

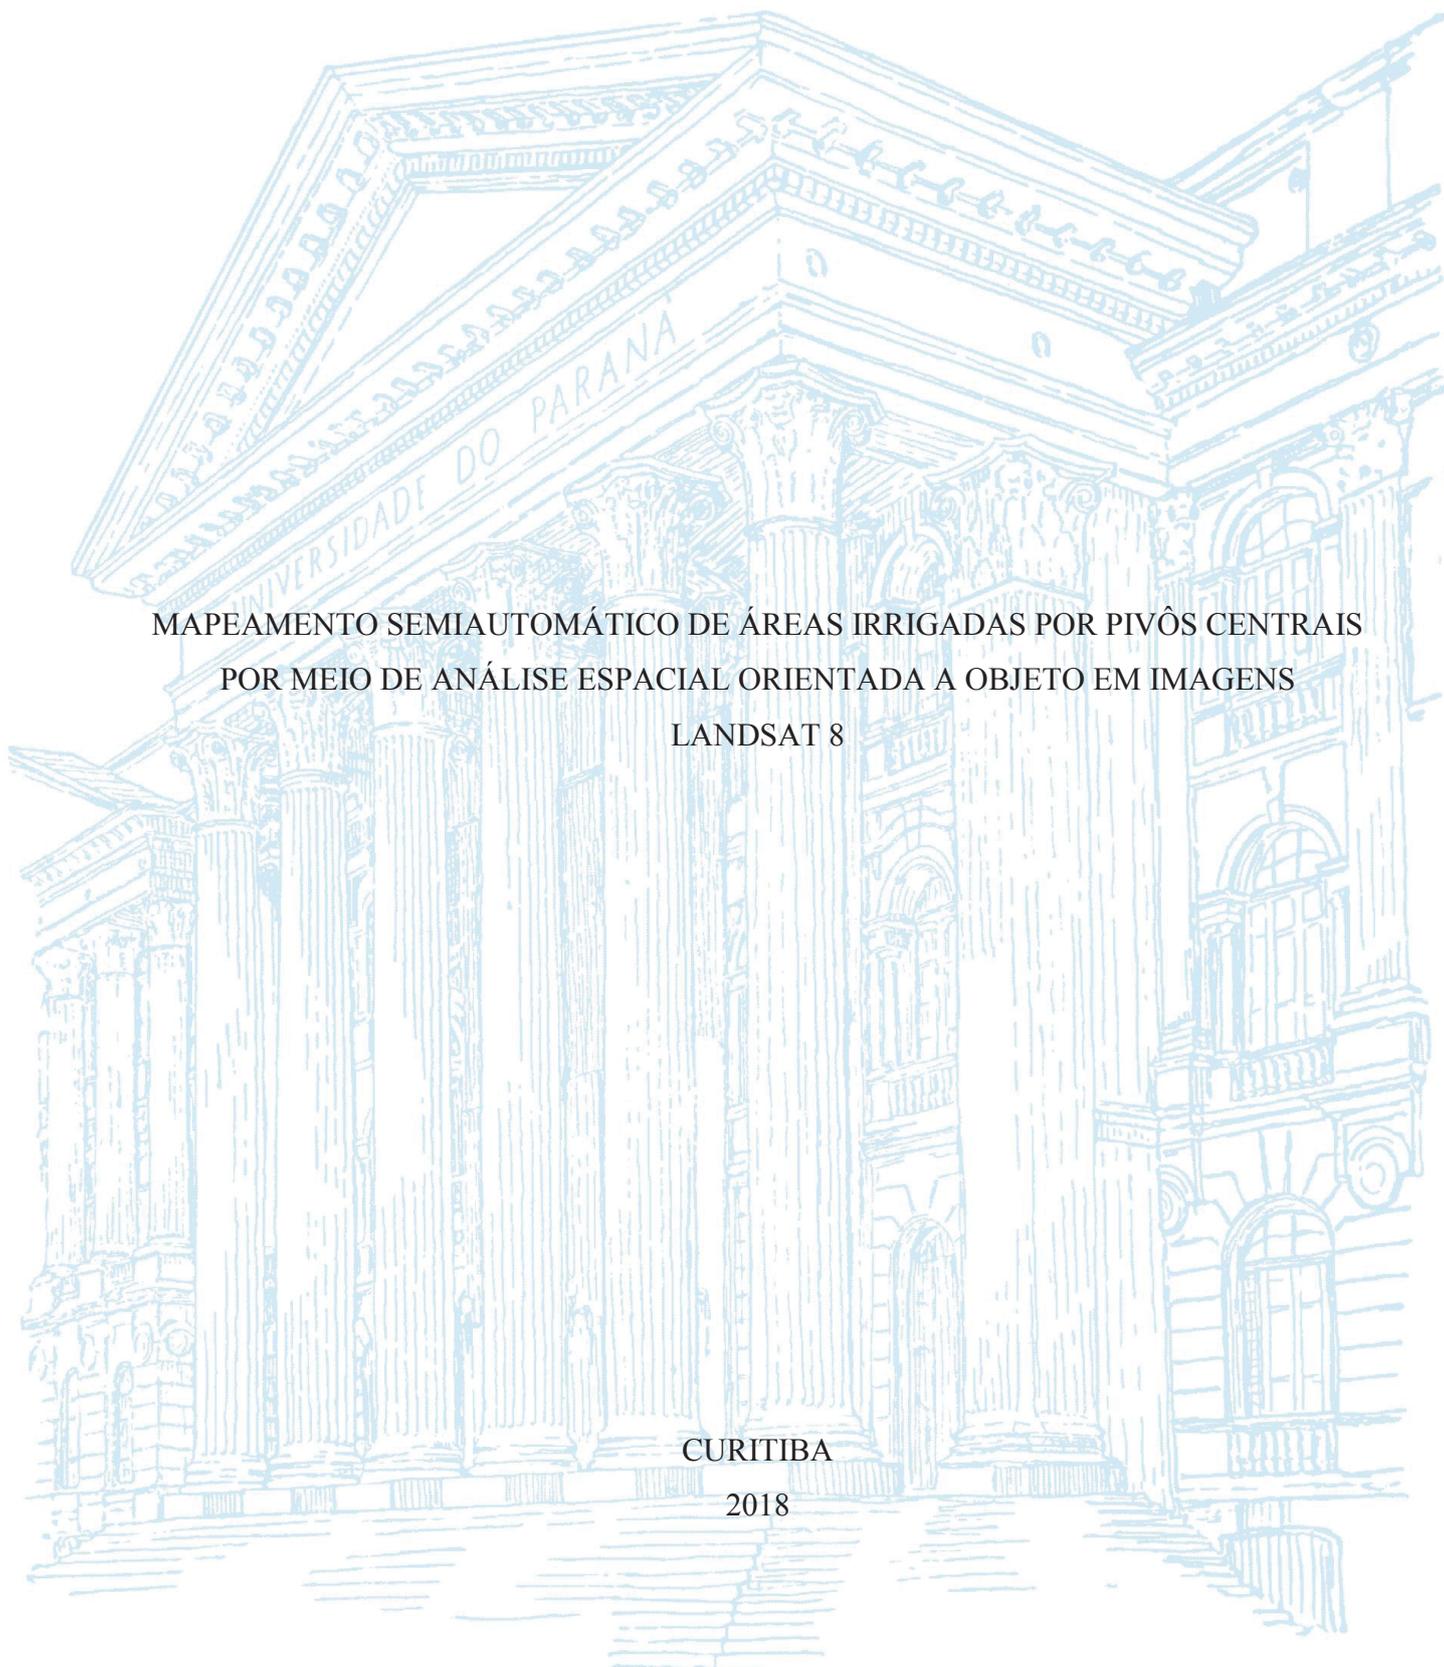
UNIVERSIDADE FEDERAL DO PARANÁ

LEANDRO GUIMARÃES MARANHA

MAPEAMENTO SEMIAUTOMÁTICO DE ÁREAS IRRIGADAS POR PIVÔS CENTRAIS
POR MEIO DE ANÁLISE ESPACIAL ORIENTADA A OBJETO EM IMAGENS
LANDSAT 8

CURITIBA

2018



LEANDRO GUIMARÃES MARANHA

MAPEAMENTO SEMIAUTOMÁTICO DE ÁREAS IRRIGADAS POR PIVÔS CENTRAIS
POR MEIO DE ANÁLISE ESPACIAL ORIENTADA A OBJETO EM IMAGENS
LANDSAT 8

Dissertação apresentada ao Curso de Pós-Graduação em Ciências Geodésicas, Área de Concentração Fotogrametria e Sensoriamento Remoto, Setor de Ciências da Terra, Universidade Federal do Paraná como requisito parcial para obtenção do Título de Mestre em Ciências Geodésicas.

Orientador: Prof. Dr. Alzir Felipe Buffara Antunes

CURITIBA

2018

Catálogo na Fonte: Sistema de Bibliotecas, UFPR
Biblioteca de Ciência e Tecnologia

M311m

Maranha, Leandro Guimarães

Mapeamento semiautomático de áreas irrigadas por pivôs centrais por meio de análise espacial orientada a objeto em imagens Landsat 8 [recurso eletrônico] / Leandro Guimarães Maranhã. – Curitiba, 2018.

Dissertação - Universidade Federal do Paraná, Setor de Ciências da Terra, Programa de Pós-Graduação em Ciências Geodésicas, 2018.

Orientador: Alzir Felipe Buffara Antunes .

1. Irrigação. 2. Engenharia de irrigação. 3. LANDSAT (Satélites). 4. Processamento de imagens.. I. Universidade Federal do Paraná. II. Antunes, Alzir Felipe Buffara. III. Título.

CDD: 631.7

Bibliotecário: Elias Barbosa da Silva CRB-9/1894

TERMO DE APROVAÇÃO

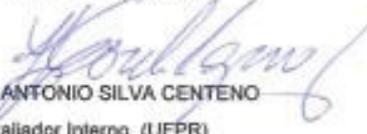
Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em CIÊNCIAS GEODÉSICAS da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **LEANDRO GUIMARAES MARANHA** intitulada: **MAPEAMENTO SEMIAUTOMÁTICO DE ÁREAS IRRIGADAS POR PIVÔS CENTRAIS POR MEIO DE ANÁLISE ESPACIAL ORIENTADA A OBJETO EM IMAGENS LANDSAT 8**, após terem inquirido o aluno e realizado a avaliação do trabalho, são de parecer pela sua Aprovação no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curitiba, 31 de Julho de 2018.


ALZIR FELIPPE BUFFARA ANTUNES
Presidente da Banca Examinadora (UFPR)


THALES SEHN KORTING
Avaliador Externo (INPE)


JORGE ANTONIO SILVA CENTENO
Avaliador Interno (UFPR)

Aos meus pais, Izídio de Araújo Maranha e
Leóides Guimarães Maranha.
Dedico.

AGRADECIMENTOS

À Deus, fonte primordial da vida e detentor de todo conhecimento.

Ao Programa de Pós-Graduação em Ciências Geodésicas da UFPR, pela oportunidade de realizar o mestrado.

Aos professores do CPGCG pelos conhecimentos transmitidos.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES pelo auxílio financeiro.

À minha família, pelo apoio e incentivo incondicional em todos os momentos.

À Kamilla Silva Oliveira, meu amor, pelo companheirismo, apoio, força e paciência.

Ao professor Dr. Alzir Felipe Buffara Antunes, pela orientação e sábios conselhos.

À Dr.^a Ieda Del’Arco Sanches, pesquisadora e professora do INPE, por todo conhecimento compartilhado e pelas valiosas contribuições antes e durante o decorrer desta pesquisa.

Aos colegas dos laboratórios de Sensoriamento Remoto (LabSenso) e Fotogrametria (LabFoto), pelos auxílios nos momentos difíceis e pelos bons momentos que tornaram o trabalho menos árduo.

RESUMO

A detecção de áreas irrigadas por meio de imagens orbitais ainda é um desafio devido à diversidade de métodos e sistemas utilizados para o fornecimento de água às culturas agrícolas. Entretanto, o sistema de irrigação por pivô central cria uma forma geométrica circular ou semicircular no local onde utilizado, produzindo padrões bem definidos em imagens orbitais de alta ou média resoluções espaciais, que podem ser explorados no desenvolvimento de rotinas semiautomatizadas para mapeamento destas áreas. Neste sentido, a abordagem GEOBIA fornece meios metodológicos que permitem automatizar parte do processo de identificação de áreas irrigadas por pivôs centrais utilizando, sobretudo, descritores de forma, e de modo complementar descritores espectrais e texturais. O objetivo geral deste estudo é analisar a aplicabilidade de classificação orientada a objetos em imagens de média resolução espacial (≈ 30 metros) para detecção de áreas irrigadas por pivôs centrais. A área de estudo é o município de Guaíra, localizado no Estado de São Paulo - Brasil. Este município se destaca como importante pólo de agricultura irrigada, sendo que no ano de 2014 existiam instalados cerca de 350 equipamentos de irrigação por pivô central, ocupando uma área de mais de 14 mil hectares. Uma série temporal de imagens OLI/Landsat-8 foi composta por seis cenas (órbita/ponto 221/074) distribuídas entre os meses de abril e setembro de 2014, pertencendo ao período de estiagem da região, o que aumentou a ocorrência de equipamentos de irrigação ativos. A metodologia central deste estudo é desenvolvida no software eCognition® Developer 8.8, onde foram realizados três experimentos. No primeiro experimento a série temporal utilizada foi composta por imagens com resolução espacial de 30 metros, a segmentação multirresolução foi utilizada para criar oito níveis hierárquicos e a classificação dos objetos-imagem pertencentes às áreas irrigadas por pivôs centrais foi realizada utilizando somente descritores de forma. No segundo experimento a série temporal utilizou imagens fusionadas, cuja resolução espacial foi de 15 metros, foram criados 10 níveis hierárquicos e a classificação também ocorreu somente com descritores de forma. O terceiro experimento se diferenciou do segundo apenas na classificação, onde descritores espectrais e texturais foram utilizados em conjunto com os de forma. Os resultados da classificação foram avaliados em termos quantitativos e qualitativos. No primeiro experimento, a classificação teve acurácia global de 70,72% e foram detectadas 215 unidades de pivôs centrais. O segundo experimento pôde detectar 228 unidades de pivôs centrais, sendo que a acurácia geral da classificação foi de 75%. O terceiro experimento apresentou os melhores resultados na classificação, onde foi possível detectar 253 unidades de pivôs centrais, com acurácia global de 83,22%. A abordagem GEOBIA apresentou desempenho satisfatório na classificação de áreas irrigadas por pivôs centrais, sendo eficiente no reconhecimento e extração de padrões em imagens orbitais de média resolução espacial, desta forma, conclui-se que a metodologia desenvolvida neste estudo pode ser utilizada para a implementação de rotinas semiautomáticas mapeamento de pivôs centrais.

Palavras-chave: Segmentação multirresolução. Série temporal. Descritores de forma. Fator de circularidade.

ABSTRACT

The detection of irrigated areas through satellite images still remains a challenge due to the diversity of methods and systems used to provide water to crops. However, the center pivot irrigation system creates a circular or semicircular geometric shape in the place where it is used, producing well defined patterns in high and medium spatial resolution images that can be explored in the development of automated routines for mapping these areas. For this, the GEOBIA approach provides methodological means that allows automating part of the process of center pivot irrigated areas identification using mainly shape features, and to complement spectral and textural features. The mainly objective of this study is to analyze the applicability of object-oriented image classification in 30 meters and 15 meters spatial resolution images, for the detection of center pivot irrigated areas. In this work, the study area is the municipality of Guaira, located in São Paulo State – Brazil. Guaira is an important center of irrigated crop production and in the year 2014 there were installed 350 center pivot systems, occupying an area of more than 14,000 ha. A temporal series of OLI/Landsat-8 images was composed by six scenes (Path/Row 221/074) distributed between the months of April and September 2014, belonging to the region's drought season, which increased the occurrence of irrigation. The central methodology of this study is developed in eCognition® Developer 8.8 software, where three experiments were carried out. In the first experiment the time series used was composed of images with 30 meters spatial resolution, and multiresolution segmentation was used to create eight hierarchical levels and the classification of the image-objects belonging to the center pivots irrigated areas performed using only shape features. In the second experiment, the time series used fused images whose spatial resolution was 15 meters, ten hierarchical levels were created and the classification also occurred only with shape features. The third experiment differed from the second only in the classification, where spectral and textural features were used in association with shape features. The results of the classification were evaluated in quantitative and qualitative terms. In the first experiment, the classification had an overall accuracy of 70.72% and 215 units of center pivots were detected. The second experiment was able to detect 228 units of center pivots, and the overall accuracy of the classification was 75%. The third experiment presented the best results in the classification, where it was possible to detect 253 units of center pivots, with an overall accuracy of 83.22%. The shapes features presented satisfactory performance in the classification process

Keywords: Multiresolution segmentation. Time series. Shape features. Circularity factor.

LISTA DE FIGURAS

FIGURA 1 –	MÉTODOS DE IRRIGAÇÃO (A) POR SUPERFÍCIE, (B) POR ASPERSÃO CONVENCIONAL, (C) LOCALIZADA E (D) SUBIRRIGAÇÃO.	20
FIGURA 2 –	IRRIGAÇÃO POR PIVÔ CENTRAL: (A) EQUIPAMENTO; (B) VISTA AERÉA DE ÁREAS IRRIGADAS; (C) PADRÕES CIRCULARES EM IMAGEM ORBITAL.	21
FIGURA 3 –	COMPARAÇÃO ENTRE CLASSIFICAÇÃO BASEADA EM OBJETO (A) E BASEADA EM PIXEL (B).	28
FIGURA 4 –	RELAÇÃO ENTRE OBJETOS E RESOLUÇÃO ESPACIAL RELATIVA: (A) BAIXA RESOLUÇÃO; (B) MÉDIA RESOLUÇÃO, E (C) ALTA RESOLUÇÃO. O QUADRO REPRESENTA O TAMANHO DO <i>PIXEL</i> ...	29
FIGURA 5 –	SEGMENTAÇÃO MULTIRRESOLUÇÃO E REDE HIERÁRQUICA DE OBJETOS DEFINIDOS TOPOLOGICAMENTE.	33
FIGURA 6 –	DECISÃO HEURÍSTICA PARA DETERMINAÇÃO DOS OBJETOS A SEREM AGRUPADOS EM CADA CICLO.	34
FIGURA 7 –	PARÂMETROS DE SEGMENTAÇÃO MULTIRRESOLUÇÃO.	35
FIGURA 8 –	ÁREA DE ESTUDO.	41
FIGURA 9 –	SISTEMAS DE IRRIGAÇÃO POR PIVÔ CENTRAL EM GUAÍRA - SP.	42
FIGURA 10 –	BHS DE CONCEIÇÃO DAS ALAGOAS-MG E ITUVERAVA-SP.	46
FIGURA 11 –	FLUXOGRAMA GERAL METODOLÓGICO.	47
FIGURA 12 –	FLUXOGRAMA DE SEGMENTAÇÃO E CLASSIFICAÇÃO.	54
FIGURA 13 –	HIERARQUIA DE CLASSES DO EXPERIMENTO II.	55
FIGURA 14 –	HIERARQUIA DE CLASSES DO EXPERIMENTO III.	57
FIGURA 15 –	DIAGRAMA DE DISPERSÃO DAS ÁREAS DOS PIVÔS CENTRAIS CLASSIFICADOS NO EXPERIMENTO I VERSUS ÁREA DOS PIVÔS CENTRAIS DE REFERÊNCIA.	62
FIGURA 16 –	HISTOGRAMA DA DIFERENÇA ENTRE A ÁREA DOS PIVÔS DETECTADOS NO EXPERIMENTO I E DOS VALORES DE REFERÊNCIA EXPRESSOS EM PORCENTAGEM.	62
FIGURA 17 –	VISTA PARCIAL DA ÁREA DE ESTUDO OS PIVÔS CENTRAIS CLASSIFICADOS NO EXPERIMENTO I E OS PIVÔS CENTRAIS DE REFERÊNCIA.	63

