	0,756	0,707	0,803	0,689	0,690	0,713
	Manhattan	0,731	0,629	0,740	0,686	0,662	0,638	0,674	0,696	0,682	0,702	0,681	0,713	0,679	0,800	0,605	0,688
	Euclidiana	0,718	0,668	0,740	0,595	0,658	0,583	0,662	0,695	0,665	0,702	0,777	0,770	0,673	0,798	0,658	0,691
<i>Accuracy</i>	DTW	0,960	0,945	0,901	0,870	0,960	0,949	0,884	0,918	0,965	0,932	0,949	0,912	0,897	0,773	0,931	0,916
	Manhattan	0,940	0,927	0,900	0,915	0,641	0,847	0,464	0,801	0,958	0,927	0,947	0,921	0,857	0,727	0,842	0,841
	Euclidiana	0,902	0,885	0,900	0,505	0,377	0,697	0,399	0,635	0,936	0,931	0,911	0,915	0,856	0,705	0,517	0,738
<i>Precision</i>	DTW	0,941	0,958	0,882	0,954	0,986	0,951	0,922	0,916	0,985	0,990	0,961	0,956	0,878	0,770	0,943	0,933
	Manhattan	0,996	0,966	0,886	0,964	0,973	0,979	1,000	1,000	0,989	0,990	0,964	0,960	1,000	0,860	0,980	0,967
	Euclidiana	0,998	0,977	0,886	0,919	0,992	0,980	1,000	1,000	0,992	0,990	0,960	0,952	0,997	0,815	1,000	0,964
<i>Recall</i>	DTW	0,992	0,966	0,981	0,863	0,964	0,988	0,932	0,994	0,960	0,861	0,935	0,895	0,979	0,950	0,969	0,949
	Manhattan	0,898	0,931	0,973	0,918	0,567	0,829	0,323	0,763	0,945	0,851	0,928	0,907	0,782	0,717	0,813	0,810
	Euclidiana	0,830	0,861	0,973	0,351	0,223	0,638	0,241	0,564	0,908	0,859	0,856	0,905	0,782	0,733	0,379	0,674
<i>F-Score</i>	DTW	0,966	0,962	0,929	0,906	0,975	0,969	0,927	0,953	0,972	0,921	0,948	0,924	0,926	0,851	0,956	0,939
	Manhattan	0,944	0,949	0,928	0,940	0,717	0,898	0,488	0,865	0,967	0,915	0,946	0,933	0,878	0,782	0,889	0,869
	Euclidiana	0,906	0,915	0,928	0,507	0,364	0,773	0,389	0,722	0,948	0,920	0,905	0,928	0,877	0,772	0,550	0,760

Figura 5.26 - Boxplot das métricas analisadas para as 15 segmentações do Estudo de Caso 3. Os pontos marcados em X representam o valor médio de cada métrica para cada experimento.

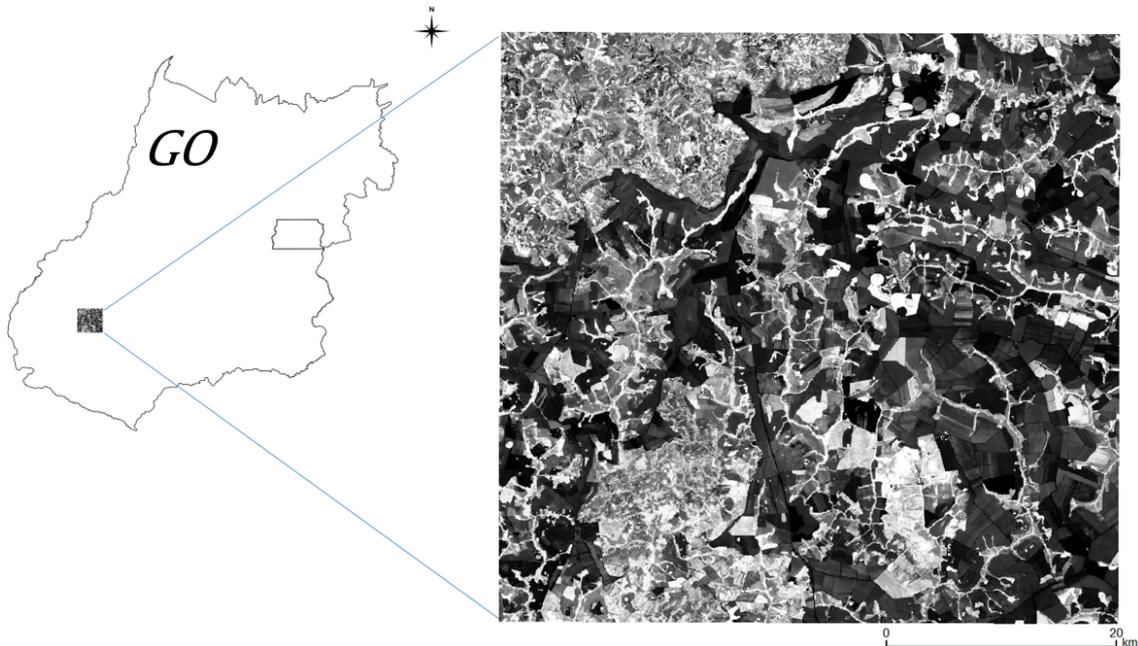


5.4 Estudo de Caso 4: Análise do Tempo Computacional

Os Estudos de Caso 1, 2 e 3 utilizaram como dados de entrada seqüências de imagens com dimensões pequenas. Em consequência disso, o maior tempo de processamento obtido foi de 183 segundos (Estudo de Caso 1 utilizando o DTW clássico como critério de homogeneidade). Fatores como processos em paralelo, entrada e saída de dados, chamadas de sub-rotinas do sistema operacional e a quantidade de processos em cache na memória podem afetar o valor do tempo de processamento de um algoritmo, especialmente em programas com tempo de execução muito baixo. Assim, a técnica de segmentação proposta foi aplicada utilizando uma seqüência de imagens de tamanho maior.