FIGURA 18 – DIAGRAMA DE DISPERSÃO DAS ÁREAS DOS PIVÔS CENTRAIS CLASSIFICADOS NO EXPERIMENTO II VERSUS ÁREA DOS PIVÔS CENTRAIS DE REFERÊNCIA.....	66
FIGURA 19 – HISTOGRAMA DA DIFERENÇA ENTRE A ÁREA DOS PIVÔS DETECTADOS NO EXPERIMENTO II E DOS VALORES DE REFERÊNCIA EXPRESSOS EM PERCENTAGEM.....	66
FIGURA 20 – VISTA PARCIAL DA ÁREA DE ESTUDO MOSTRANDO OS PIVÔS CENTRAIS CLASSIFICADOS NO EXPERIMENTO II E OS PIVÔS CENTRAIS DE REFERÊNCIA.....	67
FIGURA 21 – DIAGRAMA DE DISPERSÃO DAS ÁREAS DOS PIVÔS CENTRAIS CLASSIFICADOS NO EXPERIMENTO III VERSUS ÁREA DOS PIVÔS CENTRAIS DE REFERÊNCIA.....	70
FIGURA 22 – HISTOGRAMA DA DIFERENÇA ENTRE A ÁREA DOS PIVÔS DETECTADOS NO EXPERIMENTO III E DOS VALORES DE REFERÊNCIA EXPRESSOS EM PERCENTAGEM.....	70
FIGURA 23 – VISTA PARCIAL DA ÁREA DE ESTUDO MOSTRANDO OS PIVÔS CENTRAIS CLASSIFICADOS NO EXPERIMENTO III E OS PIVÔS CENTRAIS DE REFERÊNCIA.....	71
FIGURA 24 – OBJETO-IMAGEM COM FORMA RETANGULAR E DESCRITORES DE FORMA DENTRO DOS LIMIARES DA SUBCLASSE DOS PIVÔS PARCIAS “50%”.	73
FIGURA 25 – PIVÔS CENTRAIS DETECTADOS NO EXPERIMENTO I.	74
FIGURA 26 – PIVÔS CENTRAIS DETECTADOS NO EXPERIMENTO II.	75
FIGURA 27 – PIVÔS CENTRAIS DETECTADOS NO EXPERIMENTO III.	76
FIGURA 28 – COMPATIBILIDADE ENTRE O FATOR DE ESCALA E A ACURÁCIA NA CLASSIFICAÇÃO DE PIVÔS CENTRAIS, EXEMPLO DO EXPERIMENTO I.....	77

LISTA DE TABELAS

TABELA 1 – POSIÇÃO, NOME, NÚMERO DE EQUIPAMENTOS, ÁREA MUNICIPAL, <i>IOc</i> E ÁREA OCUPADA PELOS PIVÔS CENTRAIS PARA OS 15 MUNICÍPIOS BRASILEIROS COM MAIOR ÁREA IRRIGADA POR PIVÔ CENTRAL.....	43
TABELA 2 – PRINCIPAIS CARACTERÍSTICAS DO SENSOR OLI DO SATÉLITE LANDSAT-8.	44
TABELA 3 – RESOLUÇÃO E TIPO DE CLASSIFICAÇÃO DE CADA EXPERIMENTO.	46
TABELA 4 – CENAS UTILIZADAS NA SÉRIE TEMPORAL.....	47
TABELA 5 – NÍVEIS HIERÁRQUICOS E PARÂMETROS DA SEGMENTAÇÃO MULTIRRESOLUÇÃO DO EXPERIMENTO I.....	53
TABELA 6 – LIMIARES DOS DESCRITORES UTILIZADOS PARA CLASSIFICAÇÃO NO EXPERIMENTO I.....	55
TABELA 7 – NÍVEIS HIERÁRQUICOS E PARÂMETROS DA SEGMENTAÇÃO MULTIRRESOLUÇÃO DO EXPERIMENTO II.	56
TABELA 8 – LIMIARES DOS DESCRITORES UTILIZADOS PARA CLASSIFICAÇÃO NO EXPERIMENTO II.	56
TABELA 9 – NÍVEIS HIERÁRQUICOS E PARÂMETROS DA SEGMENTAÇÃO MULTIRRESOLUÇÃO DO EXPERIMENTO III.....	56
TABELA 10 – LIMIARES DOS DESCRITORES UTILIZADOS PARA CLASSIFICAÇÃO NO EXPERIMENTO III.	58
TABELA 11 – QUADRO RESUMO DOS RESULTADOS DA CLASSIFICAÇÃO DO EXPERIMENTO I.....	60
TABELA 12 – COMPARAÇÃO ENTRE AS ÁREAS DOS PIVÔS CLASSIFICADOS NO EXPERIMENTO I EM RELAÇÃO AOS PIVÔS DE REFERÊNCIA.	61
TABELA 13 – RESULTADOS DA CLASSIFICAÇÃO DO EXPERIMENTO II.	64
TABELA 14 – COMPARAÇÃO ENTRE AS ÁREAS DOS PIVÔS CLASSIFICADOS NO EXPERIMENTO II EM RELAÇÃO AOS PIVÔS DE REFERÊNCIA.	65
TABELA 15 – RESULTADOS DA CLASSIFICAÇÃO DO EXPERIMENTO III.	68
TABELA 16 – COMPARAÇÃO ENTRE AS ÁREAS DOS PIVÔS CLASSIFICADOS NO EXPERIMENTO III EM RELAÇÃO AOS PIVÔS DE REFERÊNCIA.	69

TABELA 17 – COMPARATIVO GERAL QUANTITATIVO ENTRE EXPERIMENTOS.

.....72

LISTA DE QUADROS

QUADRO 1 - ESCALA, SENSORES E MÉTODOS UTILIZADOS NO MAPEAMENTO DE ÁREAS IRRIGADAS.....	22
QUADRO 2 - RESUMO ESQUEMÁTICO DOS TRABALHOS ENVOLVENDO SENSORIAMENTO REMOTO NA IDENTIFICAÇÃO DE PIVÔ CENTRAIS DE IRRIGAÇÃO.....	25

SUMÁRIO

1	INTRODUÇÃO	16
1.1	HIPÓTESE	17
1.2	OBJETIVOS.....	18
1.2.1	Objetivo Geral	18
1.2.2	Objetivos Específicos	18
1.3	JUSTIFICATIVA	19
2	ESTADO DA ARTE	20
2.1	SISTEMAS DE IRRIGAÇÃO	20
2.1.1	Sistema Pivô Central	21
2.2	SENSORIAMENTO REMOTO E AGRICULTURA IRRIGADA.....	21
2.3	PIVÔS CENTRAIS E SENSORIAMENTO REMOTO.....	23
2.4	DETECÇÃO DE CÍRCULOS EM IMAGENS DIGITAIS	26
2.5	ANÁLISE DE IMAGEM BASEADA EM OBJETOS GEOGRÁFICOS	27
2.6	SEGMENTAÇÃO.....	30
2.6.1	Segmentação Multirresolução	31
2.7	CLASSIFICAÇÃO.....	37
2.7.1	Classificação Orientada a Objeto	38
3	MATERIAL E MÉTODOS	41
3.1	ÁREA DE ESTUDO	41
3.2	MATERIAL	43
3.3	MÉTODOS.....	44
3.3.1	Aquisição das imagens	47
3.3.2	Pré-processamento.....	47
3.3.3	Processamento das imagens	48
3.3.4	Avaliação dos resultados	58
4	RESULTADOS E DISCUSSÃO	60
4.1	RESULTADOS	60
4.1.1	Experimento I.....	60
4.1.2	Experimento II.....	64
4.1.3	Experimento III	68
4.2	DISCUSSÃO.....	72
5	CONCLUSÃO	78

5.1	RECOMENDAÇÕES DE TRABALHOS FUTUROS.....	79
	REFERÊNCIAS	80

1 INTRODUÇÃO

A irrigação é uma das técnicas mais antigas utilizadas pelo homem na produção agrícola, sendo praticada desde as antigas civilizações que se desenvolveram em regiões áridas, como no Egito e na Mesopotâmia. Compreende um conjunto de técnicas e equipamentos utilizados para suprir total ou parcialmente a demanda de água pelos cultivos (ANA, 2016). No Brasil, existe relato de que o primeiro sistema de irrigação tenha sido implantado ainda no período colonial, no ano de 1589, na Fazenda Santa Cruz, Estado do Rio de Janeiro (BERNARDO; SOARES; MANTOVANI, 2008).

O uso da irrigação apresenta diversas vantagens para a produção agrícola, como por exemplo, aumento da produtividade, que pode alcançar valores até três vezes superiores em relação ao cultivo de sequeiro (ZONTA et al., 2015); melhor aproveitamento do uso do solo; redução do custo unitário de produção; intensificação do uso de máquinas, implementos e mão de obra ao longo do ano; maior regularidade na disponibilidade de alimentos (MENDES, 1998); maior oferta de emprego - 1 ha irrigado gera de 0,8 a 1,2 empregos diretos e 1,0 a 1,2 empregos indiretos, enquanto na agricultura de sequeiro esses valores são da ordem de 0,22 empregos por ha (BERNARDO; SOARES; MANTOVANI, 2008). No entanto, o setor agrícola se caracteriza como o maior e mais dinâmico consumidor dos recursos hídricos do país, sendo responsável por 55% da vazão retirada e 75% da vazão consumida (ANA, 2016).

No Brasil, compete à Agência Nacional de Águas (ANA) a produção e atualização das informações acerca do balanço hídrico quantitativo nacional, que apresenta a relação entre a disponibilidade de água e as demandas por parte dos diferentes usuários. Contudo, existe grande lacuna de conhecimento em relação às áreas efetivamente irrigadas, do seu potencial de expansão e das diferentes formas de manejo do uso da água (ANA, 2016).

A informação sobre o quantitativo de área que utiliza algum sistema de irrigação é de crucial importância para os órgãos gestores dos recursos hídricos, seja em nível nacional, regional ou local. No entanto, a obtenção desse tipo de informação não é tarefa fácil.

Mapeamentos da agricultura irrigada, principalmente que cobrem grandes extensões territoriais, ainda são realizados em muitos países, incluindo o Brasil, por meio de dados estatísticos oriundos de levantamentos oficiais em nível nacional, como os realizados pelo IBGE, por meio dos censos agropecuários. Entretanto, existe forte tendência de dados deste tipo apresentarem resultados subestimados, decorrente da omissão de informações por parte dos irrigantes, devido à natureza tributária do uso da água (BASTIAANSSEN; MOLDEN; MAKIN, 2000). Outro fato que agrava negativamente os dados provenientes de pesquisas

declarativas é a falta da informação espacial, que possibilite a localização geográfica das unidades consumidoras, pois os dados são organizados em forma de tabelas, permitindo apenas a consulta dos quantitativos.

Neste sentido, o sensoriamento remoto orbital (i.e. imagens de satélite) surge como importante ferramenta que pode servir de base para a extração de informações a respeito de áreas irrigadas, desde que seja aplicada metodologia apropriada que permita a correta identificação das áreas. No entanto, pela existência de diferentes métodos e tipos de sistemas de irrigação, a identificação de certas áreas pode ser muito complexa ao passo de que outras podem ser relativamente mais simples, devido a características peculiares ao sistema, como por exemplo, o sistema de irrigação por pivô central.

O sistema de irrigação por pivô central, devido à sua natureza, confere forma geométrica circular ou semicircular à área onde está sendo utilizado, possibilitando sua identificação e mapeamento por meio de imagens de satélite. Desta forma, este estudo visa explorar as potencialidades oferecidas pela geometria bem definida destas áreas irrigadas, buscando realizar mapeamento semiautomático utilizando descritores espaciais e espectrais dentro de uma abordagem de análise de imagem baseada em objetos geográficos.

1.1 HIPÓTESE

Partindo das premissas que:

- As áreas irrigadas por pivôs centrais possuem padrão geométrico circular ou semicircular;
- A maioria das áreas irrigadas por pivôs centrais possuem tamanho suficiente para definir sua forma geométrica em imagens multiespectrais com resolução espacial de 30 metros;
- O uso de imagens orbitais com resolução espacial refinada para 15 metros, por meio de técnicas de fusão com a banda pancromática, melhora significativamente a definição da forma das áreas irrigadas por pivôs centrais, favorecendo à sua identificação;
- Os sistemas de irrigação são utilizados, principalmente, durante o período de estiagem, quando se tem baixa incidência de nuvens. Com isso, a chance de aquisição de série temporal ampla e de qualidade é aumentada.

Levando em consideração as premissas acima, define-se a seguinte hipótese:

- O uso de técnica de classificação de imagem que considere, além da informação espectral, atributos geométricos das feições podem viabilizar o reconhecimento e a extração de pivôs centrais de irrigação presentes em imagens orbitais, de forma semiautomática.

1.2 OBJETIVOS

1.2.1 Objetivo Geral

Avaliar a aplicabilidade da técnica de classificação de imagens baseada em objetos geográficos, em imagens de media resolução espacial (≈ 30 metros) provenientes do sensor OLI do satélite Landsat-8, para detecção de áreas irrigadas por pivôs centrais.

1.2.2 Objetivos Específicos

1. Estudar o regime hídrico da área de estudo para determinar o melhor período de aquisição de imagens para compor uma série temporal para identificação de áreas irrigadas por pivôs centrais;
2. Estudar o comportamento espectral dos alvos de interesse para se definir as bandas multiespectrais do sensor OLI/Landsat-8 a serem utilizadas nos testes com resolução espacial de 30 metros;
3. Avaliar a contribuição da fusão de bandas multiespectrais com a banda pancromática do sensor OLI/Landsat-8 para serem utilizadas nos testes com imagens com resolução espacial de 15 metros;
4. Realizar estudos e testes de segmentação multirresolução nas imagens com 30 e 15 metros de resolução espacial, para identificar os parâmetros mais relevantes para o isolamento de áreas de interesse;
5. Estudar e avaliar os descritores de forma e espectrais disponíveis na literatura para serem utilizados na classificação das áreas de interesse, e;
6. Desenvolver um descritor de forma que auxilie na identificação de feições circulares e semicirculares.

1.3 JUSTIFICATIVA

Dados das Nações Unidas estimam que em 2050 existam 9,1 bilhões de habitantes no mundo (UN DESA, 2009) e, baseado neste cenário, Bruinsma (2009) projetou que a demanda por alimentos seja 70% superior em relação a 2005. O aumento da população acarreta maior pressão sobre os recursos naturais, principalmente a água, que em nível global é destinada basicamente a três finalidades: abastecimento doméstico ($\approx 10\%$), uso industrial ($\approx 20\%$) e produção de alimentos ($\approx 70\%$) (CHRISTOFIDIS, 2013).

O aumento da oferta de alimentos, necessário para garantir a segurança alimentar da população, está associado ao uso de tecnologias de irrigação, pois esta é a única alternativa que possibilita o aumento do número de safras durante o ano em locais com déficit hídrico, tornando possível a intensificação do uso das terras. Tilman et al. (2002) afirmam que 40% da produção agrícola mundial são oriundas de apenas 16% de terras agrícolas que são irrigadas.

De acordo com a Comissão Internacional de Irrigação e Drenagem (ICID, 2016), as áreas irrigadas no mundo em 2015/2016 alcançaram a marca de 299,04 milhões de hectares, correspondendo a cerca de 20% das terras agricultáveis. No Brasil, de acordo com o Censo Agropecuário de 2006, o país contava com aproximadamente 4,545 milhões de ha irrigados (IBGE, 2007) e em 2014 foi estimado pela ANA o valor de 6,11 milhões de ha, sendo este último levantamento correspondente a cerca 21% do potencial de irrigação brasileiro, que é de aproximadamente 29,6 milhões de hectares (ANA, 2016). Ainda de acordo com a ANA (2016), a agricultura irrigada no Brasil vem apresentando expressivo crescimento, sempre com taxas superiores às do crescimento da área plantada total, sendo que nos últimos anos a expansão dos métodos de irrigação localizada e por pivô central apresentaram grande destaque.

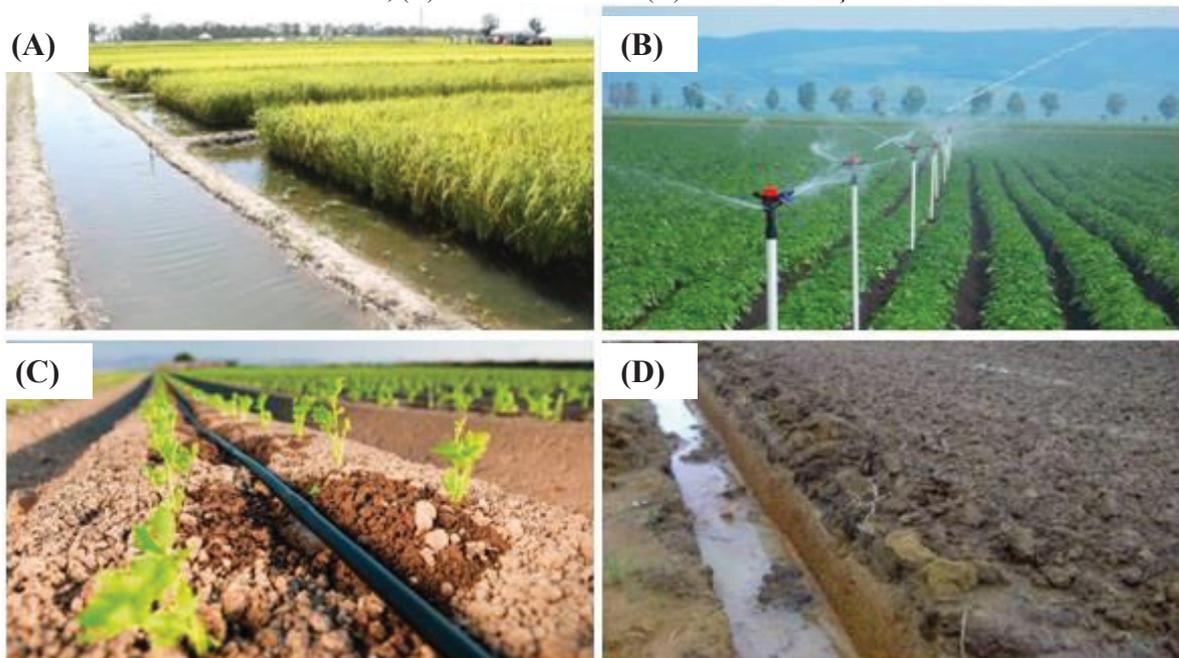
Com isso, percebe-se uma forte tendência de expansão da agricultura irrigada no Brasil pelos próximos anos, que caso seja realizada de forma desordenada poderá gerar grandes conflitos pelo uso da água. As instituições responsáveis pelo planejamento estratégico do uso da água sofrem pela grande carência de dados consistentes e atualizados acerca das áreas irrigadas no país, sendo que estas informações são fundamentais para o correto ordenamento em bases sustentáveis para esta atividade. Tendo em vista que o mapeamento de áreas irrigadas no Brasil ainda é um campo pouco explorado, surge então a possibilidade de experimentação e aplicação de técnicas de Análise de Imagem Baseada em Objetos Geográficos (*Geographic Object-Based Image Analysis - GEOBIA*) para desenvolvimento de metodologias que possam automatizar ou semiautomatizar o processo de identificação destas áreas, enfatizando assim a importância da GEOBIA na agricultura.

2 ESTADO DA ARTE

2.1 SISTEMAS DE IRRIGAÇÃO

Os métodos de irrigação são divididos em quatro tipos: superfície, aspersão, localizada e subirrigação. Na irrigação por superfície existem os sistemas por inundação, por sulcos e por faixas. No método por aspersão os sistemas são divididos em convencional, pivô central e autopropelido. A irrigação localizada utiliza basicamente dois sistemas, a microaspersão e o gotejamento. Por fim, a subirrigação ou irrigação subterrânea é um método baseado na formação e controle de um lençol freático artificial ou pelo controle de um lençol natural existente na área (BERNARDO; SOARES; MANTOVANI, 2008). A FIGURA 1 mostra exemplos de cada método de irrigação. No presente trabalho, atenção especial é dada ao sistema de irrigação por pivô central, pois este caracteriza o objeto de interesse do estudo.

FIGURA 1 – MÉTODOS DE IRRIGAÇÃO (A) POR SUPERFÍCIE, (B) POR ASPERSÃO CONVENCIONAL, (C) LOCALIZADA E (D) SUBIRRIGAÇÃO.

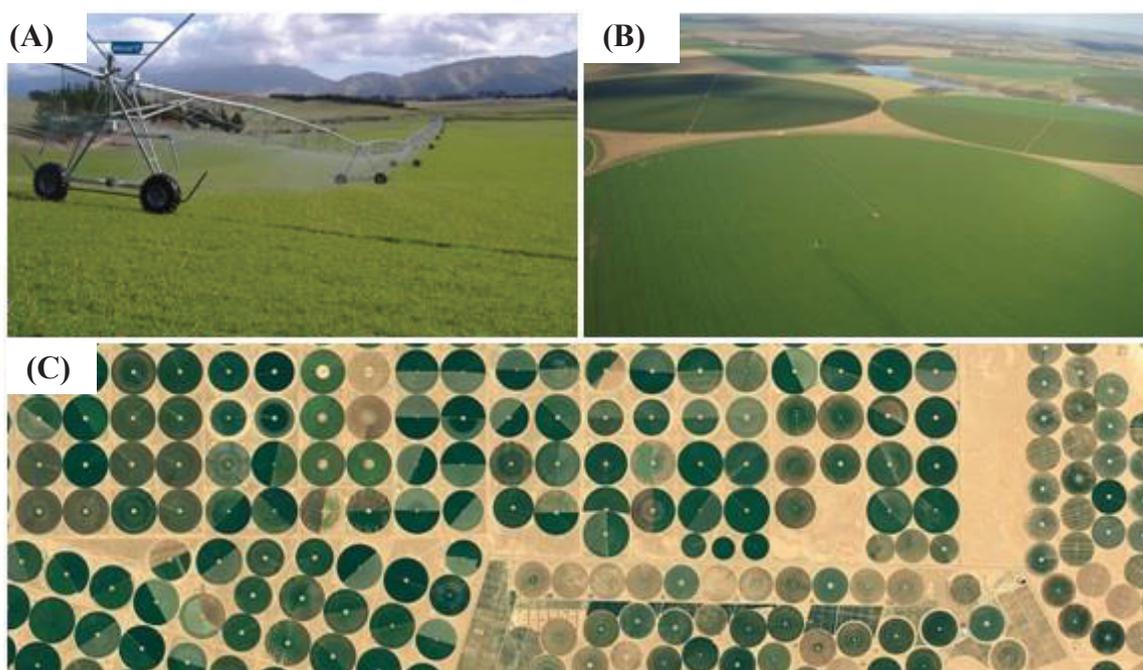


FONTE: Google Imagens (2018).

2.1.1 Sistema Pivô Central

É um sistema de movimentação circular, constituído em geral de uma linha (tubulação para condução de água sob pressão) com vários aspersores, comprimento variável, podendo alcançar até 800 m, com tubos de aço de acoplamento especial, suportada por torres dotadas de rodas, nas quais operam os dispositivos de propulsão do sistema, imprimindo à linha um movimento de rotação em torno de um ponto ou pivô, que lhe serve de ancoragem e de tomada de água (BERNARDO; SOARES; MANTOVANI, 2008). O movimento radial desse sistema é resultante de tempos diferenciais de operação das sucessivas torres que compõem o sistema (FRIZZONE, 2017), sendo este o motivo pelo qual a área que utiliza este tipo de sistema apresenta padrão circular (quando o sistema pode girar 360°) ou semicircular (quando giram menos que 360°). A FIGURA 2 mostra exemplos de áreas irrigadas por pivôs centrais.

FIGURA 2 – IRRIGAÇÃO POR PIVÔ CENTRAL: (A) EQUIPAMENTO; (B) VISTA AERÉA DE ÁREAS IRRIGADAS; (C) PADRÕES CIRCULARES EM IMAGEM ORBITAL.



FONTE: Google Imagens (2018).

2.2 SENSORIAMENTO REMOTO E AGRICULTURA IRRIGADA

O sensoriamento remoto (SR) orbital oferece enorme potencial para desenvolvimento de rotinas de monitoramento de áreas irrigadas, pois permitem visão sinóptica de extensas áreas. Contudo, estudos voltados para mapeamento de áreas irrigadas apresentam-se relativamente

raros na literatura, conforme apontado por Ozdogan et al. (2010), que atribuiu a baixa exploração desta ferramenta à alta complexidade que existe na tentativa de mapear o uso da terra em relação à cobertura do solo. Estes mesmos autores afirmam que existe um consenso na comunidade científica de que as metodologias de mapeamento de áreas irrigadas ainda estão fragmentadas e em evolução, pois a detecção destas áreas requer conhecimentos do manejo de terras agrícolas ou entendimento acerca de onde e quando é necessário utilizar técnicas de irrigação para a produção de alimentos.

Bastiaanssen et al. (2000) afirmam que o sensoriamento remoto pode prover importantes informações relacionadas aos recursos hídricos, como uso da terra, áreas irrigadas, produção e produtividade vegetal, evapotranspiração, salinidade, entre outros. Dentro do contexto de áreas irrigadas, o sensoriamento remoto pode ser utilizado para diversas finalidades, como: avaliação do uso e produtividade da água; diagnóstico de desempenho; planejamento estratégico; direito de uso de água; operações e avaliação de impactos.

O SR tem sido utilizado como ferramenta efetiva no monitoramento de áreas irrigadas ao redor do mundo sob as mais diversas condições ambientais (OZDOGAN et al., 2010). Lobell et al. (2003) quantificaram a acurácia e precisão na determinação de rotação, produtividade e data de plantio para as culturas de trigo, milho e soja, manejados sob irrigação utilizando imagens do sensor ETM⁺. Thenkabail, Schull e Turrall (2005) utilizaram dados de fluxo contínuo do sensor MODIS para mapeamento de áreas irrigadas e classificação do uso e cobertura do solo na bacia dos rios Ganges e Indus na Índia. Ozdogan e Gutman (2008) desenvolveram uma metodologia para mapeamento de áreas irrigadas utilizando dados multitemporais MODIS e dados auxiliares (climatológicos e mapas de extensões agrícolas), sendo que neste trabalho os autores mapearam as áreas irrigadas em terra seca (*dryland*), excluindo as áreas de pastagem e arroz, nos Estados Unidos. Segundo Ozdogan et al. (2010), os trabalhos de mapeamento de áreas irrigadas utilizando SR podem ser agrupados de acordo com a escala de mapeamento, sensores utilizados e métodos de mapeamentos, conforme apresentado na QUADRO 1.

QUADRO 1 - ESCALA, SENSORES E MÉTODOS UTILIZADOS NO MAPEAMENTO DE ÁREAS IRRIGADAS.

(Continua)

Escala	Sensor Utilizado	Método de Mapeamento
Local	Landsat TM/ETM+, SPOT, LISS, ASTER, AWiFS, CBERS, THEOS	Interpretação visual, Aritmética de imagens, Classificação de imagens, Segmentação, Fusão de imagens
Regional	Landsat TM/ETM+, MODIS, MERIS, AVHRR, SPOT Veg	Análise de séries temporais, Classificação supervisionada/não supervisionada, Máscaras

QUADRO 1 - ESCALA, SENSORES E MÉTODOS UTILIZADOS NO MAPEAMENTO DE ÁREAS IRRIGADAS.

(Conclusão)

Escala	Sensor Utilizado	Método de Mapeamento
Continental	Landsat TM/ETM+, MODIS, MERIS, AVHRR, SPOT Veg	Análise de séries temporais com outros dados auxiliares, Fusão de dados
Global	MODIS, MERIS, AVHRR, SPOT Veg	Clustering não supervisionado, Algoritmos de aprendizagem de máquina aplicados a séries temporais juntamente com dados auxiliares

FONTE: Adaptado de OZDOGAN et al. 2010.

Estudos realizados utilizando imagens da família Landsat são mais frequentemente aplicados às escalas locais e regionais, conforme apresentado na QUADRO 1. Em trabalhos desenvolvidos a nível local, os métodos mais comumente utilizados são interpretação visual e classificação digital de imagens. Os primeiros trabalhos desenvolvidos utilizando imagens de satélite utilizaram técnicas de interpretação visual adaptadas dos setores de aerofotos para mapear e atualizar as áreas irrigadas nos EUA e Índia, conforme afirma Ozdogan et al. (2010).

A partir da década de 1990 estudos começaram a ser desenvolvidos utilizando métodos de classificação digital de imagens adaptados ao mapeamento de áreas irrigadas (ECKHARDT; VERDIN; LYFORD (1990); RAM; KOLARKAR (1993); PAX-LENNEY et al. (1996); BELTRAN; BELMONTE (2001)), contudo utilizando-se apenas classificações supervisionadas *pixel a pixel*.

2.3 PIVÔS CENTRAIS E SENSORIAMENTO REMOTO

A literatura internacional apresenta o desenvolvimento de muitos trabalhos voltados para o mapeamento de áreas irrigadas, no entanto, não são direcionados exclusivamente para a identificação de pivôs centrais. Neste sentido, destaca-se que possivelmente, o primeiro trabalho de mapeamento de pivôs centrais com uso de imagens orbitais tenha sido desenvolvido por Rundquist et al. (1989), em que utilizaram imagens dos sensores MSS e TM do satélite Landsat-1 para inventariar, anualmente, as áreas irrigadas por pivôs centrais no estado de Nebraska nos EUA. Segundo estes autores, esse tipo de sistema de irrigação pode ser relativamente fácil de ser identificados por duas razões: i) forma que o distingue das demais áreas e, ii) alto valor de biomassa vegetal quando comparado com áreas não irrigadas. Ressalta-se aqui, que a segunda razão é prontamente válida para regiões áridas e semiáridas, pois o tipo de vegetação nativa é de baixa biomassa.

No Brasil, o sistema de irrigação por pivô central vem ganhando cada vez mais força, sendo que entre os anos de 2011 e 2014 foi registrado incremento médio de 104 mil ha por ano (ANA, 2016). Para acompanhar a evolução no crescimento da área irrigada, é necessário o uso de ferramentas que possibilitem rápida identificação. Neste cenário, o sensoriamento remoto apresenta-se como importante via para fornecimento de dados para subsidiar o mapeamento dessas áreas.

A identificação de áreas irrigadas por pivôs centrais por meio de imagens orbitais tem sido feita no Brasil, sobretudo, utilizando o método de identificação visual. A seguir, são apresentados os principais trabalhos desenvolvidos neste tema.

Schmidt et al. (2004) realizaram o mapeamento de áreas irrigadas por pivôs centrais na região Sudeste no Brasil. Neste trabalho os autores utilizaram imagens dos sensores TM e ETM⁺ dos satélites Landsat-5 e Landsat-7, respectivamente, onde realizaram identificação visual das áreas irrigadas por pivôs. Como resultados principais, os autores determinaram o número total de pivôs e a distribuição espacial destes dentro dos Estados que compõem a Região Sudeste.

Braga e Oliveira (2005) avaliaram o potencial das imagens CCD do satélite CBERS na determinação de áreas irrigadas por pivôs centrais no município de Miguelópolis – SP. Os autores utilizaram a técnica de segmentação por crescimento de regiões, implementada no *software* SPRING 4.1, fazendo uma segmentação multitemporal para duas imagens do ano de 2004. Após a segmentação, realizaram a classificação visual das áreas irrigadas por pivôs centrais, obtendo-se o número, localização e área ocupada por cada equipamento.

Sano et al. (2005) realizaram estudo utilizando imagens TM e ETM⁺ de 1992 e 2002, respectivamente, buscando determinar a variação da área irrigada por pivôs centrais no Distrito Federal e estimar a demanda hídrica desses sistemas. Os autores utilizaram a técnica de identificação visual para mapear os equipamentos. Desta forma, os autores puderam determinar o número de equipamentos, a área de cada um e a área total irrigada para as duas datas.

Ferreira et al. (2009) realizaram o mapeamento e quantificação de áreas irrigadas por pivô central na bacia do rio Paranaíba para o ano de 2008. Os autores utilizaram imagens TM do satélite Landsat-5 nas quais realizaram classificação supervisionada para identificar as áreas ocupadas por pivôs centrais. No entanto, não foi apresentado detalhes quanto à acurácia da classificação.

Ferreira et al. (2011) utilizaram imagens CCD do satélite CBERS-2B dos anos de 2008 e 2010 para mapeamento de áreas irrigadas por pivôs centrais no Estado de Minas Gerais. Com uso de identificação visual, os autores delimitaram manualmente os perímetros irrigados por

cada equipamento, que em seguida foram manipulados em ambiente de Sistema de Informação Geográfica (SIG) para realização do cálculo área total irrigada. Guimarães e Landau (2011) também realizaram mapeamento das áreas irrigadas por pivôs centrais no Estado de MG, utilizando imagens TM/Landsat-5 para o ano de 2010. Neste estudo, os autores carregaram as imagens para o *software* Google Earth onde realizaram a identificação visual e delimitação das áreas de interesse.

Fernandez et al. (2013) estudaram as taxas de uso de pivôs centrais na bacia hidrográfica do São Marcos, localizada no bioma Cerrado. Neste estudo, os autores mapearam os pivôs centrais entre os anos de 2007 e 2011. O mapeamento das áreas irrigadas foi realizado por identificação e delimitação visual diretamente sobre as imagens.

Lima et al. (2015) avaliaram a variação da área irrigada por pivô central no Cerrado entre os anos de 2002 e 2013. Neste estudo, os autores mapearam as unidades de irrigação por pivô central para o ano de 2013 com base em imagens OLI/Landsat-8 e compararam com os dados obtidos em levantamento anterior para o ano de 2002. O mapeamento foi realizado por meio de identificação visual e delimitação manual dos perímetros irrigados.

Martins et al. (2016) realizaram o levantamento da área irrigada por pivô central no Estado do Rio Grande do Sul, utilizando imagens OLI/Landsat-8 e o *software* Google Earth Pro. Neste levantamento, os autores utilizaram identificação visual das feições e delimitação manual das áreas irrigadas.

A Agência Nacional de Águas (ANA, 2016) realizou o mapeamento da agricultura irrigada por pivôs centrais em todo o Brasil para o ano de 2013 e 2014. A metodologia central utilizada neste levantamento foi identificação visual dos equipamentos em imagens de média resolução espacial (OLI/Landsat-8) e de alta resolução espacial (Google Earth Pro), onde foram delimitadas manualmente as áreas dos equipamentos identificados. Na QUADRO são apresentados, de forma resumida e esquemáticas, os trabalhos citados nesta seção.

QUADRO 2 – RESUMO ESQUEMÁTICO DOS TRABALHOS ENVOLVENDO SENSORIAMENTO REMOTO NA IDENTIFICAÇÃO DE PIVÔ CENTRAIS DE IRRIGAÇÃO.

(continua)

Autor	Dados	Abordagem	Local
Rundquist et al. (1989)	MSS e TM - Landsat-1	Identificação Visual	Nebraska - EUA
Schmidt et al. (2004)	TM Landsat-5 e ETM+ Landsat-7	Identificação Visual	Região Sudeste
Braga & Oliveira (2005)	CCD CBERS	Segmentação e Classificação Visual	Miguelópolis – SP

QUADRO 2 – RESUMO ESQUEMÁTICO DOS TRABALHOS ENVOLVENDO SENSORIAMENTO REMOTO NA IDENTIFICAÇÃO DE PIVÔ CENTRAIS DE IRRIGAÇÃO.

(Conclusão)			
Autor	Dados	Abordagem	Local
Sano et al. (2005)	TM Landsat-5 e ETM+ Landsat-7	Identificação Visual	Distrito Federal
Ferreira et al. (2009)	TM Landsat-5	Classificação sup. <i>pixel</i> a <i>pixel</i>	Bacia do rio Paranaíba
Guimarães e Landau (2011)	TM Landsat-5	Identificação Visual	Minas Gerais
Ferreira et al. (2011)	CCD CBERS -2B	Identificação Visual	Minas Gerais
Fernandez et al. (2013)	TM Landsat-5	Identificação Visual	Bacia Hidr. do São Marcos
Lima et al. (2015)	OLI Landsat-8	Identificação Visual	Região do Cerrado
Martins et al. (2016)	OLI Landsat-8 e Google Earth Pro	Identificação Visual	Rio Grande do Sul
ANA (2016)	OLI Landsat-8 e Google Earth Pro	Identificação Visual	Brasil

FONTE: O autor (2018).

2.4 DETECÇÃO DE CÍRCULOS EM IMAGENS DIGITAIS

De forma genérica, a detecção de círculos em imagens digitais apresenta-se como um tema amplamente discutido na literatura, onde diversas soluções já foram desenvolvidas utilizando diferentes abordagens. Nesta seção, será apresentada algumas das principais abordagens relatadas na área de reconhecimento de padrões e visão computacional.

Notadamente, a maioria das soluções desenvolvidas para detecção de círculos em imagens digitais são baseadas na Transformada de Hough (HT - *Hough Transform*) (HOUGH, 1962), que, dentro da visão computacional, é o método mais conceituado para reconhecimento de modelos complexos (DE MARCO et al. 2015). As primeiras aplicações da HT em imagens digitais foi para a detecção de linhas e curvas (DUDA; HART, 1972), sendo que em seguida, variações da HT foram propostas visando a detecção de outros padrões em imagens, como foi o caso da CHT - *Circular Hough Transform* (DAVIES, 1988; KIERKEGAARD, 1992) que é utilizada para detectar padrões circulares.

A CHT consiste numa sequência de etapas algorítmicas que visa encontrar os parâmetros que descrevem, de modo unívoco, os círculos presentes numa imagem (raio r e as coordenadas do centro x,y). Partindo de uma imagem binarizada, por meio de filtro de borda

(ex.: filtro de *Canny*), a CHT analisa todos os pixels pertencentes às bordas dos objetos presentes na imagem, com base num acumulador do tipo *array*, que é criado a partir de uma estratégia específica de votação, permitindo que objetos circulares sejam identificados com base na quantidade de pixels que pertençam à uma circunferência de raio r e centrada nas coordenadas x,y (DE MARCO et al. 2015).

2.5 ANÁLISE DE IMAGEM BASEADA EM OBJETOS GEOGRÁFICOS

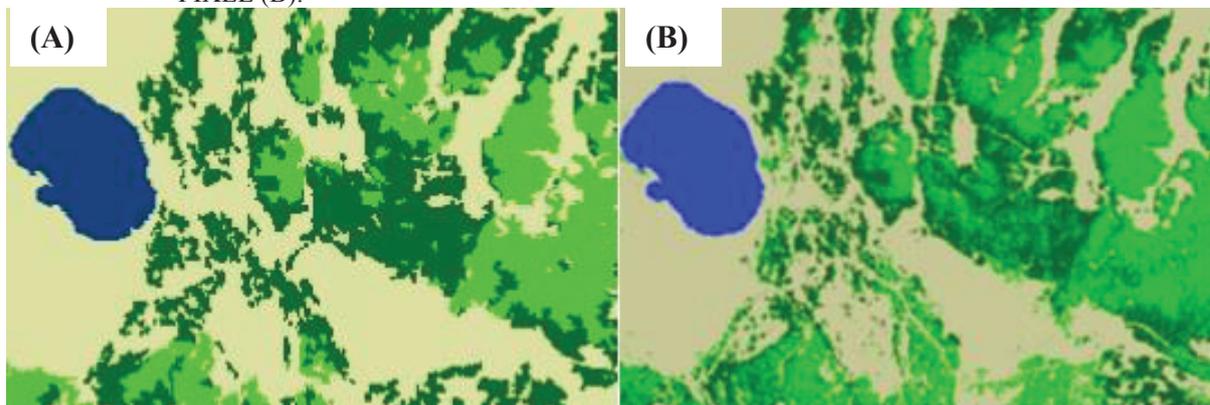
A chamada “geração 1 metro” de sensores orbitais iniciou em 1999 com o lançamento do satélite IKONOS possibilitando o uso de imagens orbitais em aplicações que requeriam grande nível de detalhes e que eram supridas essencialmente pela aerofotogrametria (BLASCHKE, 2010). Contudo, as tradicionais técnicas de extração de informações baseadas nos valores digitais apresentaram limitações, pois o incremento na resolução espacial da imagem eleva o nível de detalhe dos objetos, o que confere maior variabilidade e ruído dentro de classes homogêneas (SCHIEWE; TUFTE; EHLERS, 2001). Assim, novas concepções de classificação e análise de dados entraram em cena buscando substituir a interpretação de imagens baseada somente em *pixels* (NEUBERT; MEINEL, 2007), pois a utilização das características texturais, espaciais e topológicas dos objetos, de forma complementar à informação espectral, maximiza o entendimento e a extração de informações pelos usuários (LANG, 2008).

De acordo com Pilz e Strobl (2007) nos métodos baseados em *pixels* individuais parte-se de uma análise estatística dentro de um espaço de atributos no qual não se considera a posição espacial dos *pixels*. Desta forma, nos diferentes procedimentos para classificação, ocorre uma alocação do respectivo *pixel* a uma determinada classe, com base no valor digital. Ainda de acordo com estes autores, na interpretação visual é considerada uma resolução dos dados de imagem em amostras espaciais, onde o conhecimento especializado do analista tem um papel essencial. Pontos na imagem, que estão em vizinhança espacial possuem uma probabilidade muito maior de pertencerem à mesma classe. Esta condição é pouco considerada nos procedimentos tradicionais de classificação *pixel a pixel*.