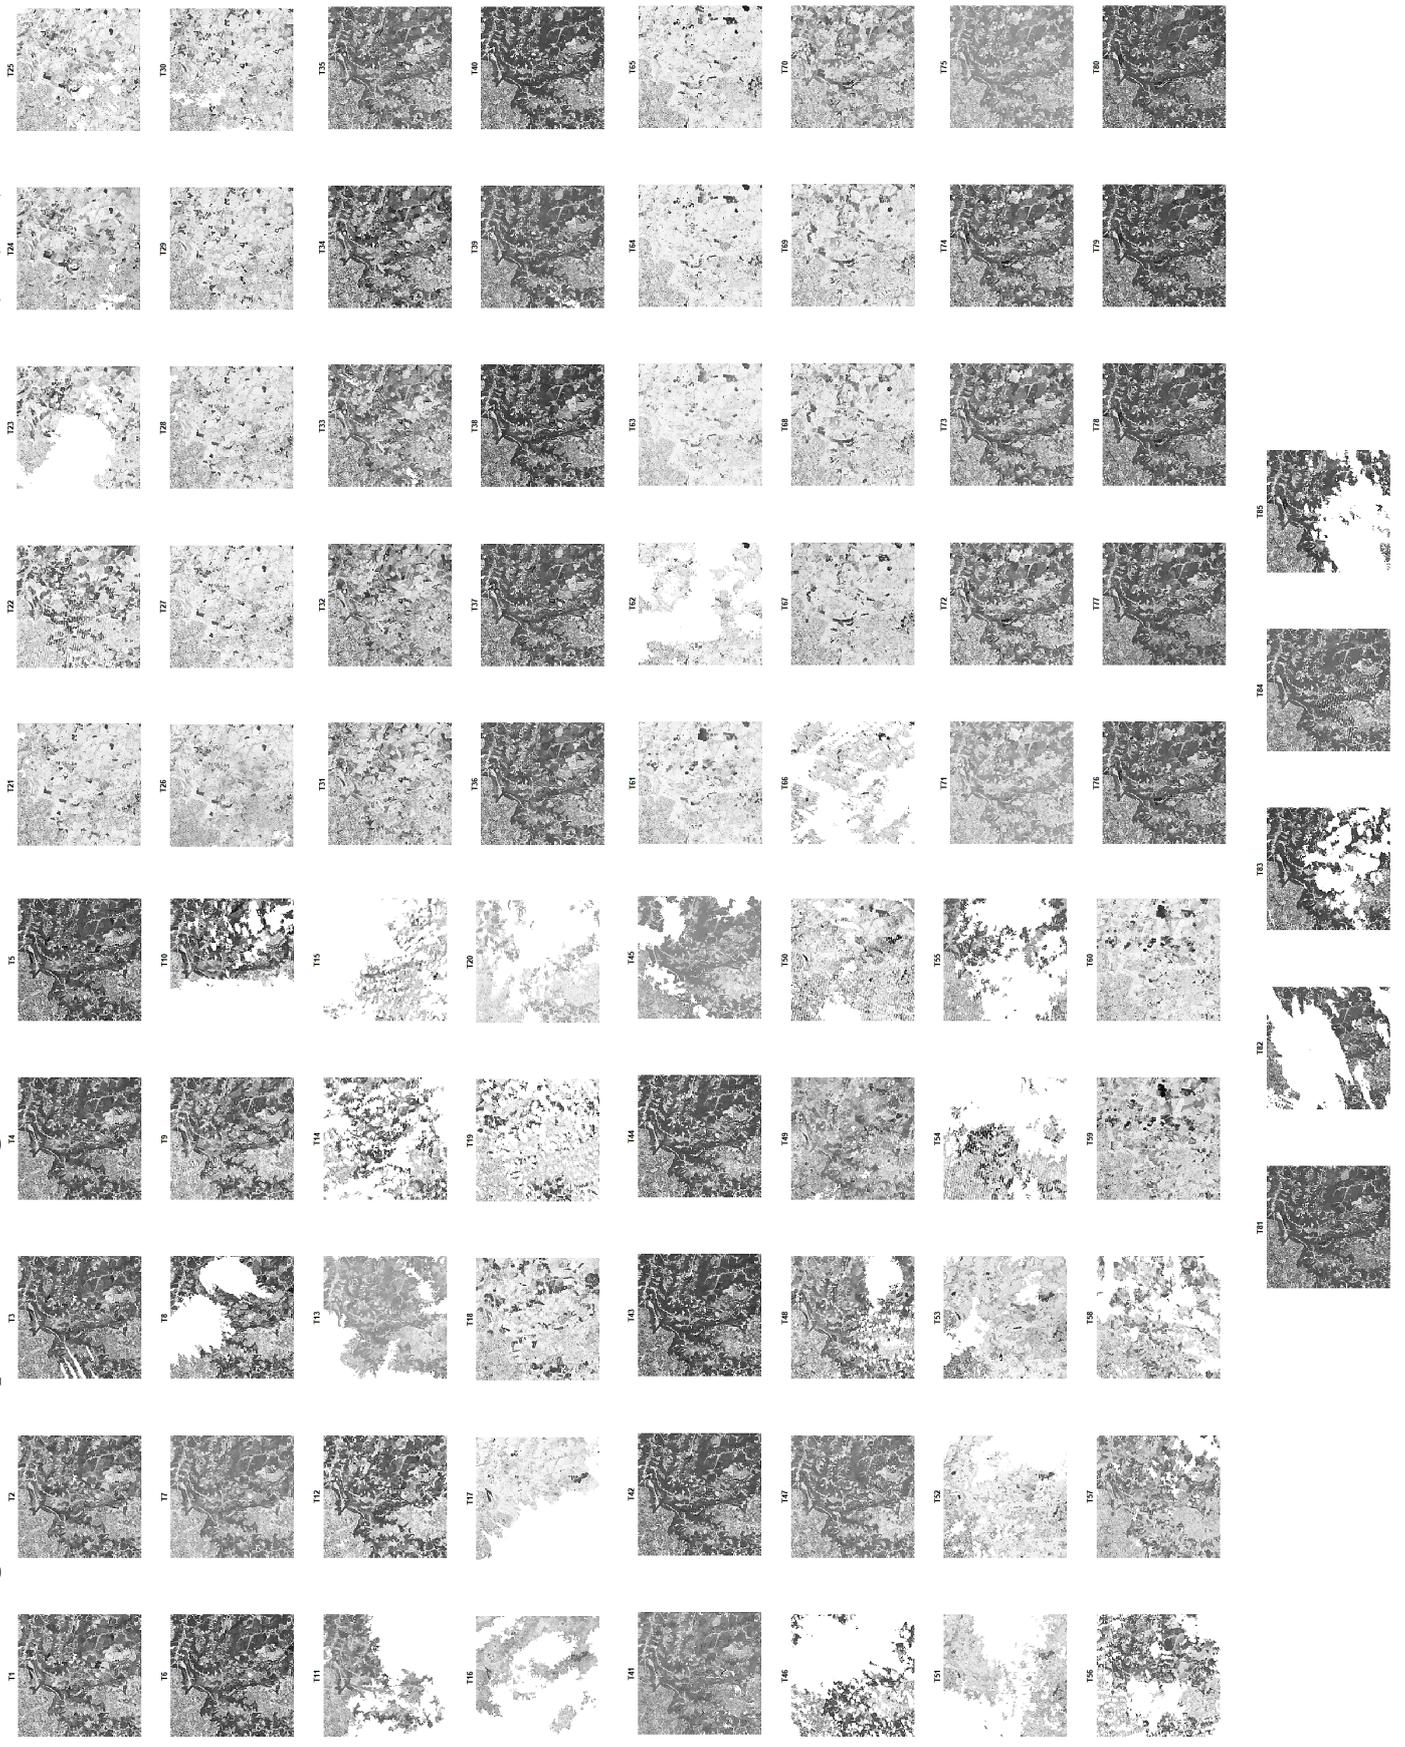
A área de estudo corresponde a uma região sudoeste do estado de Goiás (Figura 5.27). Uma seqüência de 85 imagens NDVI Landsat-8 e Landsat-7 intercaladas foi utilizada, conforme Figura 5.28.

Figura 5.27 - Área do Estudo de Caso 4. Primeira imagem NDVI Landsat-8 OLI da seqüência de dados de entrada.



A compatibilização entre as imagens Landsat-8 e Landsat-7, além do preenchimento das falhas das imagens Landsat-7, foram feitas a partir da

Figura 5.28 - Sequência de 85 imagens NDVI (Landsat-8 OLI) utilizadas no Estudo de Caso 4 (T1, T2, ..., T85).



aplicação dos algoritmos propostos em [Marujo et al. \(2017a\)](#), [Marujo et al. \(2017b\)](#). As imagens têm dimensão de 1666×1666 pixels, com resolução espacial de 30 m e resolução temporal de 8 dias. As imagens foram coletadas entre o período de 2 de fevereiro de 2015 e 26 de outubro de 2017.

Três testes foram realizados utilizando as distâncias DTW, Euclidiana e Manhattan como critério de homogeneidade. Os limiares de similaridade para os três testes foram definidos de forma que não ocorresse super ou sobre-segmentação. Com isso, o crescimento de regiões, e o consequente cômputo de várias distâncias entre as sementes e os pixels vizinhos apresentaram comportamento similar nos três testes, separando alvos distintos, como regiões de agricultura e vegetação nativa.

Na Figura 5.29 está ilustrado o resultado da segmentação utilizando a distância DTW. O limiar de similaridade foi definido como 0,06 e o de área como 50000 m^2 . Os limiares para os resultados com as distâncias de Manhattan e Euclidiana foram definidos como 6,2 e 2,3, respectivamente.

Na Tabela 6.6 são exibidos os tempos obtidos para todos os testes deste estudo de caso. O mesmo conjunto de sementes e a mesma ordem de processamento das sementes foram utilizados nos três testes. A distância DTW necessita fazer o cômputo da matriz entre as duas séries temporais para calcular o alinhamento, que acarreta num custo computacional um pouco mais elevado do que realizar operações simples como a diferença absoluta (Manhattan) ou a distância Euclidiana. Na Tabela 5.4 estão ilustrados os tempos computacionais dos Estudos de Caso 1, 2 e 4 utilizando a distância DTW, onde pode ser observado o alto custo computacional que a segmentação multitemporal baseada em crescimento de regiões exige ao aumentar a quantidade de pixels a serem analisados pelo algoritmo.