Segundo Neubert (2001), especialmente nas imagens de alta resolução e que contêm muita textura, os *pixels* individuais apresentam-se como unidades pouco informativas, e a utilização de técnicas de classificação baseadas somente nos valores digitais na análise de tais imagens faz com que áreas assumidas como tematicamente homogêneas sejam analisadas independentemente, não resultando numa classificação satisfatória. A FIGURA 3 mostra um

exemplo de comparação entre a abordagem *pixel a pixel* e a baseada em objetos, onde a variabilidade dentro de uma classe homogênea promovida pela alta resolução espacial é superada pela formação de segmentos homogêneos.

FIGURA 3 – COMPARAÇÃO ENTRE CLASSIFICAÇÃO BASEADA EM OBJETO (A) E BASEADA EM PIXEL (B).



FONTE: Adaptado de WILLHAUCK et al., (2000).

O princípio básico de GEOBIA é claro e ambicioso: representar cenas com conteúdo complexo de tal modo que a realidade imageada seja descrita da melhor maneira possível, possibilitando maior entendimento, extração e transmissão de forma clara aos usuários. No entanto, isto não é tarefa simples, pois em GEOBIA, a percepção humana (na pessoa do analista) é a referência utilizada como parâmetro final de qualidade. O senso visual humano permite compreensão do ambiente físico de modo rápido e fácil, contudo, esse entendimento é difícil de ser expresso em palavras ou num conjunto de regras. De fato, o desafio é tornar explícito o modo como lidar com a informação imageada em várias escalas, como conseguir relacionar objetos reconhecidos, como entender prontamente os conteúdos complexos da cena. Para este fim, GEOBIA utiliza conceitos do *spatial thinking*¹, que novamente é influenciado pela psicologia cognitiva (LANG, 2008).

Do ponto de vista metodológico, GEOBIA está baseada em dois pilares inter-relacionados derivados do sensoriamento remoto e SIG. O primeiro é a segmentação, que é uma técnica que consiste em dividir a imagem em regiões, que correspondam aos objetos ou a parte deles, sendo que cada segmento pode então ser descrito tanto em termos espectrais quanto em termos espaciais (ANTUNES; CENTENO, 2007); o segundo é o uso de classificadores

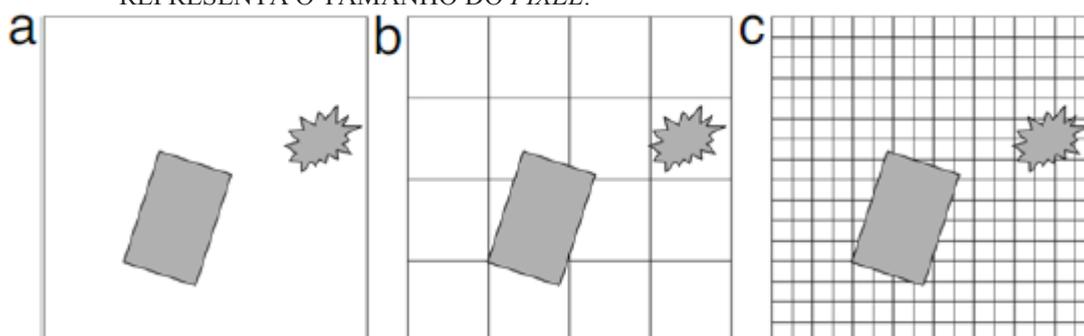
¹ Kerski (2013) define *Spatial thinking* por "identificar, analisar e compreender a localização, padrões, escala e tendências das relações geográficas e temporais entre dados, fenômenos e problemas".

baseados em regras, que tornam explícitas as propriedades espectrais e geométricas das regiões segmentadas, sendo necessário para modelagem avançada de classes (LANG, 2008).

De acordo com Lang (2008), a segmentação de imagem em GEOBIA gera objetos-imagem que reduzem o nível de detalhe e a complexidade da cena, favorecendo a compreensão da imagem como um todo. Após a segmentação, os classificadores rotulam os objetos-imagem de acordo com as regras definidas, como comportamento espectral e relações espaciais. Desta forma, verifica-se que um *pixel*, por si só não pode ser considerado um objeto-imagem, pois não possui atributos suficientes para caracterizar e representar um objeto do mundo real, porém, um conjunto de *pixels* que possam ser agrupados segundo um critério, pode ser correlacionado a objetos reais, constituindo assim objetos-imagem.

A FIGURA 4 ilustra três situações onde objetos reais possuem diferentes tamanhos em relação à resolução espacial da imagem, sendo que cada quadro na figura representa o tamanho relativo do *pixel* da imagem. Na Figura 4(a), observa-se que os objetos são significativamente menores que o *pixel*, constituindo neste caso, uma situação de baixa resolução. Em 4(b) os objetos e os *pixels* possuem mesma ordem de tamanho, caracterizando uma situação de média resolução, e em 4(c) os pixels são significativamente menores que os objetos, neste caso conformam uma situação de alta resolução (BLASCHKE, 2010).

FIGURA 4 – RELAÇÃO ENTRE OBJETOS E RESOLUÇÃO ESPACIAL RELATIVA: (A) BAIXA RESOLUÇÃO; (B) MÉDIA RESOLUÇÃO, E (C) ALTA RESOLUÇÃO. O QUADRO REPRESENTA O TAMANHO DO *PIXEL*.



FONTE: Adaptado de BLASCHKE (2010).

De acordo com Blaschke (2010), pode-se assumir que as situações 4(a) e 4(b) não deixam muita escolha quando se busca identificar, classificar e caracterizar um dado objeto, assim como ilustrado, pois as resoluções espaciais não permitem nenhuma outra abordagem além da baseada em *pixel*. Contudo, somente no caso 4(c) as vantagens específicas da abordagem GEOBIA podem ser exploradas, pois as características espaciais, texturais e topológicas dos objetos podem ser obtidas e utilizadas.

O desenvolvimento de abordagens baseadas em objetos foi impulsionado a partir da introdução de imagens com resoluções espaciais refinadas, que proporcionaram “situações de alta resolução” numa grande gama de aplicações (STRAHLER et al., 1986). Porém, isso não significa necessariamente que esta técnica não possa ser aplicada em imagens com resoluções espaciais mais grosseiras, como as obtidas pelos satélites da série Landsat, por exemplo. Neste sentido, estudos utilizando métodos GEOBIA têm sido aplicados com sucesso em imagens de média resolução espacial dos sensores TM e ETM+ dos satélites Landsat-5 e Landsat-7, respectivamente (DORREN et al., 2003; GENELETTI; GORTE, 2003; DUVEILLER et al., 2008; MYINT et al., 2008; JOBIN et al., 2008), em situações onde os objetos de interesse possuem tamanho suficiente para caracterizar uma situação passível de utilização da abordagem.

2.6 SEGMENTAÇÃO

"O todo é igual à soma de suas partes", esta proposição primitiva de Euclides pode ser utilizada para se compreender simplificada o objetivo da segmentação de imagens. O processo se inicia tomando uma imagem "inteira" e particionando-a em regiões ou objetos que constituem as "partes do todo". Gonzales e Woods (2001) definem o processo de segmentação como a subdivisão em regiões ou objetos que formam a imagem digital.

Se tratando de imagens digitais, objeto ou objeto-imagem é constituído por um conjunto de *pixels* que possuem características em comum e podem ser considerados homogêneos segundo um conjunto de regras preestabelecidas. Segundo Baatz e Schäpe (2000), a segmentação é um importante passo na análise automática de imagens, pois é nesta etapa onde os objetos de interesse podem ser extraídos e posteriormente processados.

No contexto de OBIA, a segmentação busca criar objetos-imagem por meio da divisão de uma imagem em grupos de *pixels* que são espectralmente similares e espacialmente adjacentes, formando regiões por meio da minimização da variabilidade interna do objeto, se comparada com a variabilidade entre os objetos (DESCLÉE; BOGAERT; DEFOURNY, 2006). Desta forma, as regiões com mínima heterogeneidade são encontradas e agrupadas (TEDESCO, 2015).

De acordo com Antunes (2003), não existe um modelo formal para a segmentação de imagens, sendo que o método pode variar em função do tipo de imagem e do objetivo. O processo é essencialmente empírico e, em geral, ajustável aos diferentes tipos de imagem, com limiares definidos em função da complexidade dos alvos investigados.

A quantidade de objetos-imagem que resultam da segmentação é dependente do nível de detalhamento desejado e também do tipo de problema a ser resolvido, pois o processo de segmentação é interrompido quando os objetos de interesse tiverem sido isolados (PRATT, 2007). Após a segmentação é necessário utilizar um método de classificação para associar os objetos-imagem às classes do terreno, pois os algoritmos segmentadores não reconhecem os objetos individuais e nem os relacionam com os demais, apenas subdividem a imagem (TEDESCO, 2015).

Os algoritmos de segmentação de imagens normalmente são baseados em propriedades de descontinuidade ou similaridade dos valores digitais. Na primeira categoria, o particionamento da imagem é baseado em mudanças abruptadas dos valores digitais, encontrando as bordas dos objetos. Este tipo de segmentação é utilizado quando se deseja detectar pontos, linhas e bordas isolados. As principais abordagens utilizadas na segunda categoria são baseadas na subdivisão da imagem em regiões que são similares de acordo um conjunto de critérios predefinidos. Fazem parte desta categoria os métodos de limiarização (*thresholding*), crescimento de regiões (*region growing*), divisão e fusão de regiões (*region splitting and merging*) (GONZALES; WOODS, 2001). A seguir é abordada segmentação multirresolução, uma técnica derivada do crescimento de regiões e utilizada em OBIA.

2.6.1 Segmentação Multirresolução

Os métodos de segmentação citados anteriormente são baseados exclusivamente nos valores digitais ou níveis de cinza das imagens. Nesta seção será abordado o método de segmentação implementado no *software* eCognition®, o qual utiliza outros tipos de informações além dos valores digitais para geração de objetos-imagem.

A segmentação multirresolução é baseada no conceito de que, ao analisar imagens de sensoriamento remoto, a visão humana tende a generalizar a imagem dentro de áreas homogêneas, de forma intuitiva. Em seguida, essas áreas são analisadas mais minuciosamente, fazendo surgir áreas internas a essas. Essa subdivisão resulta em objetos significativos da superfície terrestre e dependentes da escala de análise. A importância de se considerar a escala vem do fato de que frequentemente os objetos de interesse têm sua própria escala inerente, assim, ela determina a ocorrência ou não de certas classes de objetos. Portanto, analisar uma imagem em níveis diferentes de escala, ao invés de usar imagens com diferentes resoluções, é mais adequado para a identificação de feições e a compreensão das relações dentro de uma imagem (TEDESCO, 2015).

Proposta por Baatz e Schäpe (2000), a segmentação multirresolução constitui etapa fundamental para a geração de objetos/segmentos que são as unidades básicas de processamento utilizadas numa abordagem OBIA. A análise de imagem baseada em objetos possui vantagens significativamente superior aos métodos *pixel a pixel*, por fazerem uso de cálculos estatísticos, texturais, parâmetros de forma, relações topológicas, além de possuir estreita relação entre os objetos-imagem e os objetos do mundo real (BENZ et al., 2004), sendo que estas características não podem ser exploradas por abordagens baseadas somente no *pixel*. Desta forma, a segmentação multirresolução apresenta-se como uma solução de alta qualidade, que permite adaptação e aplicabilidade aos mais variados problemas e tipos de dados. Isto é possibilitado por meio de um algoritmo de segmentação geral, baseado em definições de homogeneidade em combinação com técnicas de aprimoramento local e global.

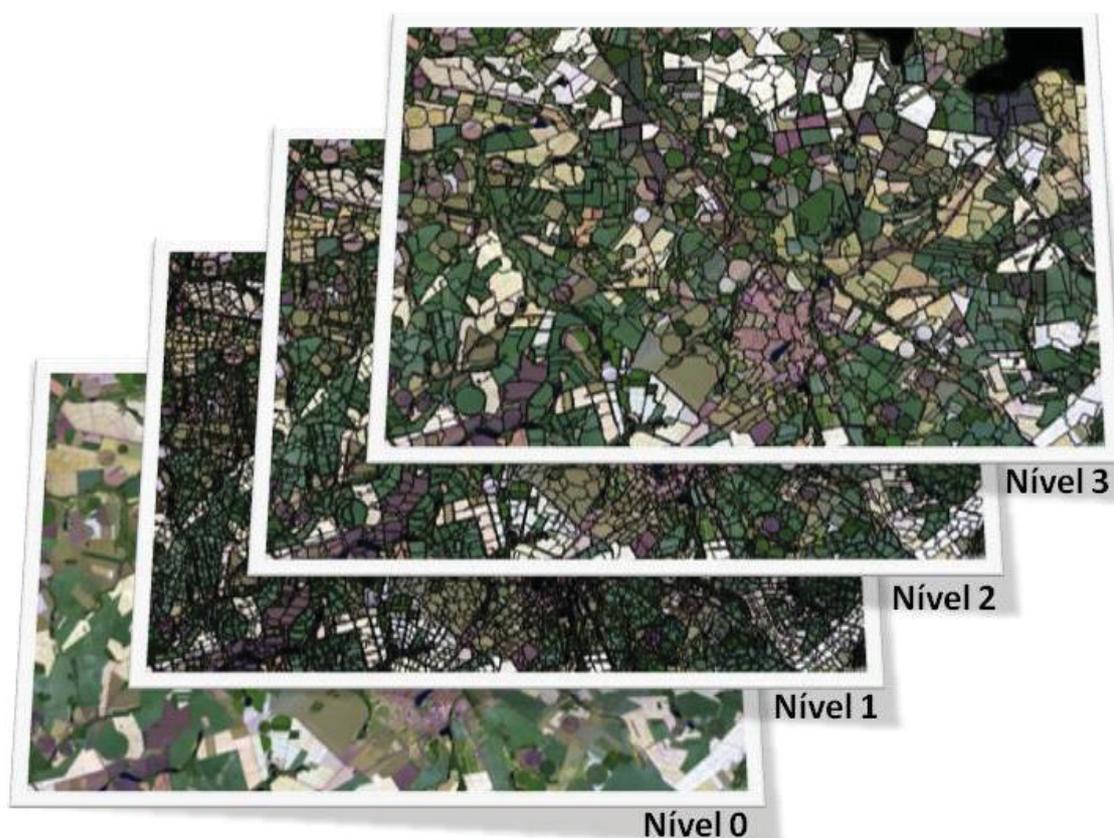
Os objetos resultantes desta segmentação são baseados em parâmetros espaciais (forma) e espectrais (valor digital), podendo ainda ser reagrupados em objetos maiores por meio de fusão, originando os superobjetos ou regiões. A geração de superobjetos cria uma rede hierárquica definida topologicamente, ou seja, a borda de um superobjeto é consistente com as bordas de seus subobjetos. Assim, cada região possui relações com os segmentos que a formaram, fazendo com que cada objeto conheça seu contexto, sua vizinhança, seus subobjetos e superobjetos (BAATZ; SCHÄPE, 1999), o que favorece análise precisa dentro de uma região específica. A FIGURA 5 mostra uma rede hierárquica definida topologicamente entre os objetos construídos em diferentes escalas.

A construção da rede hierárquica utilizando vários níveis de segmentação permite a extração de objetos de interesse representados em cada nível. Desta forma é importante que a segmentação seja realizada em quantos níveis (resoluções) forem necessários para separar os objetos de interesse, de maneira que possam ser reconhecidos e extraídos.

O procedimento de segmentação multirresolução pode ser descrito como uma técnica de crescimento de regiões. Ela inicia com cada *pixel* formando um objeto imagem. Em cada etapa (iteração), um par de objetos é fusionado, formando um objeto maior. A decisão de fusionar ou não dois objetos, é baseada em critérios de homogeneidade local, descrevendo a similaridade dos objetos adjacentes. O critério de homogeneidade não define apenas se a agrupamento é adequado ou não, é calculado um custo para cada agrupamento possível. O custo de agrupamento representa o grau de adequação. Para um possível agrupamento, o grau de adequação é calculado e caso o valor seja menor que um dado grau de adequação de referência realiza-se a fusão dos objetos. Este processo é iterativo e encerra-se quando não existem mais fusões possíveis sem ultrapassar o valor do grau de adequação de referência. O grau de

adequação de referência é expresso em termos de um parâmetro de escala. Desta forma, quanto maior o parâmetro de escala, maior o número de fusões e consequentemente, maior o tamanho médio dos objetos (BAATZ; SCHÄPE, 2000).

FIGURA 5 – SEGMENTAÇÃO MULTIRRESOLUÇÃO E REDE HIERÁRQUICA DE OBJETOS DEFINIDOS TOPOLOGICAMENTE.



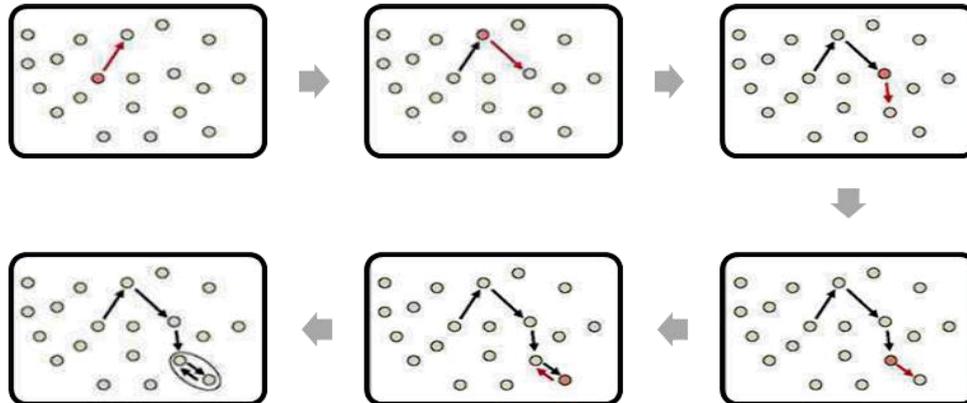
FONTE: O autor (2018).

A segmentação multirresolução possui dois principais componentes, que são: i) Decisão Heurística e ii) Definição da homogeneidade. Em (i), determina-se quais objetos devem ser fusionados em cada etapa, e em (ii), define-se a homogeneidade dos objetos para se calcular o grau de adequação do par de objetos-imagem candidatos à fusão (BAATZ; SCHÄPE, 2000).

Dada uma definição para homogeneidade (e heterogeneidade consequentemente) um método para encontrar os objetos para uma fusão é requerido (BAATZ; SCHÄPE, 2000). No *software* eCognition®, a Decisão Heurística é realizada utilizando a abordagem de Ajustamento Ótimo Mútuo Local (*Local Mutual Best Fitting*). Para tanto, os objetos a serem agrupados são determinados da seguinte forma: para um dado objeto *A* procura-se o seu objeto vizinho *B* com o qual o critério de homogeneidade é mais bem atendido. Em seguida procura-se para *B* o objeto vizinho *C* com o qual *B* cumpre melhor o critério de homogeneidade. Depois de encontrado, confirma-se se o critério de homogeneidade é atendido de forma mútua, ou seja, $C = A$. Se o critério de mutualidade for atendido o agrupamento é realizado. Caso contrário, a busca é

novamente realizada alterando-se o objeto de partida. Esta heurística permite encontrar o melhor conjunto de objetos na vizinhança local de A , seguindo o gradiente de homogeneidade. A FIGURA 6 exemplifica este processo (TRIMBLE, 2012a).

FIGURA 6 – DECISÃO HEURÍSTICA PARA DETERMINAÇÃO DOS OBJETOS A SEREM AGRUPADOS EM CADA CICLO.

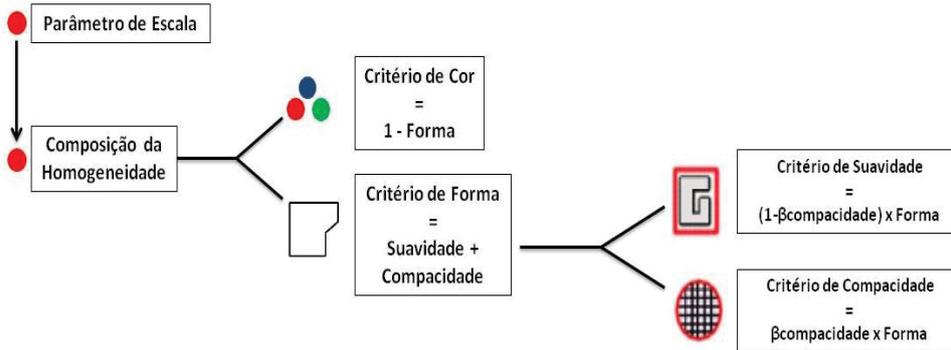


FONTE: Adaptado de TRIMBLE (2012a).

A homogeneidade de um objeto para uma determinada escala é definida na etapa de Composição do Critério de Homogeneidade. Aqui, homogeneidade é usada como sinônimo de heterogeneidade minimizada. Para tanto, três critérios são considerados no cálculo da heterogeneidade dos objetos: cor, suavidade e compacidade. Estes três critérios podem ser aplicados de diversas maneiras, porém, na maioria dos casos o parâmetro de cor é o mais importante na criação de objetos que possuem significado real. No entanto, a forma pode melhorar a qualidade da extração de objetos, principalmente quando estes possuem forte textura, como por exemplo, os dados de radar (TRIMBLE, 2012a).

No cálculo da heterogeneidade, cada componente do par de critérios (cor e forma; suavidade e compacidade) deve ser ponderado percentualmente (equalizado ao valor 1), ou seja, atribuindo-se peso 0,6 para a cor, proporcionalmente tem-se peso 0,4 para a forma. Neste caso, não se deve atribuir à forma um valor maior que 0,9, pois, assim os objetos resultantes não estarão relacionados com a informação espectral (TEDESCO, 2015). A FIGURA 7 ilustra os parâmetros a serem definidos antes da segmentação.

FIGURA 7 – PARÂMETROS DE SEGMENTAÇÃO MULTIRRESOLUÇÃO.



FONTE: Adaptado de TRIMBLE (2012a).

Desta forma, na etapa de Composição da Homogeneidade são realizados os seguintes cálculos para avaliação do custo de fusão (BAATZ et al. 2001):

1. **Heterogeneidade espectral ($h_{\text{espectral}}$):** é descrita pelo desvio padrão dos *pixels* que compõem o objeto em cada banda. É adotado o somatório dos desvios padrão (σ_c) dos valores espectrais em cada banda (c) ponderados pelo peso atribuído para cada banda:

$$h_{\text{espectral}} = \sum_c W_c * \sigma_c \quad (1)$$

2. **Compacidade:** representa quão compactado estão os *pixels* de um determinado objeto. O critério de compacidade deve ser usado quando o contraste espectral entre os objetos não permite a separação entre eles. O peso para o critério de compacidade assume valores entre o intervalo [0; 1]. O coeficiente é dado por:

$$h_{\text{compac}} = \frac{L}{\sqrt{n}} \quad (2)$$

onde L é o perímetro da borda do objeto e n é o número de *pixels* formadores do objeto.

3. **Suavidade:** representa o grau de irregularidade do contorno de um objeto. O coeficiente é obtido pela comparação do perímetro do objeto (L) com o perímetro do menor retângulo envolvente (b):

$$h_{\text{suav}} = \frac{L}{b} \quad (3)$$

4. **Heterogeneidade de forma (h_{forma}):** é função dos coeficientes de compacidade e suavidade, dado por:

$$h_{\text{forma}} = W_{\text{compac}} * h_{\text{compac}} + (1 - W_{\text{compac}}) * h_{\text{suav}} \quad (4)$$

5. **Custo de fusão (f):** verifica o grau de adequação da fusão entre dois objetos, caso o valor f esteja abaixo do valor definido no parâmetro de escala o agrupamento é realizado.

$$f = W * h_{\text{espectral}} + (1 - W) * h_{\text{forma}} \quad (5)$$

onde W é o peso atribuído à cor ($0 \leq W \leq 1$); $h_{\text{espectral}}$ e h_{forma} são as heterogeneidades calculadas nas equações (1) e (4) respectivamente.

6. **Mudança na heterogeneidade espectral após a fusão ($h_{\text{esp-fus}}$):** este parâmetro é calculado de forma virtual, mesmo antes de ocorrer a fusão, fornecendo previamente a diferença da $H_{\text{espectral}}$ dos objetos antes e após a fusão. Isto é necessário, pois o método visa fusionar os objetos que aumentem o mínimo possível a heterogeneidade. É calculado por:

$$h_{\text{esp-fus}} = \sum_c W_c * [n_{\text{fusão}} * \sigma_c^{\text{fusão}} - (n_{\text{obj1}} * \sigma_c^{\text{Obj1}} + n_{\text{obj2}} * \sigma_c^{\text{Obj2}})] \quad (6)$$

sendo: W_c o peso atribuído a cada banda c ; $n_{\text{fusão}}$ o número de *pixels* do objeto após a fusão; n_{obj1} o nº de *pixels* do objeto 1 antes da fusão; n_{obj2} o nº de *pixels* do objeto 2 antes da fusão; $\sigma_c^{\text{fusão}}$ desvio padrão dos valores espectrais do objeto após a fusão em cada banda c ; σ_c^{Obj1} e σ_c^{Obj2} os desvios padrão dos objetos 1 e 2 antes da fusão.

7. **Mudança na heterogeneidade espacial após a fusão:** do mesmo modo que no caso anterior, é calculada a diferença entre a heterogeneidade da forma, sendo esta, avaliada pela mudança nos parâmetros de compacidade e suavidade:

$$h_{\text{suav-fusão}} = n_{\text{fusão}} * \frac{L_{\text{fusão}}}{b_{\text{fusão}}} - (n_{\text{obj1}} * \frac{L_{\text{obj1}}}{b_{\text{obj1}}} + n_{\text{obj2}} * \frac{L_{\text{obj2}}}{b_{\text{obj2}}}) \quad (7)$$

$$h_{\text{compac-fusão}} = n_{\text{fusão}} * \frac{L_{\text{fusão}}}{\sqrt{n_{\text{fusão}}}} - (n_{\text{obj1}} * \frac{L_{\text{obj1}}}{\sqrt{n_{\text{obj1}}}} + n_{\text{obj2}} * \frac{L_{\text{obj2}}}{\sqrt{n_{\text{obj2}}}}) \quad (8)$$

sendo $n_{\text{fusão}}$ = número de *pixels* do objeto após a fusão; $L_{\text{fusão}}$ = perímetro do objeto após a fusão; $b_{\text{fusão}}$ = perímetro do retângulo envolvente do objeto após a fusão; n_{obj1} = número de *pixels* do objeto 1, antes da fusão; n_{obj2} = número de *pixels* do objeto 2, antes da fusão; L_{obj1} = perímetro do objeto-imagem 1; L_{obj2} = perímetro do objeto-imagem 2; b_{obj1} = perímetro do

retângulo envolvente do objeto-imagem 1, e b_{obj2} = perímetro do retângulo envolvente do objeto-imagem 2.

2.7 CLASSIFICAÇÃO

Um dos principais objetivos do sensoriamento remoto orbital é a extração das informações contidas nas imagens e a tradução em documentos mais simples, que possam ser lidos e interpretados nas formas de tabelas, gráficos ou mapas. Para extrair informações das imagens é necessário o estabelecimento de regras claras e lógicas que possam ser replicadas por qualquer analista na interpretação do dado. Essas regras estabelecem critérios para a análise dos elementos que compõem a paisagem, valendo-se das propriedades específicas de cada classe de interesse (MENESES; SANO, 2012).

As técnicas de classificação digital de imagens surgiram da necessidade de automatizar o processo de extração de informações das imagens, eliminando a subjetividade da interpretação humana e reduzindo o esforço de trabalho do analista, que por vezes necessita analisar grandes extensões espaciais num elevado número de bandas e datas (MENESES; SANO, 2012). Desta forma, a classificação de imagens pode ser entendida como um processo de extração de informações, onde visa reconhecer padrões e objetos homogêneos. É constituída basicamente pelo processo de atribuição de *pixels* ou objetos à determinada classe nas quais as características ou propriedades destes correspondam à descrição da classe em questão. O resultado final de um processo de classificação é um mapa temático, que possibilita a visualização das informações de maneira simplificada.

No campo do sensoriamento remoto orbital, a classificação de imagens tem sido um dos principais focos de pesquisa pela comunidade científica, pois os resultados oriundos de uma classificação constituem a base para aplicações em diversas áreas (Ciências agrárias, Cartografia, Geografia, etc). Cientistas e profissionais têm dedicado esforços para desenvolver técnicas e soluções avançadas para melhorar a acurácia das classificações. No entanto, classificar dados sensoriados para gerar mapas temáticos ainda é um grande desafio, pois os resultados podem ser influenciados por diversos fatores: complexidade das paisagens imageadas, fonte de dados, resoluções da imagem, técnicas de processamento de imagens e classificação (LU; WENG, 2007).

De acordo com Nath et al. (2014), vários critérios podem ser utilizados para agrupar os algoritmos classificadores, como supervisionados ou não supervisionados, paramétricos e não paramétricos, entre outros. Outra forma que esses algoritmos podem ser agrupados é com

base na natureza da informação do *pixel* usada nos dados, onde podem ser divididos em quatro categorias:

- **Classificadores por *pixel*:** classificadores tradicionais que desenvolvem uma assinatura espectral para cada classe com base nos valores digitais do conjunto de treinamento. A assinatura resultante contém as contribuições de todos os materiais presentes nos *pixels* amostrais, ignorando o impacto dos *pixels* mistos.
- **Classificadores subpixel:** o valor espectral de cada pixel é assumido como uma combinação linear ou não linear de materiais puros definidos, chamados de *endmembers*. O classificador faz uma associação proporcional de cada pixel a cada *endmember*.
- **Classificadores baseados em objeto:** neste caso, utiliza-se da segmentação de imagens para agrupar *pixels*, formando objetos, tendo em vista que, um segmento da imagem passa a ser considerado objeto a partir do momento que seus atributos são conhecidos. A classificação é realizada com base nos objetos e não nos *pixels* individuais.
- **Classificadores por campo:** classificador baseado em abordagens integradas com Sistema de Informações Geográficas (SIG). O SIG desempenha importante papel neste tipo de algoritmo, integrando dados raster e vetoriais na classificação. Os dados vetoriais são usados para subdividir uma imagem em parcelas, e a classificação é baseada nestas parcelas, minimizando os efeitos da variação espectral dentro da mesma classe.

2.7.1 Classificação Orientada a Objeto

No paradigma da análise orientada a objetos com o *software* eCognition®, a classificação é a etapa que ocorre após a criação dos objetos-imagem no processo de segmentação multirresolução. Nesta fase, o algoritmo de classificação analisa os objetos-imagem de acordo com critérios definidos pelo usuário (descrição de classe) e os atribui à classe

que melhor se adéquam (TRIMBLE, 2012b). A descrição de classe pode ser definida pelo usuário, criando funções de pertinência para cada descritor. O *software* eCognition® possui uma extensa lista de descritores, que estão relacionados à geometria, posição, textura, cor, hierarquia, e outras relações que podem ser inferidas e analisadas nos objetos-imagem.

Os algoritmos de classificação disponíveis no *software* eCognition® são agrupados em dois grupos: i) *Basic Classification Algorithms* (Algoritmos Básicos de Classificação), e ii) *Advanced Classification Algorithms* (Algoritmos Avançados de Classificação). Estes grupos são apresentados a seguir.

2.7.1.1 *Basic Classification Algorithms*

- *Assign Class*: atribui todos os objetos-imagem à classe especificada pelo usuário (apenas uma classe). O valor da associação para a classe atribuída é definido como 1 para todos os objetos, independentemente da descrição da classe. Os resultados da segunda e terceira melhor classificação são definidos como 0 (TRIMBLE, 2012b). Este algoritmo é recomendado quando os objetos-imagem de interesse podem ser descritos por apenas um atributo, onde o uso de um simples limiar pode separar os objetos em pertencentes e não pertencentes à classe;
- *Classification*: avalia o valor da associação de um objeto-imagem em uma lista de classes selecionadas. O resultado da classificação do objeto-imagem é atualizado de acordo com o resultado da avaliação de classe. As três melhores classes são armazenadas no resultado da classificação do objeto-imagem. Classes sem uma descrição, são consideradas como tendo um valor de associação igual a 1 (TRIMBLE, 2012b). *Classification* pode ser utilizado para classificar mais de uma classe ao mesmo tempo, sendo que os atributos dos objetos-imagem são comparados aos descritores de cada classe. Neste caso, é necessário que o usuário defina as funções de pertinência ou de associação de cada descritor em cada classe;
- *Hierarchical Classification*: este algoritmo avalia o valor da associação de um objeto-imagem em relação a uma lista de classes selecionadas. O resultado da classificação do objeto-imagem é atualizado de acordo com o resultado da

avaliação de classe. As três melhores classes são armazenadas como o resultado da classificação do objeto-imagem. Presume-se que as classes sem uma descrição de classe tenham um valor de associação igual a 0. Esse algoritmo é otimizado para aplicar hierarquias de classes complexas a níveis inteiros de objetos-imagem. Ao se trabalhar em processos com classificação de domínios específicos, os algoritmos *Assign Class* e *Classification* são recomendados (TRIMBLE, 2012b).

2.7.1.2 *Advanced Classification Algorithms*

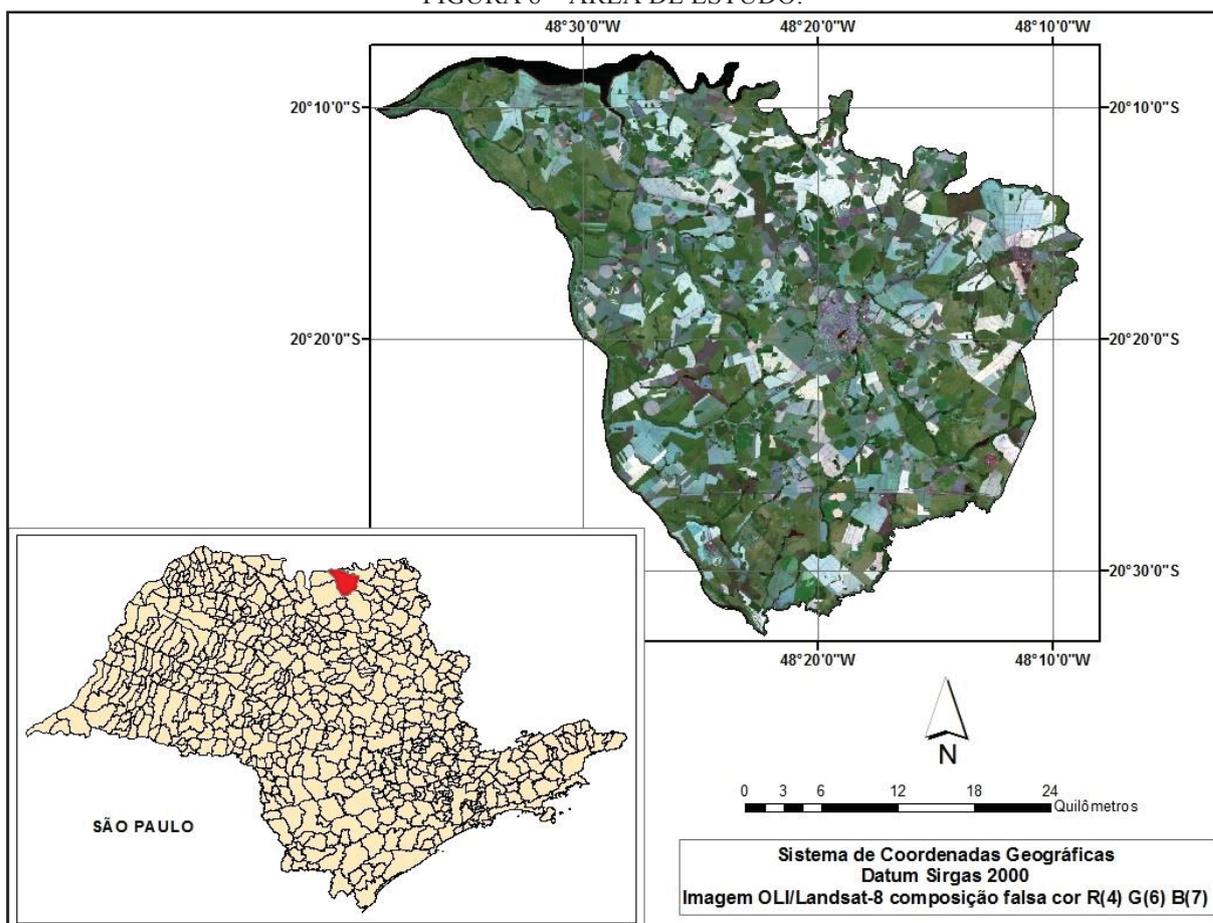
- *Find Domain Extrema*: classifica objetos-imagem que possuem os maiores e menores valores para um determinado atributo, dentro do domínio dos objetos-imagem (TRIMBLE, 2012b);
- *Find Local Extrema*: classifica os objetos-imagem que atende a uma condição extrema local, de acordo com os atributos dos objetos-imagem dentro de um domínio de pesquisa em suas vizinhanças (TRIMBLE, 2012b);
- *Find Enclosed by Class*: encontra e classifica objetos-imagem que estão completamente circundados por outro objeto-imagem pertencentes a uma determinada classe (TRIMBLE, 2012b);
- *Find Enclosed by Image Object*: encontra e classifica objetos-imagem que estão circundados por outros objetos-imagem (TRIMBLE, 2012b);
- *Connector*: classifica objetos-imagem que fazem a menor conexão entre o objeto-imagem sob análise e outro objeto-imagem que se encontra nas condições estabelecidas nas configurações do algoritmo (TRIMBLE, 2012b);
- *Classifier*: o algoritmo permite aplicar as funções de aprendizado de máquina (*machine-learning*). A utilização acontece num processo de duas etapas. Em primeiro lugar, um classificador é treinado, usando os objetos classificados do domínio dos objetos-imagem, como amostras de treinamento. Este algoritmo pode ser utilizado como classificador *pixel a pixel* ou orientado a objetos. Pode utilizar os classificadores *Bayes*, *KNN*, *SVN* ou *Decision Tree* (TRIMBLE, 2012b);

3 MATERIAL E MÉTODOS

3.1 ÁREA DE ESTUDO

A área de estudo corresponde ao município de Guaíra - SP, localizado entre as latitudes $20^{\circ}07'33,1''$ e $20^{\circ}32'46,5''$ S e longitudes $48^{\circ}08'45,5''$ e $48^{\circ}38'48,9''$ W. O município possui uma área territorial de 1.258,465 km² e conta com uma população estimada em pouco mais de 40 mil habitantes (IBGE-CIDADES, 2017), sendo a produção agropecuária a maior geradora de empregos e divisas, com destaque para a produção de Cana-de-açúcar. O município também se destaca no estado de São Paulo como maior polo de irrigação. Os solos predominantes no município são classificados como Latossolo vermelho distrófico de textura argilosa ou muito argilosa (IBGE-EMBRAPA, 2001).

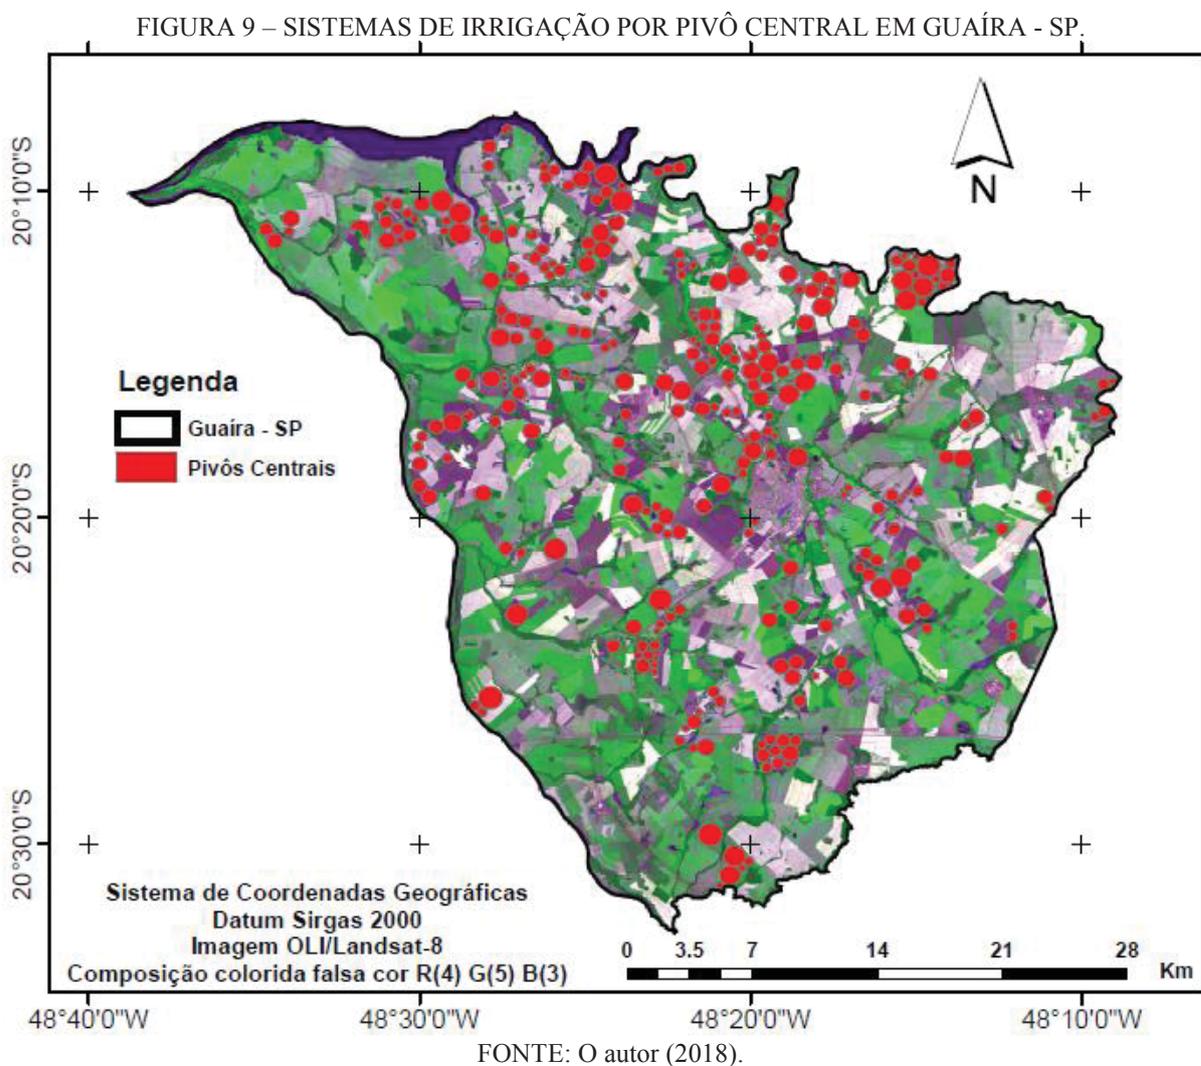
FIGURA 8 – ÁREA DE ESTUDO.