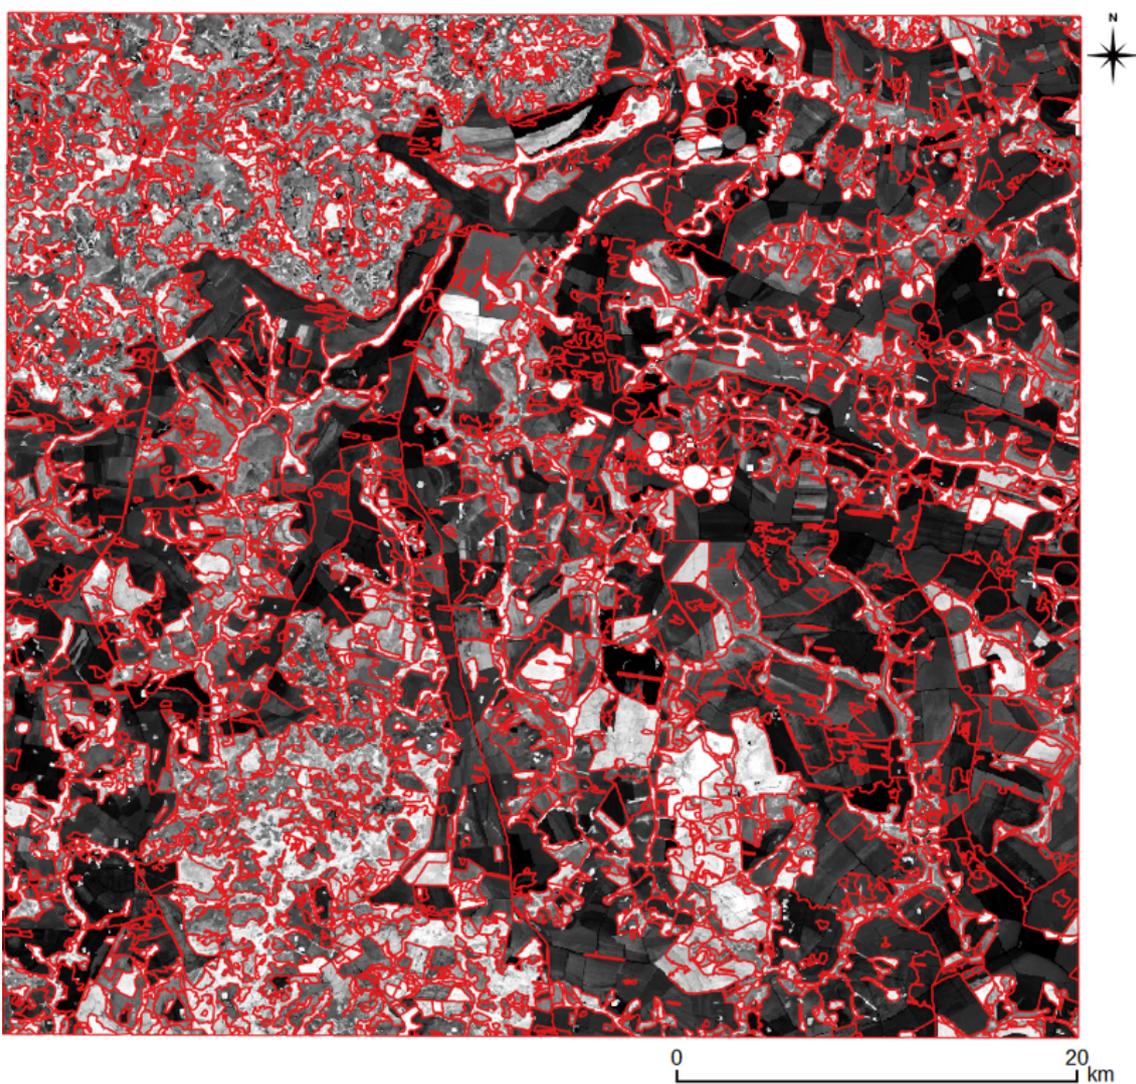
Tabela 5.6 - Tempo computacional de cada distância analisada no Estudo de Caso 4.

Distância	Tempo (horas)
DTW	20,66
Euclidiana	20,06
Manhattan	17,77

Tabela 5.7 - Tempo computacional dos Estudos de Caso 1, 2 e 4 utilizando a distância DTW como critério de homogeneidade.

Estudo de Caso	Dimensão x N. Imagens	Número de Pixels	Tempo (s) - DTW
Estudo de Caso 1	189x161 x 44	1.338.876	183
Estudo de Caso 2	155x132 x 27	552.420	143
Estudo de Caso 4	1666x1666 x 85	235.922.260	74376

Figura 5.29 - Resultado da segmentação utilizando a distância DTW como critério de homogeneidade para o Estudo de Caso 4. Os segmentos (contornos em vermelho) estão sobrepostos em uma imagem NDVI Landsat-8 OLI.



Os valores obtidos para os testes confirmaram um custo computacional da distância DTW um pouco maior que as outras distâncias. A segmentação usando DTW necessitou de mais 0,6 horas (36 min) em relação à distância Euclidiana e de mais 2,89 horas em relação à distância de Manhattan para gerar a saída do algoritmo para o estudo de caso 4. Pode-se inferir que o processo do crescimento de regiões do segmentador deve ser levado em consideração no peso do custo total do algoritmo, uma vez que a diferença entre as distâncias DTW e Euclidiana apresentaram apenas uma diferença de 3%.

No entanto, apesar de a técnica proposta utilizando a distância DTW como critério de homogeneidade ter alto custo computacional, esta apresentou os melhores resultados nas avaliações qualitativas e quantitativas nos estudos de caso que possuíam polígonos de referência para comparação.

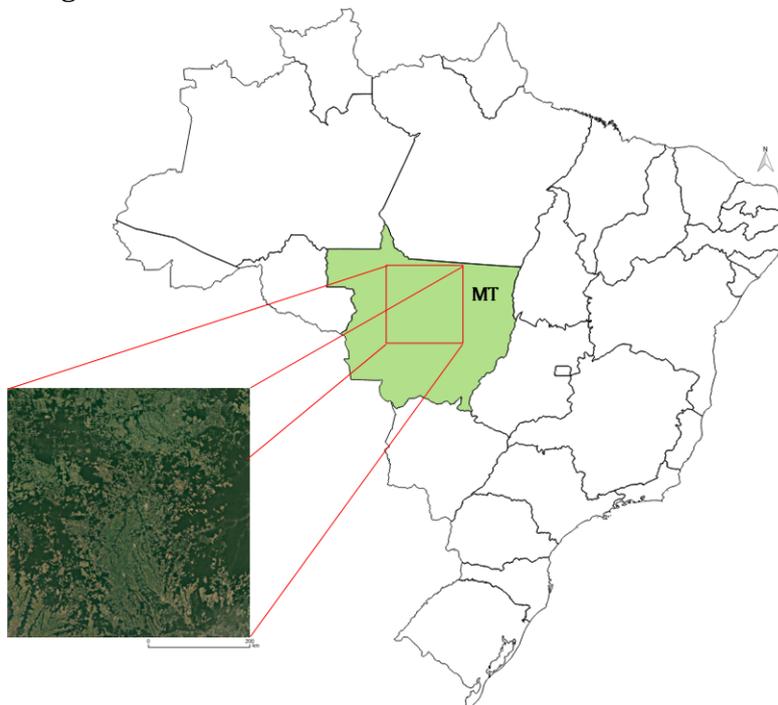
5.5 Estudo de Caso 5: Análise da segmentação em imagens MODIS

O estudo dessa região foi realizado com o propósito de observar a resposta da segmentação para imagens que contêm simultaneamente regiões que apresentam propriedades homogêneas em relação a algumas regiões adjacentes (por exemplo, regiões contíguas de agricultura de diferentes culturas) e propriedades heterogêneas para outras (regiões de agricultura, vegetação nativa e área urbana) numa mesma cena. O resultado esperado da segmentação deve conter objetos cujos pixels apresentaram propriedades similares durante os 4 anos analisados. A área de estudo corresponde a uma região no centro-oeste brasileiro, localizada no estado do Mato do Grosso (MT) e ilustrada na Figura 5.30.

Como dados de entrada, foi utilizada uma sequência de 92 imagens obtidas a partir do sensor MODIS no período de janeiro de 2010 a dezembro de 2013 (23 imagens por ano), com correção atmosférica. Cada pixel corresponde a um valor do índice de vegetação NDVI. As imagens contêm dimensão de 2000×2000 pixels, com resolução espacial de 250 m e resolução temporal de 16 dias. A região cobre uma área de 250.000 m^2 e contém áreas de vegetação nativa e agricultura. A resolução espacial das imagens é baixa e cada pixel representa uma área de 62.500 m^2 .

Na Figura 5.31 é ilustrado o resultado da segmentação, utilizando o limiar de similaridade equivalente a 0,05. Como a área de cada pixel representa

Figura 5.30 - Localização da área de estudo do exemplo de aplicação da metodologia. Imagem Landsat-8 (R4G3B2).



250m×250m, o limiar de área foi desconsiderado, de modo que o algoritmo possa gerar segmentos de até 1 pixel. Neste caso, a avaliação da segmentação foi realizada baseada na fotointerpretação da imagem de satélite, comparando o resultado da segmentação sobreposto a uma imagem Landsat-8 (R4G3B2) coletada no dia mais próximo à última imagem da sequência utilizada como entrada.

Observando os segmentos resultantes do método proposto, nota-se que o limiar de similaridade adotado permitiu fazer a distinção de áreas adjacentes heterogêneas, correspondentes a regiões de vegetação nativa, agricultura e área urbana. Além disso, para este experimento, o segmentador provocou a generalização e conseqüente sub-segmentação das regiões de agricultura da área de estudo. Visualmente, as regiões segmentadas representam grupos de geo-objetos de tamanhos similares, tais como árvores, áreas residenciais e campos de agricultura de diferentes culturas. O conjunto de dados de entrada está representado na Figura 5.32.

Figura 5.31 - Resultado da segmentação (contornos em vermelho) para o exemplo de aplicação da metodologia. Os segmentos resultantes foram sobrepostos em uma imagem Landsat-8 (R4G3B2). A área ampliada à direita indica que o método proposto distinguiu regiões de áreas urbanas (centro), de vegetação nativa e de agricultura.