FONTE: O autor (2018).

O município de Guaíra possui mais de 105 mil hectares (ha) destinados à produção agrícola, dos quais 60 mil ha são ocupados com Cana-de-açúcar, 25 mil ha com Soja (grão), 15 mil ha com Milho (grão), 3,5 mil ha com Feijão (grão) e 1,6 mil ha com outras culturas

temporárias e permanentes (IBGE-PAM, 2016). De acordo com o levantamento realizado pela ANA (2016), deste total de área agrícola pouco mais de 14 mil ha são equipados com sistema de irrigação por pivô central, distribuídos em 350 equipamentos, conforme ilustrado na FIGURA 9.



A seleção deste município foi realizada considerando a área ocupada por pivôs centrais e a relação entre o número de pivôs e a área municipal, aqui denominado de Índice de Ocorrência (IOc), conforme a fórmula:

$$IOc = \frac{Np}{Am} \quad (12)$$

onde:

- IOc = Índice de Ocorrência de equipamentos de Pivôs Centrais, dado em Pivôs.km⁻²;
- Np = Número de equipamentos de irrigação do tipo Pivô Central existente no município no ano de 2014 (ANA, 2016);

- Am = Área territorial do município em km^2 .

Este índice foi escolhido como critério de seleção, por conta do caráter experimental deste estudo, visando otimizar o tempo de processamento. Desta forma, é de crucial importância o uso de imagens que possuam ao mesmo tempo a menor dimensão e a maior quantidade de informação de interesse possível. A TABELA 1 apresenta os valores calculados de IOc para os 15 municípios com maior área irrigada por pivô central no Brasil.

TABELA 1 – POSIÇÃO, NOME, NÚMERO DE EQUIPAMENTOS, ÁREA MUNICIPAL, IOc E ÁREA OCUPADA PELOS PIVÔS CENTRAIS PARA OS 15 MUNICÍPIOS BRASILEIROS COM MAIOR ÁREA IRRIGADA POR PIVÔ CENTRAL.

Posição	Nome do Município	Número de Equipamentos	Área Municipal (km^2)	IOc (Pivô. km^2)	Área Ocupada (ha)
1°	Unaí-MG	663	8.448,082	0,08	61.151
2°	Paracatu-MG	882	8.229,595	0,11	59.752
3°	Cristalina-GO	698	6.162,089	0,11	56.072
4°	Barreiras-BA	340	7.538,152	0,05	34.870
5°	Mucugê-BA	503	2.462,153	0,20	34.293
6°	São Desidério-BA	316	15.116,398	0,02	33.368
7°	Primavera do Leste-MT	168	5.482,065	0,03	20.212
8°	Jaborandi-BA	163	9.994,479	0,02	18.221
9°	Luís Eduardo Magalhães-BA	177	4.245,046	0,04	16.298
10°	Rio Paranaíba-MG	280	1.352,353	0,21	14.422
11°	Itaí-SP	288	1.082,782	0,27	14.368
12°	Guaíra-SP	350	1.258,465	0,28	14.323
13°	Brasília-DF	225	5.779,997	0,04	13.479
14°	Sorriso-MT	98	9.329,604	0,01	13.207
15°	Paranapanema-SP	292	1.018,724	0,29	12.619

FONTE: O autor (2018).

3.2 MATERIAL

Para a realização deste estudo foi utilizado o seguinte material:

- ✓ Notebook com processador Intel Core I7 de 2,7 GHz, 6 Gb de memória RAM, Disco rígido de 600 Gb, Sistema Operacional Windows 7 de 64 Bits;
- ✓ *Software* ENVI versão 4.7;
- ✓ *Software* eCognition® Developer versão 8.8;
- ✓ *Software* ArcGIS 10.3;
- ✓ Série temporal de imagens OLI/LANDSAT-8 para o ano de 2014, entre os meses de abril e setembro;

As licenças dos softwares utilizados neste estudo foram disponibilizadas pela Universidade Federal do Paraná – Setor de Ciências da Terra. As imagens do sensor OLI do Satélite Landsat-8 foram selecionadas por meio do sítio eletrônico

<http://earthexplorer.usgs.gov/> e posteriormente adquiridas de forma *on demand*, sem custo por meio da plataforma <https://espa.cr.usgs.gov/>, ambos os sítios pertencentes ao *United States Geological Survey* (USGS).

As imagens adquiridas no modo *on demand* no sítio da USGS são fornecidas pré-processadas, desta forma o usuário não necessita realizar os procedimentos de registro, correção atmosférica e definição do sistema de projeção. De modo opcional, o usuário também pode solicitar que as imagens sejam convertidas em Reflectância de Superfície (*Surface Reflectance*) e/ou Reflectância no Topo da Atmosfera (*Top of Atmosphere Reflectance*) além de índices espectrais, como NDVI (*Normalized Difference Vegetation Index*), EVI (*Enhanced Vegetation Index*), SAVI (*Soil Adjusted Vegetation Index*), MSAVI (*Modified Soil Adjusted Vegetation Index*), NDMI (*Normalized Difference Moisture Index*), NBR (*Normalized Burn Ratio*) e NBR2 (*Normalized Burn Ratio 2*) (USGS – Users Guide, 2017). Na TABELA 2 são apresentadas as principais características do sensor OLI a bordo do Satélite Landsat-8.

TABELA 2 – PRINCIPAIS CARACTERÍSTICAS DO SENSOR OLI DO SATÉLITE LANDSAT-8.

Nome das Bandas	Resolução Espectral (μm)	Resolução Espacial (m)	Resolução Temporal (dias)	Resolução Radiométrica (Bits)
Banda 1 – Coastal aerosol	0.433 – 0.453	30		
Banda 2 – Blue	0.450 – 0.515	30		
Banda 3 – Green	0.525 – 0.600	30		
Banda 4 – Red	0.630 – 0.680	30		
Banda 5 – NIR	0.845 – 0.885	30	16	12
Banda 6 – SWIR* 1	1.560 – 1.660	30		
Banda 7 – SWIR 2	2.100 – 2.300	30		
Banda 8 – PAN	0.500 – 0.680	15		
Banda 9 – Cirrus	1.360 – 1.390	30		

* SWIR (Shortwave Infrared).

FONTE: Adaptado de BARSÍ et al. (2014).

3.3 MÉTODOS

A definição do período para composição da série temporal para o ano de 2014 foi baseada na análise do Balanço Hídrico Sequencial (BHS) para os municípios de Ituverava-SP e Conceição das Alagoas-MG, por serem os municípios mais próximos da área de estudo (dentro de um raio de 55 km), que possuem estações climatológicas vinculadas ao Instituto Nacional de Meteorologia (INMET).

O balanço hídrico (BH) desenvolvido por Thornthwaite e Mather (1955) nada mais é que um sistema contábil de entrada e saída de água no solo, resultado da aplicação do princípio de conservação de massa para a água num dado volume de solo vegetado. A entrada de água é

representada pela precipitação ou irrigação e a saída pela evapotranspiração potencial (NETO, 1989).

Em função do tipo aplicação, o balanço hídrico pode ser classificado como o balanço hídrico normal ou balanço hídrico sequencial:

- Balanço hídrico normal ou climatológico: É apresentado na escala mensal e para um “ano médio”. O BH normal é importante para o planejamento agrícola, caracterização climática de uma região, servindo de subsídio para a determinação da melhor época e tipo de manejo da exploração agrícola.
- Balanço hídrico sequencial (BHS): Permite acompanhar a disponibilidade de água no solo no momento de seu cálculo, podendo ser a escala de tempo compatível com as tomadas de decisões, ou seja, diária, semanal, decenal ou mensal.

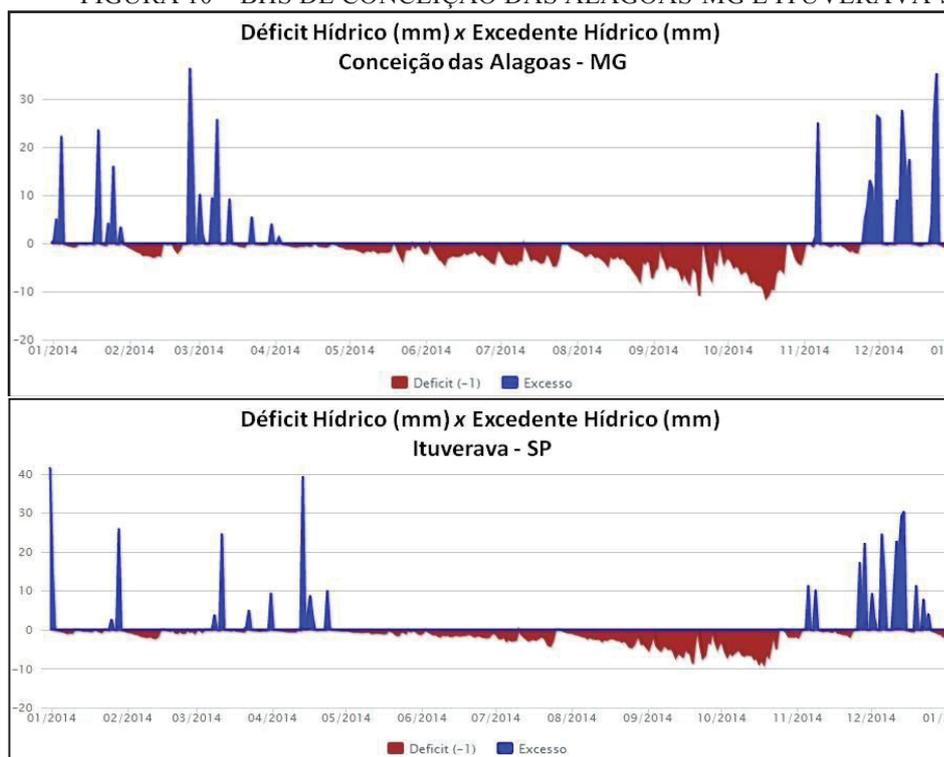
Para o cálculo do BH são utilizadas variáveis climatológicas obtidas em estações de observação (temperatura, umidade relativa, precipitação, velocidade do vento), variáveis pedológicas (textura do solo) e outras obtidas de tabelas com base na latitude do local (horas de luz, etc.). O balanço hídrico é originalmente calculado por meio de tabelas, porém para facilitar a visualização e interpretação dos dados, estes são plotados em gráficos.

O balanço hídrico sequencial utilizado neste estudo foi gerado por meio da plataforma SISDAGRO (Sistema de Suporte à Decisão na Agropecuária), vinculada ao Instituto Nacional de Meteorologia (INMET), disponível do endereço: <http://sisdagro.inmet.gov.br/sisdagro/app/monitoramento/bhs>. No cálculo do BHS nesta plataforma é necessária a definição dos seguintes parâmetros:

- Data inicial: definiu-se 31/12/2013;
- Data final: definiu-se 31/12/2014;
- Estação: foram utilizadas as estações automáticas Ituverava – SP e Conceição das Alagoas – MG;
- Solo: usou-se a textura argilosa, com Capacidade de Armazenamento de Água (CAD) igual a 100 mm.

Uns dos principais produtos gerados pelo BHS são os relativos à variação do armazenamento de água no solo, que permitem a identificação dos períodos onde há deficiência ou excesso de água. Na FIGURA 10 os principais dados referentes à disponibilidade de água no solo para as duas estações são apresentados.

FIGURA 10 – BHS DE CONCEIÇÃO DAS ALAGOAS-MG E ITUVERAVA-SP.



FONTE: O autor (2018).

Pela análise da FIGURA 10, é possível aferir que no ano de 2014, o período favorável ao uso de sistemas de irrigação ficou compreendido entre os meses de abril a outubro. Desta forma, se buscou imagens da área de estudo livre de nuvens dentro deste período para compor a série temporal.

Neste estudo foram realizados três experimentos, sendo que o Experimento I utilizou imagens com 30 metros de resolução espacial e a classificação foi realizada apenas com descritores de forma; o Experimento II utilizou imagens fusionadas, com resolução espacial de 15 metros, e a classificação também utilizou somente descritores de forma. O Experimento III utilizou as mesmas imagens que o Experimento II, contudo, a classificação utilizou descritores de forma, espectrais e um textural, conforme apresentado na TABELA 3.

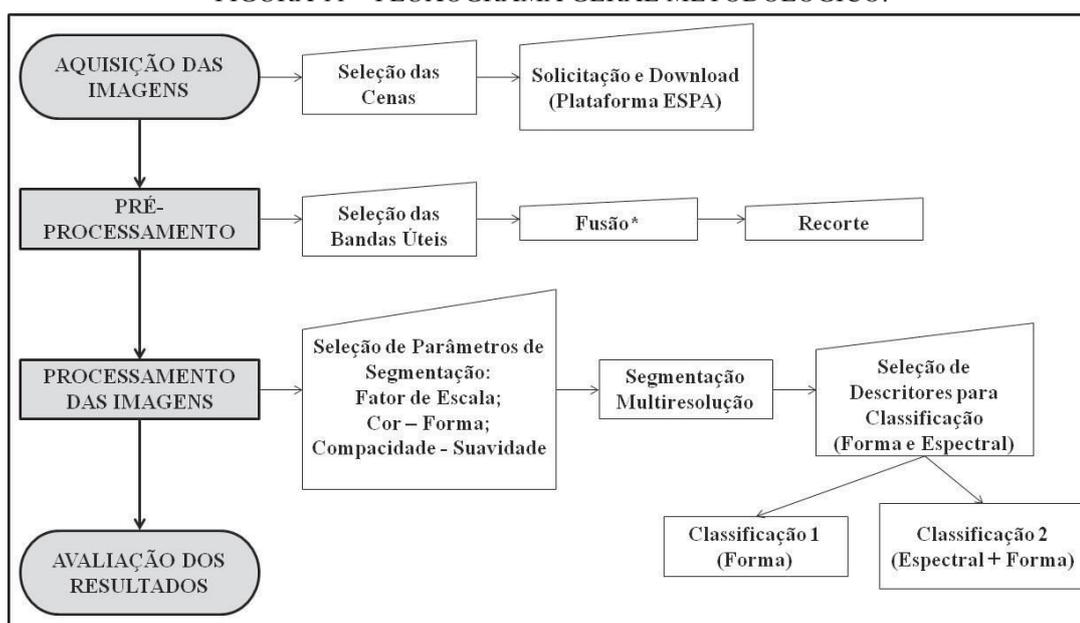
TABELA 3 – RESOLUÇÃO E TIPO DE CLASSIFICAÇÃO DE CADA EXPERIMENTO.

	Experimento I	Experimento II	Experimento III
Resolução espacial	30 metros	15 metros	15 metros
Classificação	Somente forma	Somente forma	Forma + Espectral + Textural

FONTE: O autor (2018).

A metodologia utilizada neste estudo segue o fluxograma geral apresentado na FIGURA 11. O detalhamento de cada fase é apresentado em seguida, assim como as particularidades de cada experimento.

FIGURA 11 – FLUXOGRAMA GERAL METODOLÓGICO.



FONTE: O autor (2018).

*A fusão não foi realizada no Experimento I.

3.3.1 Aquisição das imagens

As imagens foram selecionadas e adquiridas por meio das plataformas pertencentes à USGS, conforme apresentadas na seção 3.2. Para composição da série temporal foram adquiridas seis cenas, compreendidas entre os meses de abril e setembro de 2014, conforme pode ser observado na TABELA 4.

TABELA 4 – CENAS UTILIZADAS NA SÉRIE TEMPORAL.

Imagem	Data da tomada	Órbita/Ponto
1	24 de abril de 2014	
2	14 de junho de 2014	
3	16 de julho de 2014	
4	01 de agosto de 2014	221/074
5	02 de setembro de 2014	
6	18 de setembro de 2014	

FONTE: O autor (2018).

3.3.2 Pré-processamento

A seleção das bandas úteis para o Experimento I se deu de forma visual, avaliando a resposta espectral dos alvos, onde se analisaram os contrastes propiciados entre os objetos de interesse e os demais objetos presentes na imagem, objetivando a melhor diferenciação possível. Para o Experimento I foram selecionadas as bandas 4 (Red), 6 (SWIR 1) e 7 (SWIR

2). Para os Experimentos II e III foram utilizadas as bandas 3 (Green), 4 (Red) e 5 (NIR), fusionadas com a banda 8 (PAN) para gerar imagens com resolução espacial de 15 metros.

A fusão das imagens foi realizada por meio do método de *Gram-Schmidt Spectral Sharpening*. Gram-Schmidt (GS) é um método que opera no domínio espectral das imagens, que garante uma imagem nítida com baixas distorções espectrais. A essência deste método é o uso da ortogonalização de Gram-Schmidt, que consiste em transformar um conjunto de vetores linearmente independentes de um espaço unitário em um conjunto de vetores ortogonais. Considera-se um espaço de vetores n -dimensionais, em que cada banda é um vetor de alta dimensão, sendo o primeiro vetor uma imagem pancromática simulada, que é a soma ponderada da intensidade das sucessivas bandas da imagem multiespectral. Após a etapa de ortogonalização, a imagem pancromática simulada é substituída por uma imagem pancromática de alta resolução. Em seguida, é realizada a transformação GS reversa, resultando nas imagens multiespectrais de maior resolução espacial (GROCHALA; KEDZIERSKI, 2017).

3.3.3 Processamento das imagens

A fase de processamento das imagens iniciou-se com a seleção dos parâmetros ótimos para a Segmentação Multirresolução. Para isso, foi realizada uma série de testes com várias combinações de Fator de Escala, Peso relativo de Cor - Forma e do Peso relativo da Compacidade - Suavidade. O teste seguiu até o momento em que foi possível obter bom isolamento dos objetos de interesse. Os valores utilizados para estes parâmetros variaram em cada experimento, e são apresentados nas seções 3.3.3.4, 3.3.3.5 e 3.3.3.6.

A etapa de seleção dos descritores para a classificação foi realizada com base nas análises dos objetos-imagem de interesse criados nos diferentes níveis de segmentação. Desta forma, foram selecionados e desenvolvidos os descritores espectrais, de forma e textural, apresentados a seguir.

3.3.3.1 Descritores Espectrais utilizados

Os descritores espectrais são baseados no valor de radiação emitida ou refletida pelos objetos em diferentes faixas do espectro eletromagnético. Assim, os valores armazenados em cada banda de uma imagem correspondem ao comportamento dos objetos (TRIMBLE, 2012a). Os descritores espectrais utilizados nos experimentos não estão implementados no *software* eCognition®, portanto, foi necessário fazer suas inclusões. Os descritores são:

- **Média espectral:** média dos valores digitais dos pixels, na banda L , que compõem o objeto-imagem. Calculado conforme a equação 13:

$$\bar{C}L = \frac{1}{n_p} \cdot \sum_{i=1}^{n_p} CL_i \quad (13)$$

Onde:

$\bar{C}L$ = média espectral do objeto-imagem, na banda L ;

n_p = número de pixels que compõem o objeto-imagem;

CL_i = valor digital do pixel i , na banda L ;

- **NDVI:** o Índice de Vegetação da Diferença Normalizada (*Normalized Difference Vegetation Index*) foi proposto por Rouse et al. (1973). O NDVI é calculado pela diferença dos valores de reflectância entre as bandas do infravermelho próximo (IVP) e do vermelho (VER). Essa diferença é normalizada pela divisão da soma das bandas IVP e VER, conforme a equação:

$$NDVI = \frac{IVP-VER}{IVP+VER} \quad (14)$$

O valor de NDVI varia de [-1.0, +1.0]. Valores negativos representam as nuvens e corpos hídricos, valores próximos de zero representam solo descoberto ou sem vegetação e, NDVI mais alto, indica maior grau de desenvolvimento vegetativo (LIU, 2006). O NDVI foi calculado para cada cena da série temporal, totalizando 6 índices.

- **Soma de NDVI:** representa o somatório dos valores de NDVI calculado para cada objeto-imagem em todas as cenas da série temporal.

$$\text{Soma NDVI} = \sum \text{NDVI} \quad (15)$$

3.3.3.2 Descritores de Forma utilizados

Os descritores de forma usados neste estudo são baseados na geometria dos objetos e, são calculados com base nos *pixels* que os formam (TRIMBLE, 2012a). Eles são descritos a seguir:

- **Área:** corresponde ao número de *pixels* que formam um objeto-imagem. O valor pode ser facilmente convertido em valores reais apenas multiplicando o número de *pixels* pela dimensão do *pixel* no terreno.

$$A_i = n_{p_i} \cdot u^2 \quad (16)$$

Onde:

A_i é a área do objeto i em *pixels* ou unidades métricas;

n_{p_i} é o número de *pixels* que formam o objeto-imagem i ;

u é a dimensão do *pixel* na unidade do sistema de coordenadas utilizado. Se a unidade for *pixels*, $u=1$.

- **Relação Comprimento/Largura:** este índice descreve o alongamento de um objeto-imagem. Quanto mais próximo de 1, mais regular (redondo ou quadrado) é o objeto. Esta relação pode ser calculada de forma aproximada por dois métodos:

1. O primeiro método é fazendo a relação dos autovalores da matriz de covariância do objeto-imagem, fazendo do maior autovalor o numerador da fração:

$$\gamma_i^{AV} = \frac{\lambda_1(i)}{\lambda_2(i)} \quad (17)$$

Onde:

γ_i^{AV} é a razão comprimento/largura do objeto-imagem i ;

$\lambda_1(i)$ e $\lambda_2(i)$ são os autovalores da matriz covariância do objeto-imagem i , sendo $\lambda_1(i) > \lambda_2(i)$;

2. O segundo método é usando o menor retângulo envolvente do objeto-imagem:

$$\gamma_i^{RE} = \frac{a^2 + ((1-f) \cdot b)^2}{A_i} \quad (18)$$

Onde:

γ_i^{RE} é a razão comprimento/largura do objeto-imagem i ;

a é o lado menor do retângulo envolvente;

b é o lado maior do retângulo envolvente;

A_i é a área do objeto i ;

f é o grau de preenchimento, dado pela razão entre a área do A do objeto i pela área do retângulo envolvente $a \cdot b$.

No software eCognition®, a relação comprimento/largura é calculada pelos dois métodos, e o menor é retornado como valor do objeto-imagem.

- **Raio do Menor Círculo Envolvente:** descreve a similaridade entre o objeto-imagem e uma elipse. O cálculo utiliza uma elipse com a mesma área que o objeto-imagem, baseada na matriz de covariância. A elipse é então ampliada por fator de escala até englobar todo o objeto, sendo retornada como valor do descritor a relação entre a elipse final pela inicial.
- **Circularidade ou Arredondamento (Roundness):** descreve quão similar um objeto-imagem é de uma elipse. É calculado pela diferença entre os raios do Maior Círculo Envolvente e do Maior Círculo Envolvido no objeto-imagem.

$$Circ = \varepsilon_v^{max} - \varepsilon_v^{min} \quad (19)$$

Onde:

ε_v^{max} é o raio do Menor Círculo Envolvente;

ε_v^{min} é o raio do Maior Círculo Envolvido;

3.3.3.3 Descritor de Forma Desenvolvido

- **Fator de Circularidade:** descreve a relação entre a área do objeto-imagem e a área de um círculo teórico, cujo raio é derivado do comprimento do objeto, conforme a expressão:

$$Fator\ de\ Circularidade = \frac{\text{Área do objeto-imagem}}{\text{Área do Círculo teórico}} \quad (20)$$

Onde:

$$\text{Área do Círculo teórico} = \pi r^2$$

$$r = \frac{\text{Comprimento}}{2}$$

$$\text{Comprimento} = \sqrt{n_{pi} \cdot \gamma_v}$$

n_{pi} = número de pixels que formam o objeto-imagem i ;

γ_v = relação Comprimento/Largura do objeto-imagem v ;

Este descritor também não está implementado no *software* eCognition®, e portanto, necessitou ser desenvolvido e implementado.

3.3.3.4 *Descritor Textural*

Em imagens digitais, a textura representa a variação local dos níveis de cinza ou valores digitais, que podem ser interpretados como variações nas superfícies físicas dos objetos. Superfícies rugosas são exibidas nas imagens com diferentes tonalidades de cinza, gerando grandes texturas em relação às superfícies planas e homogêneas, que possuem pouca ou nenhuma variação dos valores digitais. Para a classificação digital de imagens, um conjunto de variáveis desenvolvidas por Haralick, Shanmugan e Dinstein (1973), podem ser calculadas e utilizadas para identificação de diversos tipos de feições, dentre os quais podem ser citados: homogeneidade, contraste, dissimilaridade, entropia, momento angular de segunda ordem, média, desvio-padrão e correlação.

O descritor textural utilizado neste estudo é baseado na matriz de coocorrência de nível de cinza das imagens (GLCM – *Gray Level Co-occurrence Matrix*), de acordo com Haralick, Shanmugan e Dinstein (1973). A GLCM é uma tabulação que mostra quantas vezes diferentes combinações de níveis de cinza de pixel ocorrem em uma cena. Existe uma GLCM diferente para cada relação espacial, ou seja, para cada direção. Para o cômputo da invariância direcional, a soma de todas as quatro direções (0°, 45°, 90°, 135°) é calculada antes do cálculo da textura. Um ângulo de 0° representa a direção vertical, um ângulo de 90° a direção horizontal. No software eCognition®, a textura de Haralick é calculada para todos os pixels de um objeto-imagem (TRIMBLE, 2012a). Abaixo segue a descrição e formulação do descritor textural utilizado:

- **GLCM Contrast (all directions):** descreve o contraste de cada objeto-imagem, sendo calculado para todas as direções com base na GLCM. O contraste é conceitualmente o inverso da homogeneidade. Numericamente, o contraste apresenta uma medida de acúmulo de variação local dentro do objeto-imagem, sendo que quanto maior a textura, maior o valor do contraste. O contraste é descrito por:

$$GLCM\ Contrast = \sum_{i,j=0}^{N-1} P_{i,j} (i - j)^2 \quad (21)$$

Onde:

i é o número da linha da matriz co-ocorrência;

j é o número da coluna matriz co-ocorrência;

$P_{i,j}$ é o valor normalizado da célula i,j da GLCM;

N é o número de linhas ou colunas da matriz de co-ocorrência.

Os valores de GLCM Contrast variam entre 0 e 65025.

A classificação foi realizada utilizando duas abordagens diferentes: a primeira utilizou apenas descritores de forma, buscando explorar o caráter geométrico circular das áreas irrigadas por pivôs centrais, e; a segunda foi realizada utilizando descritores espectrais, de forma e textural. A seguir é apresentado o detalhamento da metodologia empregada em cada experimento.

3.3.3.5 Experimento I

No Experimento I, a série temporal utilizada foi composta por seis cenas (Tabela 4), tendo como base imagens com resolução espacial de 30 metros. Foram utilizadas as bandas 4 (Red), 6 (SWIR 1) e 7 (SWIR 2) do sensor OLI/Landsat-8.

A etapa de processamento das imagens nesse experimento se deu pelo uso da segmentação multirresolução e classificação dos objetos-imagem. Estes processos foram realizados em conjunto e de forma sequencial, no intuito de extrair o máximo possível de informações de interesse das imagens orbitais.

A segmentação multirresolução foi utilizada para criar diferentes níveis hierárquicos, onde se puderam isolar objetos-imagem de interesse. Esta fase do processamento foi dividida em oito etapas, sendo cada uma correspondente a um nível da rede hierárquica. A primeira etapa correspondeu à segmentação ao nível mais alto, com maior fator de escala, onde foi possível isolar objetos-imagem circulares com maior dimensão e, a oitava etapa, correspondeu ao nível mais baixo, utilizado para isolar objetos-imagem de menor tamanho. A TABELA 5 apresenta os parâmetros da segmentação multirresolução utilizados em cada nível hierárquico.

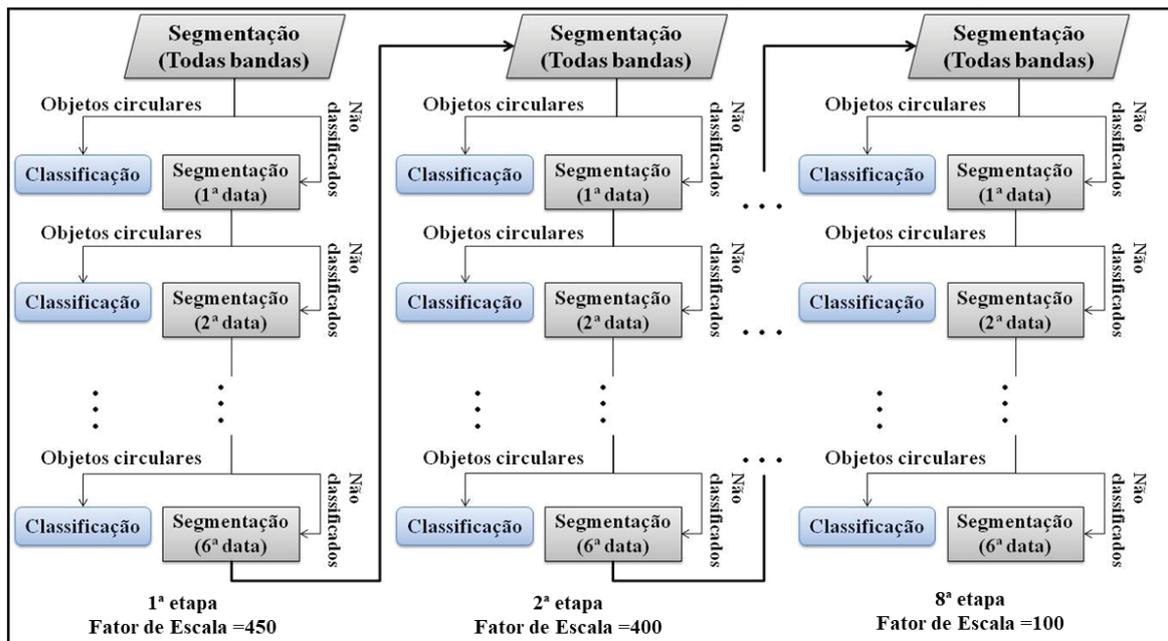
TABELA 5 – NÍVEIS HIERÁRQUICOS E PARÂMETROS DA SEGMENTAÇÃO MULTIRRESOLUÇÃO DO EXPERIMENTO I.

Etapa	Fator de Escala	Peso da Forma	Peso da Compacidade
1 ^a	450		
2 ^a	400		
3 ^a	350		
4 ^a	300		
5 ^a	250	0.5	0.5
6 ^a	200		
7 ^a	150		
8 ^a	100		

FONTE: O autor (2018).

Dentro de cada etapa, foi realizada uma sequência de sete segmentações e classificações. Este processo ocorreu da seguinte forma: (i) iniciando na primeira etapa, procedeu-se à segmentação multirresolução utilizando todas as 18 bandas da série temporal, o que resultou na geração de um número n de objetos-imagem de interesse, os quais foram classificados; (ii) em seguida, tomando por base a segmentação existente e excetuando os objetos-imagem já classificados, realizou-se uma nova segmentação dentro do mesmo nível, porém, utilizando apenas as três primeiras bandas da série temporal, que correspondem à primeira data (24/04/14). Assim, foram criados novos objetos-imagem que, foram classificados. O processo descrito em (ii) foi repetido para as bandas correspondentes à segunda (14/06/14), terceira (16/07/14), quarta (01/08/14), quinta (02/09/14) e sexta (18/09/14) datas da série temporal, sequencialmente, em todas as oito etapas, assim como ilustrado na Figura 12.

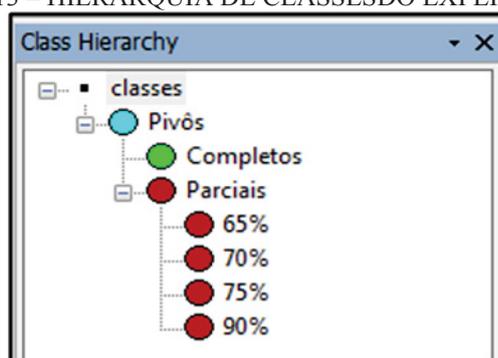
FIGURA 12 – FLUXOGRAMA DE SEGMENTAÇÃO E CLASSIFICAÇÃO.



FONTE: O autor (2018).

O fluxograma metodológico de segmentação e classificação apresentado na Figura 12 foi utilizado em todos os experimentos realizados neste estudo, alterando apenas o número de etapas e os respectivos fatores de escala. Ainda no Experimento I, a classificação foi realizada por meio do algoritmo *Classification*, implementado no eCognition®, utilizando somente os descritores de forma apresentados na Seção 3.3.3.2.

FIGURA 13 – HIERARQUIA DE CLASSES DO EXPERIMENTO II.



FONTE: O autor (2018).

No processo de classificação, a hierarquia das classes (Figura 13) foi definida com base nas variações em que os objetos de interesse podem ocorrer, ou seja, em quais possíveis variações os pivôs centrais podem ser encontrados. Desta forma, *a priori*, a classe “Pivôs” foi subdividida em “Completos” e “Parciais”. A subclasse “Completos” foi utilizada para receber os objetos-imagem com forma circular completa, ao passo que a subclasse “Parciais” foi destinada a agrupar os objetos-imagem que pertencem à classe dos pivôs, mas que não possuem forma circular completa. A subclasse “Parciais” foi subdividida durante o processo de classificação conforme a necessidade de classificar objetos-imagem relacionados à pivôs incompletos, sendo assim, foram criadas quatro subclasses (65%, 70%, 75% e 90%), com base no valor dado pelo descritor de forma “Fator de Circularidade”, que representa a proporção entre a área do objeto-imagem e a área de um círculo completo com o mesmo raio. Os limiares definidos para cada descritor utilizado na classificação são apresentados na TABELA 6.

TABELA 6 – LIMIARES DOS DESCRITORES UTILIZADOS PARA CLASSIFICAÇÃO NO EXPERIMENTO I.

Classe	Descritores de Forma			
	Área	Relação C/L*	Raio Menor Círculo**	Fator de Circularidade
Completos	60 – 3000	0.99 – 1.210	1.00 – 1.155	-
65%	250 – 270	1.15 – 1.270	1.30 – 1.330	0.640 – 0.660
70%	200 – 332	1.15 – 1.265	1.27 – 1.370	0.729 – 0.732
75%	500 – 800	1.00 – 1.650	1.30 – 1.330	0.740 – 0.771
90%	290 – 300	1.00 – 1.100	1.15 – 1.200	0.900 – 0.940

FONTE: O autor (2018).

*Relação Comprimento/Largura; ** Raio do Menor Círculo Envolvente.

3.3.3.6 Experimento II

No segundo experimento, a série temporal foi composta por imagens com resolução espacial de 15 metros, obtidas por meio de técnica de fusão com a banda pancromática. O processo de segmentação e classificação seguiu o mesmo fluxo metodológico descrito para o Experimento I (Figura 14), tendo diferenças apenas no número de níveis hierárquicos criados,

nos fatores de escala da segmentação, bem como nas subclasses e nos respectivos limiares dos descritores utilizados na classificação, conforme apresentado nas Tabelas 7 e 8.

TABELA 7 – NÍVEIS HIERÁRQUICOS E PARÂMETROS DA SEGMENTAÇÃO MULTIRRESOLUÇÃO DO EXPERIMENTO II.

Etapa	Fator de Escala	Peso da Forma	Peso da Compacidade
1 ^a	1000		
2 ^a	900		
3 ^a	800		
4 ^a	700		
5 ^a	600		
6 ^a	500	0.5	0.5
7 ^a	400		
8 ^a	300		
9 ^a	200		
10 ^a	150		

FONTE: O autor (2018).

TABELA 8 – LIMIARES DOS DESCRITORES UTILIZADOS PARA CLASSIFICAÇÃO NO EXPERIMENTO II.

Classe	Descritores de Forma			
	Área	Relação C/L*	Raio Menor Elipse**	Fator de Circularidade
Completo	178 – 6110	0.99 – 1.240	0.990 – 1.176	-
60%	1000 – 1200	1.36 – 1.390	1.400 – 1.430	0.600 – 0.6110
65%	1085 – 2782	1.00 – 1.350	1.346 – 1.420	0.630 – 0.6736
70%	180 – 1000	1.00 – 1.185	1.200 – 1.270	0.700 – 0.7050
75%	180 – 5000	1.00 – 1.200	1.300 – 1.370	0.750 – 0.7700
80%	180 – 5000	1.00 – 1.200	1.000 – 1.170	0.800 – 0.8400

FONTE: O autor (2018).

*Relação Comprimento/Largura; ** Raio do Menor Círculo Envolvente.

3.3.3.7 Experimento III

No Experimento III foi utilizada a mesma série temporal que o Experimento II. A sequência metodológica deste teste seguiu o mesmo fluxograma que os demais experimentos (Figura 12). Na TABELA 9 são apresentados o número de níveis hierárquicos e os parâmetros da segmentação multirresolução.

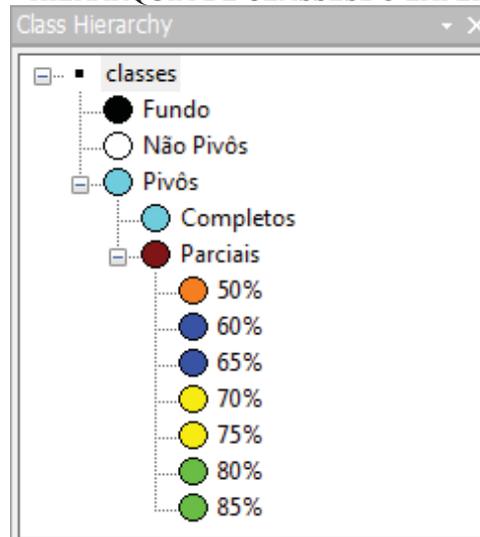
TABELA 9 – NÍVEIS HIERÁRQUICOS E PARÂMETROS DA SEGMENTAÇÃO MULTIRRESOLUÇÃO DO EXPERIMENTO III.

Etapa	Fator de Escala	Peso da Forma	Peso da Compacidade
1 ^a	1000		
2 ^a	900		
3 ^a	800		
4 ^a	700		
5 ^a	600		
6 ^a	500	0.5	0.5
7 ^a	400		
8 ^a	300		
9 ^a	200		
10 ^a	150		

FONTE: O autor (2018).

Na classificação foram utilizados, além dos descritores de forma, descritores espectrais e textural. Neste experimento também foi necessário criar duas outras classes, sendo uma para classificar o *background* da imagem, pois nesta região, apesar de conter apenas pixels com valores digitais iguais a zero, também geram objetos-imagem durante o processo de classificação. A outra classe foi criada para classificar objetos-imagem que não são pertencentes aos pivôs centrais. As classes foram nomeadas como “Fundo” e “Não Pivôs”, respectivamente, conforme apresentado na Figura 14.

FIGURA 14 – HIERARQUIA DE CLASSES DO EXPERIMENTO III.



FONTE: O autor (2018).

Para as classes “Fundo” e “Não Pivôs”, foram utilizados o algoritmo de classificação *Assign Class*. Para a classe “Pivôs” e suas subclasses, a classificação foi realizada com o algoritmo *Classification*, da mesma forma que nos experimentos anteriores. Na TABELA 10 são apresentados os limiares dos descritores utilizados no processo de classificação, exceto para o descritor textural *GLCM – Contrast*, que teve valores variáveis em cada etapa de classificação.

TABELA 10 – LIMIARES DOS DESCRITORES UTILIZADOS PARA CLASSIFICAÇÃO NO EXPERIMENTO III.