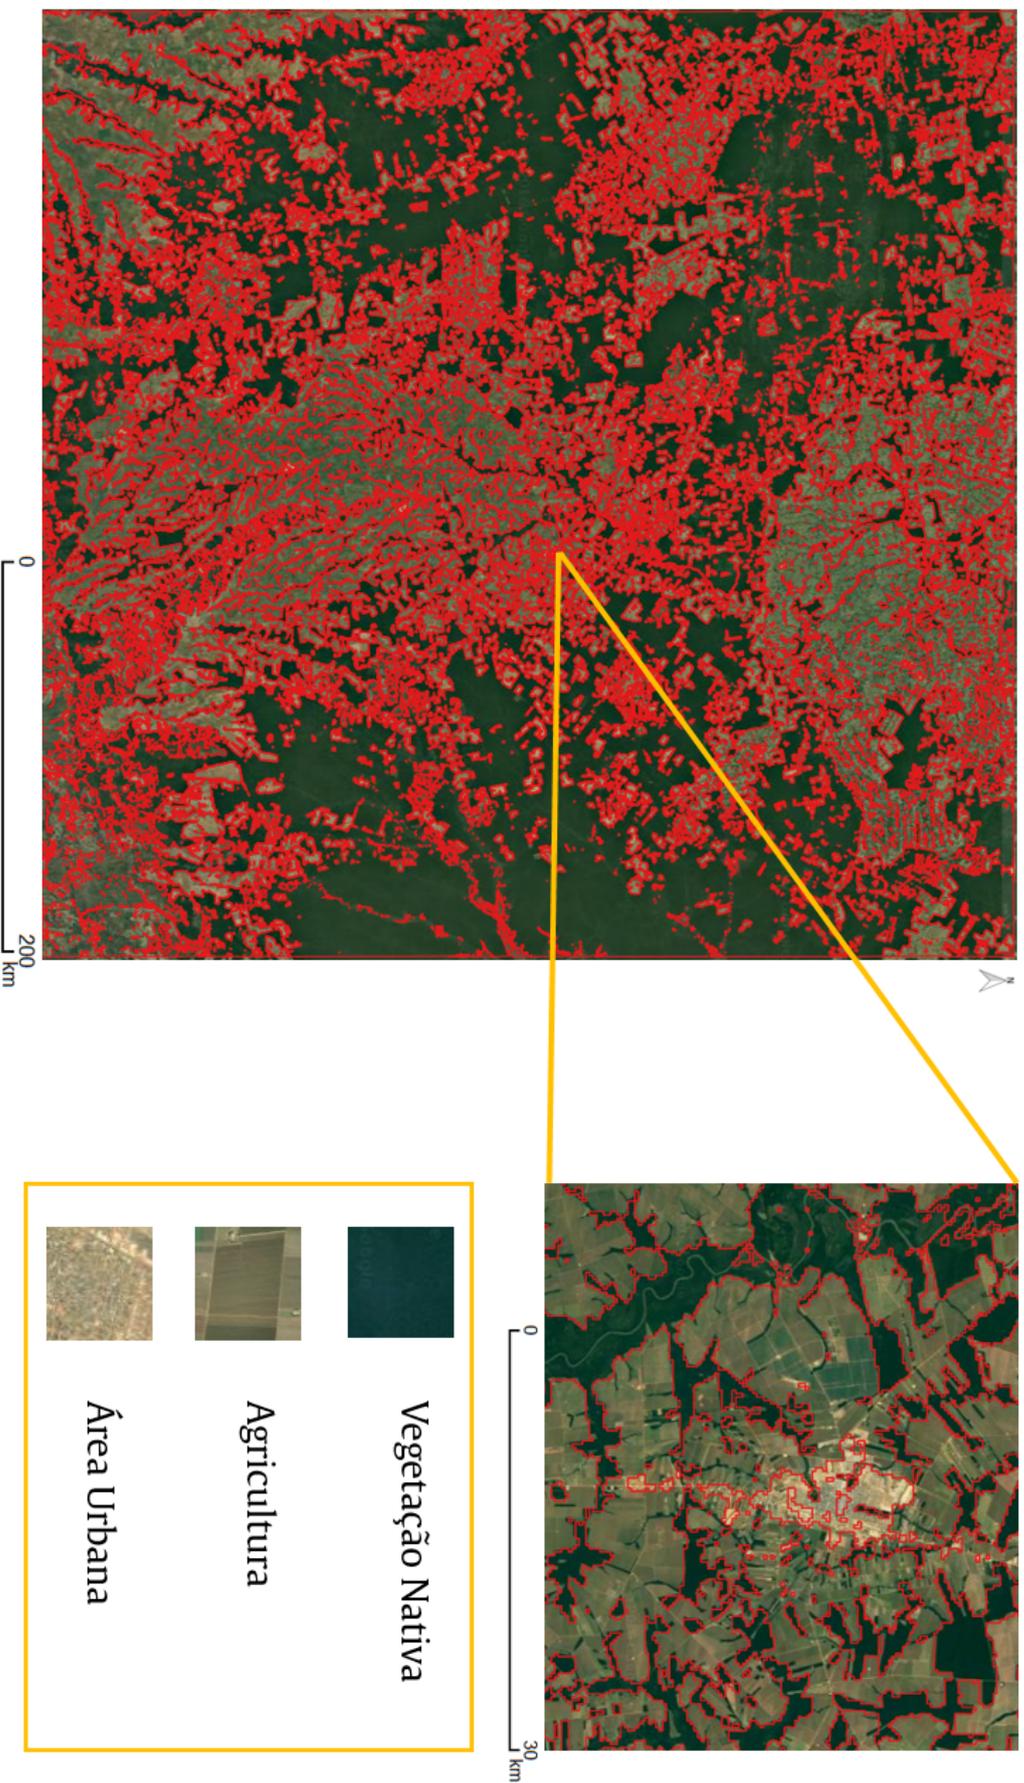
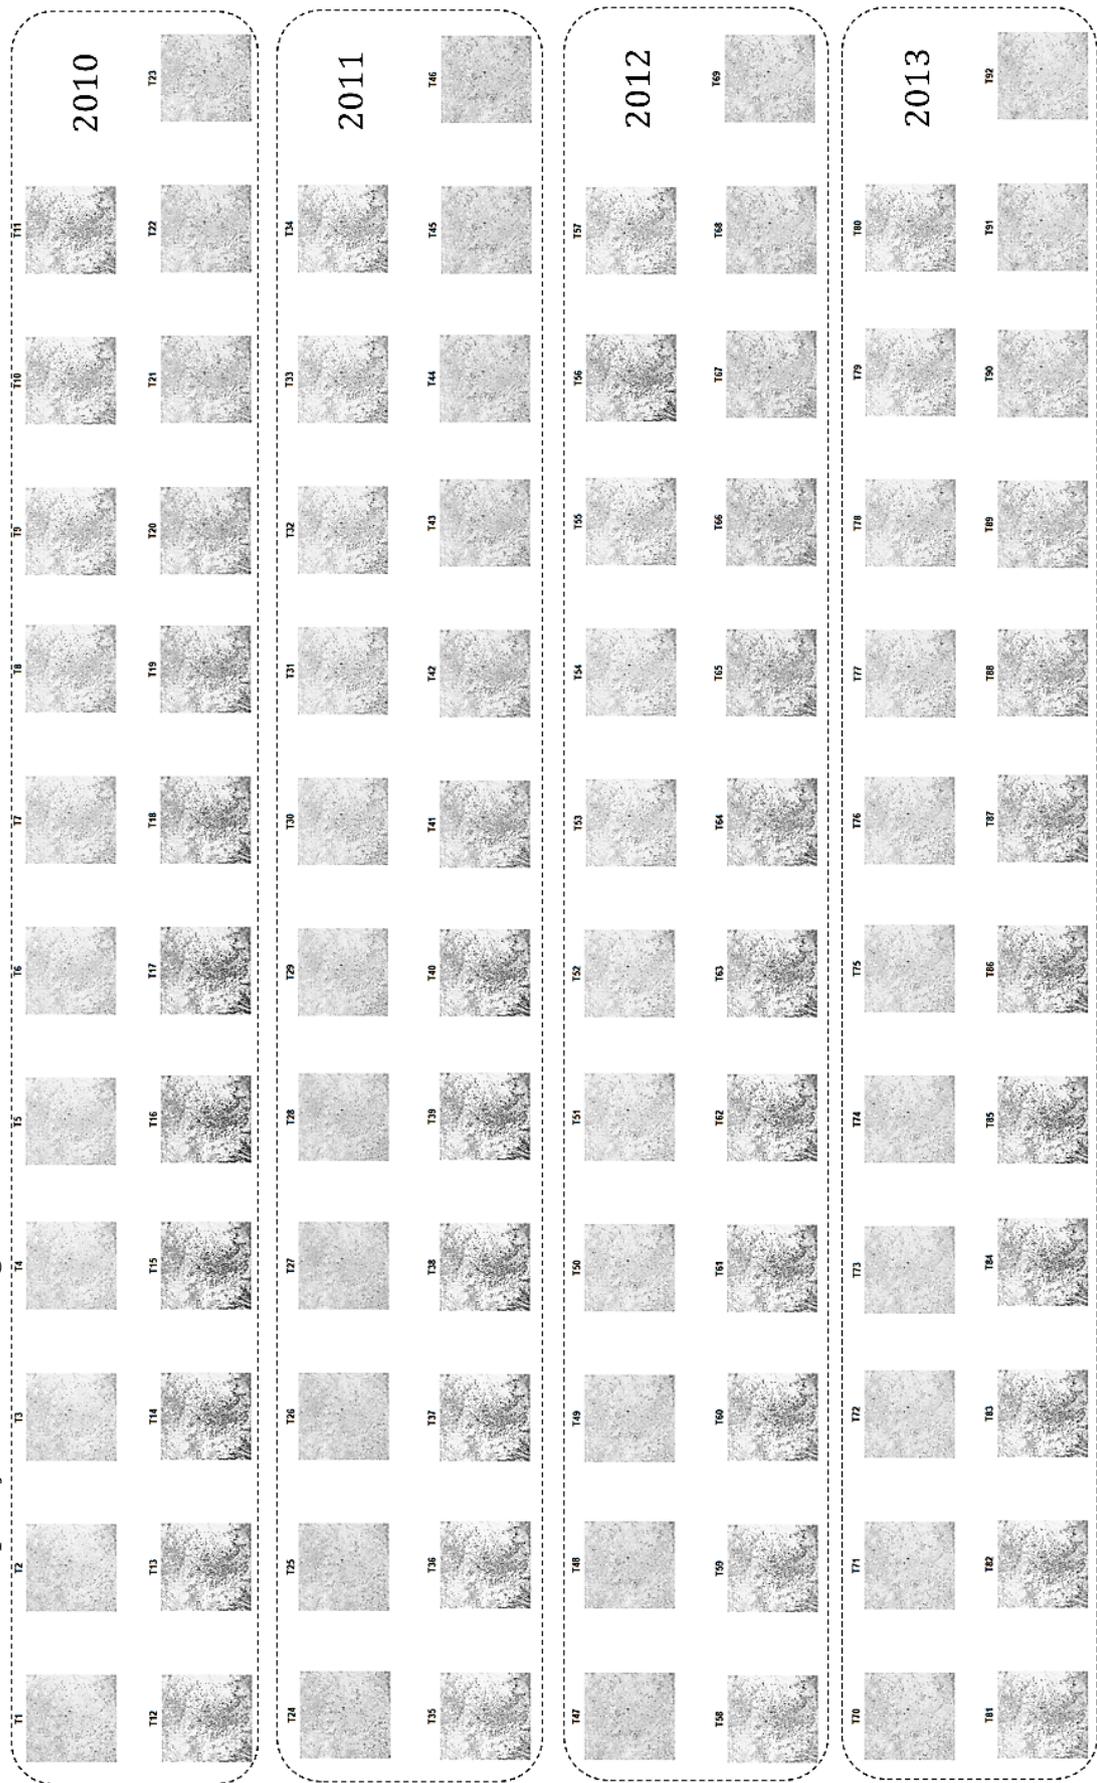


Figura 5.32 - Conjunto de 92 imagens NDVI (T_1, T_2, \dots, T_{92}) com correção atmosférica utilizadas como dados de entrada para o exemplo de aplicação da metodologia.



6 CONSIDERAÇÕES FINAIS

Os estudos de técnicas de segmentação mais recentes têm dado atenção à alta resolução espacial das imagens, enquanto que, até o momento, existem poucos estudos utilizando grandes sequências de imagens multitemporais. Todavia, é importante ressaltar que o uso da dimensão temporal aumenta a complexidade do processamento se comparado com a segmentação tradicional.

Dentro deste contexto, este trabalho teve o objetivo de desenvolver um algoritmo de segmentação espaço-temporal para detecção de regiões com propriedades homogêneas durante um determinado período de tempo. A estratégia de análise para a construção da hipótese deu-se a partir da adaptação do algoritmo tradicional de segmentação por crescimento de regiões, possibilitando a melhoria do critério de homogeneidade para considerar, além das propriedades espaciais e espectrais, o domínio temporal. A distância DTW, uma das medidas mais utilizadas para quantificar a similaridade entre duas séries temporais, foi proposta como critério de homogeneidade do algoritmo.

A segmentação utilizando DTW como critério de homogeneidade foi implementada na linguagem R. O processo de avaliação qualitativa e quantitativa foi realizado com o auxílio do sistema de informações geográficas QGIS e da linguagem Python.

Cinco estudos de caso foram conduzidos, utilizando sequências de imagens MODIS, Landsat-8 e Landsat-7 como dados de entrada dos experimentos. Índices NDVI e EVI provenientes destes sensores foram utilizados para criação das séries temporais analisadas pelo algoritmo proposto.

Os resultados da segmentação utilizando a distância DTW como critério de homogeneidade foram comparados com resultados utilizando as distâncias de Manhattan e Euclidiana. Os resultados para as três distâncias foram avaliados qualitativamente, comparando os segmentos gerados com os polígonos de referência. Além disso, as métricas *GShape*, *FITXY*, *Accuracy*, *Precision*, *Recall* e *F-Score* foram usadas para avaliar quantitativamente os segmentos gerados em um dos estudos de caso. Em todos os estudos de caso que continham polígonos de referência, os resultados utilizando a distância DTW clássica obtiveram o melhor desempenho em relação à qualidade dos segmentos. O segmentador proposto também obteve os melhores resultados

em todas as métricas calculadas no Estudo de Caso 3, com exceção da métrica *Precision*, o que pode ser justificado devido a alguns segmentos gerados usando a distância Euclidiana e Manhattan serem significativamente menores do que a referência.

No tocante ao tempo de processamento, a segmentação utilizando DTW como critério de homogeneidade apresentou um custo computacional um pouco mais alto para geração dos segmentos comparados com as distâncias de Manhattan e Euclidiana. O alto custo computacional está relacionado a fatores como o processo de crescimento de regiões do segmentador e o cômputo da matriz entre as séries temporais para obtenção do alinhamento global ótimo. Além disso, testes utilizando a distância DTW com as restrições globais de janelas de busca de Sakoe-Chiba e Itakura foram feitos. Apesar de obter uma leve redução no tempo de processamento, houve uma redução da qualidade dos segmentos se comparados com a distância DTW clássica.

Logo, como o método proposto é baseado na técnica de crescimento de regiões, o algoritmo contém algumas desvantagens. Além do alto custo computacional, diferentes conjuntos de sementes e a ordem de processamento das sementes, por exemplo, causam resultados diferentes na segmentação.

De forma geral, os estudos de casos demonstraram o potencial do trabalho proposto em tratar séries temporais com ruído geradas por imagens de diferentes sensores. Como trabalhos futuros, a segmentação será aplicada em dados de entrada com resoluções temporais e espaciais mais finas. Além disso, outros índices podem ser investigados como valor do pixel das imagens para criação das séries temporais para diferentes aplicações.

Apesar de os resultados do método proposto terem sido comparados com o algoritmo de segmentação de crescimento regiões clássico (distância Euclidiana), comparações com métodos recentes de segmentação com dados temporais podem ser investigadas. Ademais, como a definição da localização das sementes e dos limiares foram definidos empiricamente, técnicas de ajustes de parâmetros podem ser estudadas para aprimoramento do algoritmo.

REFERÊNCIAS BIBLIOGRÁFICAS

ADAMS, R.; BISCHOF, L. Seeded region growing. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 16, n. 6, p. 641–647, 1994. [3](#), [11](#), [12](#), [35](#)

BAATZ, M.; SCHÄPE, A. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. In: ANGEWANDTE GEOGRAPHISCHE INFORMATIONSVERRARBEITUNG XII, 12., 2000, Karlsruhe. **Proceedings...** Karlsruhe: Wichmann-Verlag, Heidelberg, 2000. p. 12–23. [12](#), [19](#), [38](#)

BENDINI, H. N.; SANCHES, I. D.; KÖRTING, T. S.; FONSECA, L. M. G.; LUIZ, A. J. B.; FORMAGGIO, A. R. Using Landsat 8 Image Time Series for Crop Mapping in a Region of Cerrado, Brazil. **ISPRS Journal of Photogrammetry and Remote Sensing**, p. 845–850, 2016. [68](#)

BERNDT, D. J.; CLIFFORD, J. Using dynamic time warping to find patterns in time series. In: WORKSHOP ON KNOWLEDGE DISCOVERY IN DATABASES, 10., 1994, Seattle. **Proceedings...** AAAI Press, 1994. p. 359–370. [26](#)

BEUCHER, S. The watershed transformation applied to image segmentation. **Scanning Microscopy Supplement**, n. 6, p. 299–325, 1992. [14](#)

BINS, L. S.; FONSECA, L. M. G.; ERTHAL, G. J.; II, F. M. Satellite imagery segmentation: a region growing approach. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8., 1996, Salvador, BA. **Anais...** São José dos Campos: INPE, 1996. p. 677–680. [8](#), [12](#), [13](#)

BLASCHKE, T. Towards a framework for change detection based on image objects. **Göttinger Geographische Abhandlungen**, v. 113, p. 1–9, 2005. [3](#), [16](#), [17](#), [18](#)

_____. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65, n. 1, p. 2–16, 2010. [1](#), [16](#), [17](#)

BONTEMPS, S.; BOGAERT, P.; TITEUX, N.; DEFOURNY, P. An object-based change detection method accounting for temporal dependences

in time series with medium to coarse spatial resolution. **Remote Sensing of Environment**, v. 112, n. 6, p. 3181–3191, 2008. 3, 19

BORIAH, S. **Time series change detection: algorithms for land cover change**. 2010. 160 p. Tese (Doutorado em Filosofia) — University of Minnesota, Minneapolis, 2010. 2, 19, 21

BORIAH, S.; KUMAR, V.; STEINBACH, M.; POTTER, C.; KLOOSTER, S. Land cover change detection. In: ACM SIGKDD INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING, 14., 2008. **Proceedings...** New York, New York, USA: ACM Press, 2008. p. 857. ISBN 9781605581934. ISSN 1477-9145. Disponível em: <<http://dl.acm.org/citation.cfm?id=1401993><http://dl.acm.org/citation.cfm?doid=1401890.1401993>>. 16, 21

BOULILA, W.; FARAH, I. R.; ETTABAA, K. S.; SOLAIMAN, B.; GHÉZALA, H. B. A data mining based approach to predict spatiotemporal changes in satellite images. **International Journal of Applied Earth Observation and Geoinformation**, v. 13, n. 3, p. 386–395, 2011. 22

BRAZIL MINISTÉRIO DA AGRICULTURA. **Sectoral plan for climate mitigation and adaptation**. Brasília: MA, 2011. (Relatório Técnico). 43

CHANT, T. D.; KELLY, M. Individual object change detection for monitoring the impact of a forest pathogen on a hardwood forest. **Photogrammetric Engineering & Remote Sensing**, v. 75, n. 8, p. 1005–1013, 2009. 16

CHENG, H.; JIANG, X.; SUN, Y.; WANG, J. Color image segmentation: advances and prospects. **Pattern Recognition**, v. 34, n. 12, p. 2259–2281, dec 2001. ISSN 00313203. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0031320300001497>>. 8, 9, 10

CHU, S.; KEOGH, E.; HART, D.; PAZZANI, M. Iterative deepening dynamic time warping for time series. In: SIAM INTERNATIONAL CONFERENCE ON DATA MINING. **Proceedings...** Philadelphia, PA: SIAM, 2002. p. 195–212. ISBN 978-0-89871-517-0. 27

COHEN, W. B.; GOWARD, S. N. Landsat's role in ecological applications of remote sensing. **BioScience**, v. 54, n. 6, p. 535–545, 2004. 23

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. ISBN 0-8186-7822-4. ISSN 1063-6919. Disponível em: <http://ieeexplore.ieee.org/xpls/abs/_all.jsp?arnumber=609410><http://ieeexplore.ieee.org/document/609410/>>. 7, 14

_____. Mean shift: a robust approach toward feature space analysis. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 24, n. 5, p. 603–619, may 2002. ISSN 01628828. Disponível em: <<http://ieeexplore.ieee.org/document/1000236/>>. 14

COSTA, W.; FONSECA, L.; KORTING, T.; BENDINI, H.; SOUZA, R. Segmentation of optical remote sensing images for detecting homogeneous regions in space and time. In: GEOINFO, 18., 2017, Salvador, BA. **Proceedings...** São José dos Campos: INPE, 2017. p. 40–51. 46

COSTA, W.; FONSECA, L.; KORTING, T.; SIMOES, M.; KUCHLER, P. A case study for a multitemporal segmentation approach in optical remote sensing images. In: INTERNATIONAL CONFERENCE ON ADVANCED GEOGRAPHIC INFORMATION SYSTEMS, APPLICATIONS, AND SERVICES (GEOPROCESSING), 10., 2018. **Proceedings...** Rome: IARIA, 2018. p. 66–70. 57

COSTA, W. S.; FONSECA, L. M. G.; KORTING, T. S.; BENDINI, H. D. N.; SOUZA, R. C. M. d. Spatio-temporal segmentation applied to optical remote sensing image time series. **IEEE Geoscience and Remote Sensing Letters**, v. 15, n. 8, p. 1299–1303, aug 2018. ISSN 1545-598X. Disponível em: <<https://ieeexplore.ieee.org/document/8361471/>>. 66

COSTA, W. S.; GARCIA, F. L. M.; KORTING, T. S.; SIMOES, M.; BENDINI, H. d. N.; SOUZA, R. C. M. Segmentation of optical remote sensing images for detecting homogeneous regions in space and time. **Revista Brasileira de Cartografia**, v. 70, n. 5, p. 1779–1801, dec 2018. ISSN 1808-0936. 46

DASS, R.; DEVI, S. Image segmentation techniques. **The International Journal of Electronics & Communication Technology (IJECT)**, v. 3, n. 1, p. 66–70, 2012. 8

DELVES, L. M.; WILKINSON, R.; OLIVER, C. J.; WHITE, R. G. Comparing the performance of SAR image segmentation algorithms. **International**

Journal of Remote Sensing, v. 13, n. 11, p. 2121–2149, 1992. ISSN 0143-1161. **39, 40, 71**

DESCLÉE, B.; BOGAERT, P.; DEFOURNY, P. Forest change detection by statistical object-based method. **Remote Sensing of Environment**, v. 102, n. 1, p. 1–11, 2006. **3, 18**

DEY, V.; ZHANG, Y.; ZHONG, M. A review on image segmentation techniques with remote sensing perspective. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 38, p. 31–42, July 2010. **16, 18**

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. **3, 18**

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. **3, 18**

DURO, D.; FRANKLIN, S.; DUBÉ, M. Hybrid object-based change detection and hierarchical image segmentation for thematic map updating. **Photogrammetric Engineering & Remote Sensing**, v. 79, n. 3, p. 259–268, 2013. **3, 16**

EECKHAUT, M. V. D.; KERLE, N.; POESEN, J.; HERVÁS, J. Object-oriented identification of forested landslides with derivatives of single pulse lidar data. **Geomorphology**, v. 173–174, p. 30–42, 2012. ISSN 0169-555X. **39, 69**

ERASMI, S.; BOTHE, M.; PETTA, R. A. Enhanced filtering of MODIS time series data for the analysis of desertification processes in Northeast Brazil. In: ISPRS/ITC MIDTERM SYMPOSIUM: REMOTE SENSING: FROM PIXELS TO PROCESSES, 2006, The Netherlands. **Proceedings...** The Netherlands: ISPRS, 2006. p. 8–11. **25**

FREITAS, R. d.; ARAI, E.; ADAMI, M.; FERREIRA, A. S.; SATO, F. Y.; SHIMABUKURO, Y. E.; ROSA, R. R.; ANDERSON, L. O.; RUDORFF, B. F. T. Virtual laboratory of remote sensing time series: visualization of MODIS EVI2 data set over South America. **Journal of Computational Interdisciplinary Sciences**, v. 2, n. 1, p. 57–68, 2011. **22, 26**

GÓMEZ, C.; WHITE, J. C.; WULDER, M. A. Characterizing the state and processes of change in a dynamic forest environment using hierarchical spatio-temporal segmentation. **Remote Sensing of Environment**, v. 115, n. 7, p. 1665–1679, 2011. [3](#), [16](#), [17](#)

GÓMEZ, C.; WHITE, J. C.; WULDER, M. A. Optical remotely sensed time series data for land cover classification: a review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 116, p. 55–72, 2016. ISSN 09242716. [2](#), [23](#)

GONZALEZ, R. C.; WOODS, R. E. **Digital image processing**. 3. ed. Upper Saddle River: Prentice-Hall, 2006. ISBN 013168728X. [1](#), [5](#), [6](#), [7](#), [8](#), [9](#), [10](#), [11](#)

GULZAR, H. M. **Comprehensive Python module for computing and visualizing Dynamic Time Warping alignment: DTWPy**. 2015. 71 p. Dissertação (Mestrado em Ciência da Computação) — University of Stavanger, Stavanger, Norway, 2015. [28](#), [30](#), [31](#)

GUTTLER, F.; IENCO, D.; NIN, J.; TEISSEIRE, M.; PONCELET, P. A graph-based approach to detect spatiotemporal dynamics in satellite image time series. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 130, p. 92–107, aug 2017. ISSN 09242716. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0924271616306396>>. [3](#), [17](#)

HARALICK, R. M.; SHAPIRO, L. G. Image segmentation techniques. **Proceedings of SPIE**, v. 548, n. 1, p. 2–9, 1985. [3](#), [6](#), [35](#)

HIRD, J. N.; MCDERMID, G. J. Noise reduction of NDVI time series: an empirical comparison of selected techniques. **Remote Sensing of Environment**, v. 113, n. 1, p. 248–258, 2009. [25](#)

HUETE, A.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E. P.; GAO, X.; FERREIRA, L. G. Overview of the radiometric and biophysical performance of the modis vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1, p. 195–213, 2002. [23](#), [24](#)

ITAKURA, F. Minimum prediction residual principle applied to speech recognition. **IEEE Transaction on Acoustics, Speech and Signal Processing**, v. 23, n. 1, p. 67–72, 1975. [31](#)

JIANG, Z.; HUETE, A. R.; DIDAN, K.; MIURA, T. Development of a two-band enhanced vegetation index without a blue band. **Remote Sensing of Environment**, v. 112, n. 10, p. 3833–3845, 2008. 24

JUSTICE, C.; TOWNSHEND, J.; VERMOTE, E.; MASUOKA, E.; WOLFE, R.; SALEOUS, N.; ROY, D.; MORISETTE, J. An overview of MODIS land data processing and product status. **Remote Sensing of Environment**, v. 83, n. 1, p. 3–15, 2002. 24

KANG, W.-X.; YANG, Q.-Q.; LIANG, R.-P. The comparative research on image segmentation algorithms. In: INTERNATIONAL WORKSHOP ON EDUCATION TECHNOLOGY AND COMPUTER SCIENCE, 1., 2009, Wuhan, China. **Proceedings...** Wuhan, China: IEEE, 2009. v. 2, p. 703–707. 8

KEOGH, E.; RATANAMAHATANA, C. A. Exact indexing of dynamic time warping. **Knowledge and Information Systems**, v. 7, n. 3, p. 358–386, 2005. 27

KHIALI, L.; NDIATH, M.; ALLEAUME, S.; IENCO, D.; OSE, K.; TEISSEIRE, M. Detection of spatio-temporal evolutions on multi-annual satellite image time series: a clustering based approach. **International Journal of Applied Earth Observation and Geoinformation**, v. 74, n. July 2018, p. 103–119, feb 2019. ISSN 03032434. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0303243418304781>>. 3, 15, 16, 17

KUENZER, C.; OTTINGER, M.; WEGMANN, M.; GUO, H.; WANG, C.; ZHANG, J.; DECH, S.; WIKELSKI, M. Earth observation satellite sensors for biodiversity monitoring: potentials and bottlenecks. **International Journal of Remote Sensing**, v. 35, n. 18, p. 6599–6647, 2014. Disponível em: <<https://doi.org/10.1080/01431161.2014.964349>>. 1, 2

LAMBIN, E. F.; LINDERMAN, M. Time series of remote sensing data for land change science. **IEEE Transactions on Geoscience and Remote Sensing**, v. 44, n. 7, p. 1926–1928, 2006. 19, 21

LU, D.; MAUSEL, P.; BRONDIZIO, E.; MORAN, E. Change detection techniques. **International Journal of Remote Sensing**, v. 25, n. 12, p. 2365–2401, 2004. 23

LUNETTA, R. S.; KNIGHT, J. F.; EDIRIWICKREMA, J.; LYON, J. G.; WORTHY, L. D. Land-cover change detection using multi-temporal MODIS NDVI data. **Remote Sensing of Environment**, v. 105, n. 2, p. 142–154, 2006. ISSN 00344257. 23

MARUJO, R. B.; FONSECA, L. M. G.; KORTING, T.; BENDINI, H.; QUEIROZ, G.; VINHAS, L.; FERREIRA, K. Remote sensing image processing functions in lua language. **Journal of Computational Interdisciplinary Sciences**, v. 8, n. 3, p. 1–14, 2017. ISSN 1983-8409.

Disponível em:

<http://epacis.net/jcis/PDF{ }JCIS/JCIS11-art.0133.pdf><http://epacis.net/jcis/10.6062jcis.2017.08.03.0133.php>. 76

MARUJO, R. B.; FONSECA, L. M. G.; KORTING, T.; BENDINI, H. Spectral normalization between Landsat-8/OLI, Landsat- 7/ETM+ and CBERS-4/MUX bands through linear regression and spectral unmixing. In: GEOINFO, 18., 2017, Salvador, BA. **Anais...** São José dos Campos: INPE, 2017. p. 273–282. 76

MAUS, V.; CÂMARA, G.; APPEL, M.; PEBESMA, E. dtwSat: time-weighted dynamic time warping for satellite image time series analysis in R. **Journal of Statistical Software**, v. 5, n. 2, 2016. Disponível em:

<http://www.jstatsoft.org/>. 32

MAUS, V.; CAMARA, G.; CARTAXO, R.; RAMOS, F. M.; SANCHEZ, A.; RIBEIRO, G. Q. Open boundary dynamic time warping for satellite image time series classification. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), 2015. **Proceedings... IEEE**, 2015. p. 3349–3352. ISBN 978-1-4799-7929-5. Disponível em:

<http://ieeexplore.ieee.org/document/7326536/>. 32

MAUS, V. W. **Land use and land cover monitoring using remote sensing image time series**. 2016. 114 p. Tese (Doutorado em Ciência do Sistema Terrestre) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2016. 32, 33

MEHNERT, A.; JACKWAY, P. An improved seeded region growing algorithm. **Pattern Recognition Letters**, v. 18, n. 10, p. 1065–1071, 1997. 12

MORETTIN, P. A.; TOLOI, C. **Análise de séries temporais**. São Paulo: Blucher, 2006. 21

MÜLLER, M. **Information retrieval for music and motion**. Bonn, Germany: Springer, 2007. 30, 31, 32

NIEMEYER, I.; MARPU, P.; NUSSBAUM, S. Change detection using object features. In: BLASCHKE, T.; LANG, S.; HAY, G. (Ed.). **Object-based image analysis**. Berlin: Springer, 2008, (Lecture Notes in Geoinformation and Cartography). p. 185–201. ISBN 978-3-540-77057-2. Disponível em: <http://dx.doi.org/10.1007/978-3-540-77058-9_10>. 3, 17

NIKHIL, P.; SANKAR, P. A review on image segmentation techniques. **Pattern Recognition**, v. 26, n. 9, p. 1277–1294, sep 1993. ISSN 00313203. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/003132039390135J>>. 38

NOVO-FERNÁNDEZ, A.; FRANKS, S.; WEHENKEL, C.; LÓPEZ-SERRANO, P. M.; MOLINIER, M.; LÓPEZ-SÁNCHEZ, C. A. Landsat time series analysis for temperate forest cover change detection in the Sierra Madre Occidental, Durango, Mexico. **International Journal of Applied Earth Observation and Geoinformation**, v. 73, n. June, p. 230–244, dec 2018. ISSN 03032434. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0303243418302812>>. 1, 2

OLIVEIRA, J. C. de. **Índice para avaliação de segmentação (IAVAS). Uma aplicação em agricultura**. 2002. 160 p. Dissertação (Mestrado em Sensoriamento Remoto) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2002. 13

OLTHOF, I.; FRASER, R. H. Detecting landscape changes in high latitude environments using landsat trend analysis: 2. classification. **Remote Sensing**, v. 6, n. 11, p. 11558–11578, 2014. ISSN 20724292. 23

PAPE, A. D.; FRANKLIN, S. E. MODIS-based change detection for Grizzly Bear habitat mapping in Alberta. **Photogrammetric Engineering & Remote Sensing**, v. 74, n. 8, p. 973–985, 2008. 3, 16

PETITJEAN, F.; INGLADA, J.; GANÇARSKI, P. Clustering of satellite image time series under time warping. In: INTERNATIONAL WORKSHOP ON THE ANALYSIS OF MULTI-TEMPORAL REMOTE SENSING IMAGES, 6., 2011. **Proceedings...** IEEE, 2011. p. 69–72. 26, 27, 32

_____. Satellite image time series analysis under time warping. **IEEE Transactions on Geoscience and Remote Sensing**, v. 50, n. 8, p. 3081–3095, 2012. 2, 23, 27, 30, 32

PETITJEAN, F.; WEBER, J. Efficient satellite image time series analysis under time warping. **Geoscience and Remote Sensing Letters**, v. 11, n. 6, p. 1143–1147, jun 2014. ISSN 1545-598X. Disponível em: <<http://ieeexplore.ieee.org/document/6671999/>>. 23, 32

RATANAMAHATANA, A.; KEOGH, E. Everything you know about dynamic time warping is wrong. In: WORKSHOP ON MINING TEMPORAL AND SEQUENTIAL DATA, 3.; ACM SIGKDD INT. CONF. KNOWLEDGE DISCOVERY AND DATA MINING, 10., 2004, Seattle, WA. **Proceedings...** ACM, 2004. 27

REICHE, J.; LUCAS, R.; MITCHELL, A. L.; VERBESSELT, J.; HOEKMAN, D. H.; HAARPAINTNER, J.; KELLNDORFER, J. M.; ROSENQVIST, A.; LEHMANN, E. A.; WOODCOCK, C. E.; SEIFERT, F. M.; HEROLD, M. Combining satellite data for better tropical forest monitoring. **Nature Climate Change**, v. 6, p. 120–122, Jan 2016. Disponível em: <<https://doi.org/10.1038/nclimate2919>>. 1

ROERDINK, J. B.; MEIJSTER, A. The watershed transform: definitions, algorithms and parallelization strategies. **Fundamenta Informaticae**, v. 41, n. 1,2, p. 187–228, abr. 2000. ISSN 0169-2968. Disponível em: <<http://dl.acm.org/citation.cfm?id=2372488.2372495>>. 15

SAKOE, H.; CHIBA, S. A dynamic programming approach to continuous speech recognition. In: INTERNATIONAL CONGRESS ON ACOUSTICS, 7., 1971. **Proceedings...** Budapest: Akademiai Kiado, 1971. v. 3, p. 65–69. 27

_____. Dynamic programming algorithm optimization for spoken word recognition. **IEEE Transaction on Acoustics, Speech and Signal Processing**, New York, NY, v. 26, n. 1, p. 43–49, 1978. 27, 31

SCHIEWE, J. Segmentation of high-resolution remotely sensed data-concepts, applications and problems. **International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences**, v. 34, n. 4, p. 380–385, 2002. 1, 7, 8

SHIH, F. Y.; CHENG, S. Automatic seeded region growing for color image segmentation. **Image and Vision Computing**, v. 23, n. 10, p. 877–886, 2005. [12](#)

SHIMABUKURO, Y. E.; BEUCHLE, R.; GRECCHI, R. C.; ACHARD, F. Assessment of forest degradation in brazilian amazon due to selective logging and fires using time series of fraction images derived from landsat etm+ images. **Remote Sensing Letters**, v. 5, n. 9, p. 773–782, 2014. Disponível em: <<https://doi.org/10.1080/2150704X.2014.967880>>. [23](#)

SINGH, D.; HERAS, D.; RIVERA, F. Parallel seeded region growing algorithm. In: SIMPOSIUM NACIONAL DE RECONOCIMIENTO DE FORMAS Y ANÁLISIS DE IMÁGENES, 8., 1999. **Anales...** Bilbao, 1999. [12](#)

SONG, X.-P.; HANSEN, M. C.; STEHMAN, S. V.; POTAPOV, P. V.; TYUKAVINA, A.; VERMOTE, E. F.; TOWNSHEND, J. R. Global land change from 1982 to 2016. **Nature**, v. 560, n. 7720, p. 639–643, 2018. ISSN 1476-4687. Disponível em: <<https://doi.org/10.1038/s41586-018-0411-9>>. [1, 15](#)

SOUZA, C. F. S.; PANTOJA, C. E. P.; SOUZA, F. C. M. Verificação de assinaturas offline utilizando Dynamic Time Warping. In: CONGRESSO BRASILEIRO DE REDES NEURAIAS, 9. **Proceedings...** SBRN, 2009. p. 25–28. [29](#)

TAO, W.; JIN, H.; ZHANG, Y. Color image segmentation based on mean shift and normalized cuts. **IEEE Transactions on Systems, Man and Cybernetics, Part B (Cybernetics)**, v. 37, n. 5, p. 1382–1389, oct 2007. ISSN 1083-4419. Disponível em: <<http://ieeexplore.ieee.org/document/4305291/>>. [14](#)

THOMPSON, J. A.; LEES, B. G. Applying object-based segmentation in the temporal domain to characterise snow seasonality. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 97, p. 98–110, 2014. [3, 16, 19](#)

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote sensing of Environment**, v. 8, n. 2, p. 127–150, 1979. [24](#)

TUCKER, C. J.; PINZON, J. E.; BROWN, M. E.; SLAYBACK, D. A.; PAK, E. W.; MAHONEY, R.; VERMOTE, E. F.; SALEOUS, N. E. An extended

AVHRR 8-km NDVI dataset compatible with MODIS and SPOT vegetation NDVI data. **International Journal of Remote Sensing**, v. 26, n. 20, p. 4485–4498, 2005. 23

VARSHNEY, S.; RAJPAL, N.; PURWAR, R. Comparative study of image segmentation techniques and object matching using segmentation. In: INTERNATIONAL CONFERENCE ON METHODS AND MODELS IN COMPUTER SCIENCE, 2009, Delhi, India. **Proceedings... IEEE**, 2009. p. 1–6. 8

VERBESSELT, J.; HYNDMAN, R.; NEWNHAM, G.; CULVENOR, D. Detecting trend and seasonal changes in satellite image time series. **Remote Sensing of Environment**, v. 114, n. 1, p. 106–115, 2010. 23

VERBESSELT, J.; ZEILEIS, A.; HEROLD, M. Near real-time disturbance detection using satellite image time series. **Remote Sensing of Environment**, v. 123, p. 98–108, 2012. ISSN 00344257. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2012.02.022>>. 23

VUOLO, F.; MATTIUZZI, M.; KLISCH, A.; ATZBERGER, C. Data service platform for MODIS vegetation indices time series processing at BOKU Vienna: current status and future perspectives. **Proceedings of SPIE**, v. 8538, p. 1–10, 2012. Disponível em: <<http://dx.doi.org/10.1117/12.974857>>. 25

WARDLOW, B. D.; EGBERT, S. L.; KASTENS, J. H. Analysis of time-series MODIS 250 m vegetation index data for crop classification in the U.S. Central Great Plains. **Remote Sensing of Environment**, v. 108, n. 3, p. 290–310, 2007. ISSN 00344257. 23

WASSENBERG, J.; MIDDELMANN, W.; SANDERS, P. An efficient parallel algorithm for graph-based image segmentation. In: JIANG, X.; PETKOV, N. (EDS.). **Computer analysis of images and patterns**. Berlin: Springer, 2009. p. 1003–1010. 1

WEBER, J.; PETITJEAN, F.; GANÇARSKI, P. Towards efficient satellite image time series analysis: combination of dynamic time warping and quasi-flat zones. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2012, München, Germany. **Proceedings... IEEE**, 2012. p. 4387–4390. 27

XIAO, P.; YUAN, M.; ZHANG, X.; FENG, X.; GUO, Y. Cosegmentation for object-based building change detection from high-resolution remotely sensed images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 55, n. 3, p. 1587–1603, mar 2017. ISSN 0196-2892. Disponível em:

<<http://ieeexplore.ieee.org/document/7803617/>>. 3, 17, 40

XIAO, X.; BOLES, S.; LIU, J.; ZHUANG, D.; FROLKING, S.; LI, C.; SALAS, W.; MOORE, B. Mapping paddy rice agriculture in southern China using multi-temporal MODIS images. **Remote Sensing of Environment**, v. 95, n. 4, p. 480–492, 2005. ISSN 00344257. 23

YONG, X.; FENG, D.; RONGCHUN, Z. Optimal selection of image segmentation algorithms based on performance prediction. In: PAN-SYDNEY AREA WORKSHOP ON VISUAL INFORMATION PROCESSING, 5., 2004. **Proceedings...** Sydney: Australian Computer Society, 2004. p. 105–108. Disponível em:

<<http://dl.acm.org/citation.cfm?id=1082140>>. 38

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, apr 2015. ISSN 09242716. Disponível em:

<<http://dx.doi.org/10.1016/j.isprsjprs.2015.01.009><https://linkinghub.elsevier.com/retrieve/pii/S092427161500026X>>. 40

ZHANG, X.; XIAO, P.; FENG, X.; YUAN, M. Separate segmentation of multi-temporal high-resolution remote sensing images for object-based change detection in urban area. **Remote Sensing of Environment**, v. 201, p. 243–255, nov 2017. ISSN 00344257. Disponível em:

<<http://dx.doi.org/10.1016/j.rse.2017.09.022><https://linkinghub.elsevier.com/retrieve/pii/S0034425717304340>>. 1, 3, 17, 40

ZHU, Z.; WOODCOCK, C. E. Automated cloud, cloud shadow, and snow detection in multitemporal landsat data: an algorithm designed specifically for monitoring land cover change. **Remote Sensing of Environment**, v. 152, p. 217 – 234, 2014. ISSN 0034-4257. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0034425714002259>>. 23

ZUCKER, S. W. Region growing: childhood and adolescence. **Computer Graphics and Image Processing**, v. 5, n. 3, p. 382–399, 1976. 6

PUBLICAÇÕES TÉCNICO-CIENTÍFICAS EDITADAS PELO INPE

Teses e Dissertações (TDI)

Teses e Dissertações apresentadas nos Cursos de Pós-Graduação do INPE.

Manuais Técnicos (MAN)

São publicações de caráter técnico que incluem normas, procedimentos, instruções e orientações.

Notas Técnico-Científicas (NTC)

Incluem resultados preliminares de pesquisa, descrição de equipamentos, descrição e ou documentação de programas de computador, descrição de sistemas e experimentos, apresentação de testes, dados, atlas, e documentação de projetos de engenharia.

Relatórios de Pesquisa (RPQ)

Reportam resultados ou progressos de pesquisas tanto de natureza técnica quanto científica, cujo nível seja compatível com o de uma publicação em periódico nacional ou internacional.

Propostas e Relatórios de Projetos (PRP)

São propostas de projetos técnico-científicos e relatórios de acompanhamento de projetos, atividades e convênios.

Publicações Didáticas (PUD)

Incluem apostilas, notas de aula e manuais didáticos.

Publicações Seriadas

São os seriados técnico-científicos: boletins, periódicos, anuários e anais de eventos (simpósios e congressos). Constam destas publicações o International Standard Serial Number (ISSN), que é um código único e definitivo para identificação de títulos de seriados.

Programas de Computador (PDC)

São a seqüência de instruções ou códigos, expressos em uma linguagem de programação compilada ou interpretada, a ser executada por um computador para alcançar um determinado objetivo. Aceitam-se tanto programas fonte quanto os executáveis.

Pré-publicações (PRE)

Todos os artigos publicados em periódicos, anais e como capítulos de livros.