Classes	DESCRITORES						
	Forma			Espectral		Textural	
	Área	Relação C/L*	Raio Menor Círculo**	Fator de Circul.	Média	Soma NDVI	GLCM Contrast
Fundo	-	-	-	-	= 0	-	-
Não Pivôs	-	-	-	-	-	≤ 0.95	Variável
Completo	178 – 6400	0.99 – 1.241	0.99 – 1.170	-	-	-	-
50%	527 – 2525	1.75 – 2.130	-	0.464 – 0.550	-	-	-
60%	960 – 1205	1.30 – 1.325	-	0.600 – 0.622	-	-	-
65%	2274 – 3047	1.24 – 1.313	1.25 – 1.417	0.640 – 0.673	-	-	-
70%	3000 – 3200	1.10 – 1.175	1.20 – 1.555	0.687 – 0.718	-	-	-
75%	1018 – 3210	1.00 – 1.200	1.20 – 1.375	0.733 – 0.770	-	-	-
80%	820 – 823	1.00 – 1.200	-	0.783 – 0.810	-	-	-
85%	869 – 871	0.99 – 1.050	-	0.850 – 0.855	-	-	-

FONTE: O autor (2018).

*Relação Comprimento/Largura; ** Raio do Menor Círculo Envolvente.

3.3.4 Avaliação dos resultados

Os resultados das classificações obtidos em cada etapa foram analisados em termos do número total de objetos-imagem criados, classificados e corretamente classificados. A acurácia da classificação em cada etapa foi calculada pela seguinte fórmula:

$$Acurácia\ Relativa_{(i)}(\%) = \frac{N_{cci} - N_{cci-1}}{N_{Tci} - N_{Tci-1}} * 100 \quad (22)$$

Onde:

$Acurácia_{relativa\ (i)}$ é a acurácia relativa da classificação na etapa i ;

N_{cci} é o número de objetos-imagem corretamente classificados na etapa i ;

N_{cci-1} é o número de objetos-imagem corretamente classificados na etapa $i - 1$;

N_{Tci} é o número total de objetos-imagem classificados na etapa i , e;

N_{Tci-1} é o número total de objetos-imagem classificados na etapa $i - 1$.

Para o cálculo da acurácia global da classificação, realizou-se um mapeamento manual das áreas irrigadas por pivôs centrais, utilizando a mesma série temporal das classificações. Neste mapeamento, foram delimitados todos os pivôs completos e parciais que apresentaram

contraste suficiente, permitindo sua identificação em pelo menos uma data da série temporal. Com isso, chegou-se ao número de 304 pivôs centrais, que foi considerado como o número máximo passível de detecção. A acurácia global da classificação foi então calculada pela seguinte expressão:

$$Acurácia\ Global\ (\%) = \frac{N_{Tcc}}{N_{ref}} * 100 \quad (23)$$

Onde:

N_{Tcc} é o número de objetos-imagem corretamente classificados na última fase, e;

N_{ref} é o número de pivôs centrais de referência = 304.

Para cada pivô central identificado nas classificações, foi calculada a diferença entre a área do pivô central detectado e a do pivô central de referência. Para isto, foram criados arquivos vetoriais tanto para os pivôs centrais detectados quanto para os provenientes do mapeamento de referência e foram calculadas suas respectivas áreas, expressas em hectares (ha). Os valores correspondentes à área de cada pivô central foram extraídos da tabela de atributos dos arquivos vetoriais e analisados. A diferença da área foi calculada de acordo a expressão (24) e expressos em percentagem:

$$Diferença\ (\%) = \frac{A_{detectado} - A_{referência}}{A_{referência}} * 100 \quad (24)$$

Onde:

$A_{detectado}$ é a área do pivô central detectado, e;

$A_{referência}$ é a área do respectivo pivô central de referência.

4 RESULTADOS E DISCUSSÃO

A seguir, serão apresentados os resultados obtidos em cada experimento. Na sequência é realizada a discussão geral dos resultados.

4.1 RESULTADOS

4.1.1 Experimento I

Na TABELA 11 são apresentados os resultados obtidos no Experimento I. É mostrada para cada etapa, a quantidade de objetos-imagem criados, classificados, corretamente classificados, os erros de classificação, a acurácia relativa em cada etapa e a acurácia global. Observa-se que o número de objetos-imagem criado pela segmentação aumentou na medida em que o fator de escala diminuiu, resultando em objetos-imagem com tamanho médio menor. Na primeira etapa, o tamanho médio dos objetos-imagem criados foi de 1.516,77 pixels com desvio padrão de 1.630,21 pixels, ao passo que na oitava etapa o tamanho médio foi reduzido a apenas 143,39 pixels com desvio padrão de 173,29 pixels.

TABELA 11 – QUADRO RESUMO DOS RESULTADOS DA CLASSIFICAÇÃO DO EXPERIMENTO I.

Tamanho da Imagem = 2.712.478 pixels						
Etapa	Fator de Escala	Objetos-imagem				Acurácia relativa (%)
		Criados	Classificados	Corretamente classificados	Erros de classificação	
1ª	450	715	72	66	6	91,67
2ª	400	957	112	105	7	97,50
3ª	350	1.239	127	117	10	80,00
4ª	300	1.569	140	130	10	100,00
5ª	250	2.089	156	144	12	87,50
6ª	200	3.003	181	162	19	72,00
7ª	150	5.291	228	193	35	65,96
8ª	100	10.661	299	215	84	31,00
Pivôs Centrais de Referência		304	Acurácia global (%)			70,72

FONTE: O autor (2018).

O número de objetos-imagem classificados aumentou com o avançar das etapas de segmentação e classificação. Nas etapas iniciais, devido aos maiores fatores de escala utilizados nas segmentações, foram isolados e classificados os maiores objetos-imagem que pertenciam aos pivôs centrais de maior tamanho, e do mesmo modo, nas etapas finais, foram classificados os objetos-imagem de menores dimensões correspondentes aos pivôs de menor tamanho. O tamanho médio dos objetos-imagem corretamente classificados na primeira etapa foi de 553,77

pixels, com desvio padrão de 290,83 pixels. Na oitava etapa o tamanho médio foi de 276,95 pixels com desvio padrão de 251,65 pixels. A acurácia relativa obtida em cada etapa de classificação foi considerada alta, exceto para a última etapa, cujo valor foi de 31%. As demais etapas apresentaram valores superiores a 65%.

Para cada pivô central detectado, foi avaliada a qualidade da classificação em termos da área de cada objeto. Para isto, foi realizada a análise das diferenças entre as áreas dos pivôs centrais detectados e dos respectivos pivôs centrais provenientes do mapeamento de referência, conforme metodologia apresentada na seção 3.3.4. Os resultados desta análise podem ser verificados na TABELA 12.

TABELA 12 – COMPARAÇÃO ENTRE AS ÁREAS DOS PIVÔS CLASSIFICADOS NO EXPERIMENTO I EM RELAÇÃO AOS PIVÔS DE REFERÊNCIA.

Medidas de posição					
Variável	Menor valor	Maior Valor	Média	Mediana	Moda
Hectares					
Classificação	5,22	134,775	37,714 a**	32,265	8,955
Referência	4,52	135,131	38,777 a**	34,184	18,081
Medidas de dispersão					
Variável	Amplitude	Variância¹	Desvio Padrão	EPM²	CV(%)
Hectares					
Classificação	129,555	655,966	25,612	1,755	67,911
Referência	130,611	663,225	25,753	1,764	66,413
Soma da área total					
Classificação³	8.033,030 ha		Referência	8.259,500 ha	

FONTE: O autor (2018).

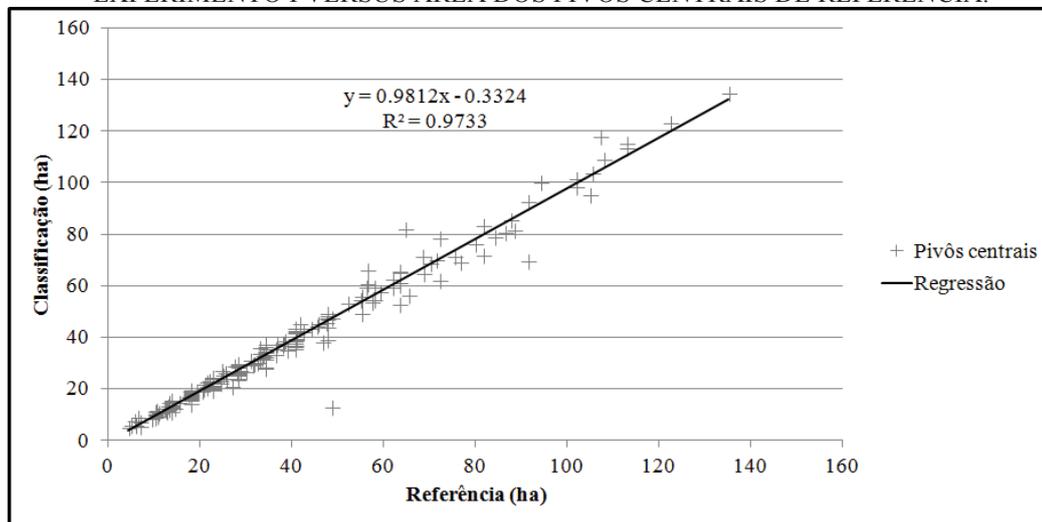
¹Variância é expressa em ha²; ²EPM – Erro Padrão Médio. ³A soma considerou apenas a área dos objetos corretamente classificados. **Significativo a 1% de probabilidade. Médias seguidas da mesma letra não diferem estatisticamente pelo Teste t de Student ($p < 0,01$).

Pela análise da TABELA 12 se verifica que os pivôs centrais detectados pela classificação apresentaram valores estatísticos muito próximos aos valores dos pivôs de referência. Em relação ao tamanho médio, estes não diferiram estatisticamente pelo teste “t” de Student, ao nível de significância de 1%. Nas medidas de posição, se observa que os resultados obtidos na classificação para as métricas menor e maior valores, média e mediana apresentaram valores com diferenças menores que 1.9 hectares em relação aos dados de referência. Nas medidas de dispersão, a amplitude e o desvio padrão apresentaram diferenças de 1,061 e 0,141 ha, respectivamente. Por fim, a soma das áreas dos pivôs classificados apresentou uma omissão de 226,47 ha em relação à área de referência, sendo que esta diferença, em termos de pixels, é de aproximadamente 2.516 pixels.

A FIGURA 15 apresenta o diagrama de dispersão e correlação dos pares de área para os pivôs detectados. Os dados apresentaram correlação positiva de 98,7%, sendo que a

regressão foi obtida por meio de uma função linear, com coeficiente de determinação igual a 0,9733.

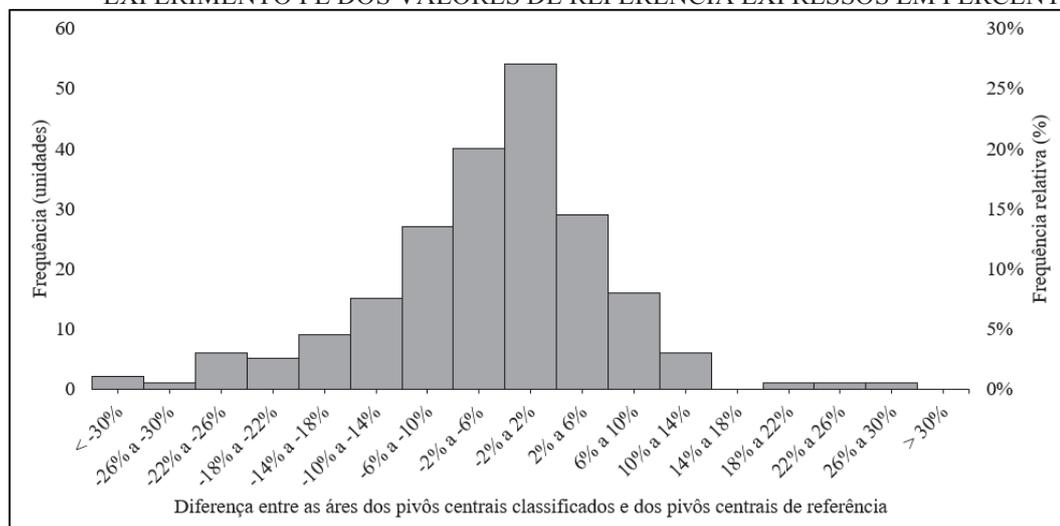
FIGURA 15 – DIAGRAMA DE DISPERSÃO DAS ÁREAS DOS PIVÔS CENTRAIS CLASSIFICADOS NO EXPERIMENTO I VERSUS ÁREA DOS PIVÔS CENTRAIS DE REFERÊNCIA.



FONTE: O autor (2018).

Na FIGURA 16 é apresentado o histograma da distribuição dos erros relativos entre as áreas dos pivôs centrais classificados e dos pivôs centrais de referência. O histograma foi dividido em dezessete classes, sendo que cada uma contou com intervalo de 4% de erro. O intervalo de classe que varia entre -2% e 2%, cujo valor central é 0%, apresentou a maior frequência, totalizando 54 ocorrências, correspondendo a 25,35% da frequência relativa das observações. Mais de 57% das ocorrências ficaram distribuídas nos três intervalos centrais, representando uma amplitude de erros entre -6% e 6%.

FIGURA 16 – HISTOGRAMA DA DIFERENÇA ENTRE A ÁREA DOS PIVÔS DETECTADOS NO EXPERIMENTO I E DOS VALORES DE REFERÊNCIA EXPRESSOS EM PORCENTAGEM.

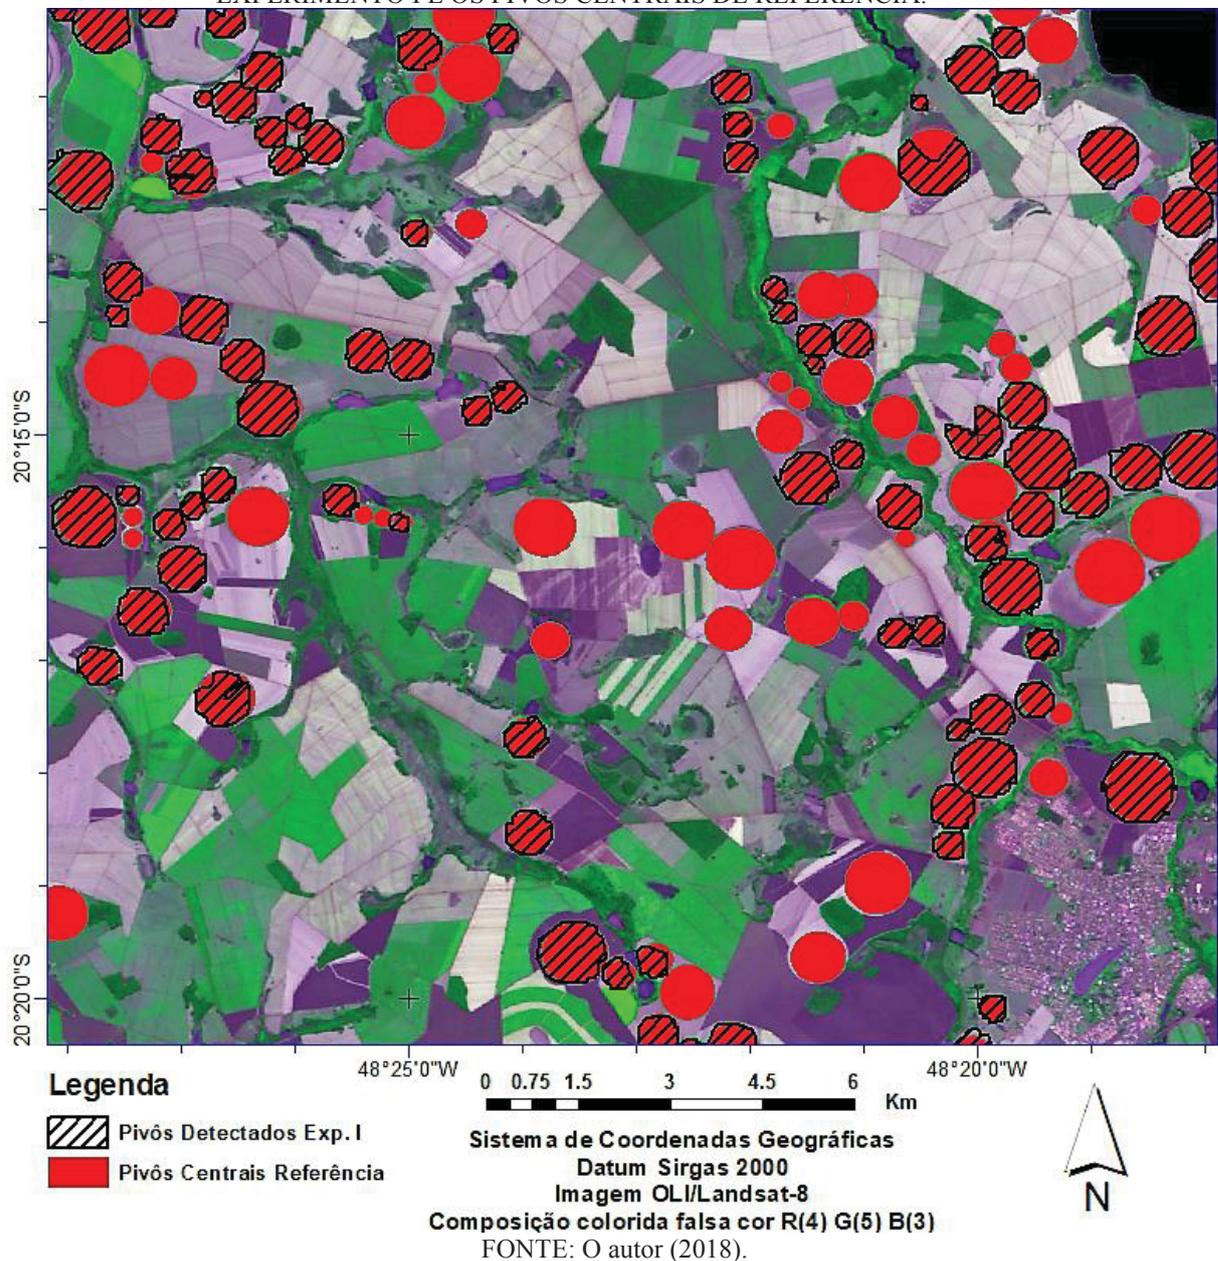


FONTE: O autor (2018).

A FIGURA 17 mostra uma vista parcial da área de estudo com os pivôs centrais detectados nos processos de segmentações e classificações (hachurados) e os pivôs centrais mapeados manualmente (vermelho) utilizados como referência. Pode-se perceber na imagem que grande parte dos pivôs centrais pôde ser identificada e que, visualmente, apresentaram bastante semelhança com os pivôs de referência.

Neste primeiro experimento, a classificação foi mais eficiente na detecção dos pivôs centrais completos. Dos 215 pivôs centrais detectados na classificação, apenas 5 pertencem às classes dos pivôs parciais.

FIGURA 17 – VISTA PARCIAL DA ÁREA DE ESTUDO OS PIVÔS CENTRAIS CLASSIFICADOS NO EXPERIMENTO I E OS PIVÔS CENTRAIS DE REFERÊNCIA.



4.1.2 Experimento II

Na TABELA 13 são apresentados os resultados obtidos no Experimento II. Para cada etapa é mostrado a quantidade de objetos-imagem criados, classificados, corretamente classificados, os erros de classificação, a acurácia relativa em cada etapa e a acurácia global. Na primeira etapa, o tamanho médio dos objetos-imagem criados foi de 9.414,82 pixels com desvio padrão de 11.751,97 pixels, e na décima etapa, o tamanho médio foi reduzido a 543,03 pixels com desvio padrão de 586,85 pixels. O tamanho médio dos objetos-imagem corretamente classificados na primeira etapa foi de 2.047,74 pixels, com desvio padrão de 1148,65 pixels. Na décima etapa o tamanho médio foi de 602,86 pixels com desvio padrão de 391,70 pixels. A acurácia obtida até a oitava etapa de classificação foi superior a 68%. A nona e a décima etapa tiveram os valores de acurácia mais baixos, com 47,06% e 25,93% respectivamente. A acurácia global da classificação foi de 75%.

TABELA 13 – RESULTADOS DA CLASSIFICAÇÃO DO EXPERIMENTO II.

Tamanho da Imagem = 11.186.779 pixels							
Etapa	Fator de Escala	Objetos-imagem				Acurácia relativa (%)	
		Criados	Classificados	Corretamente classificados	Erros de classificação		
1 ^a	1000	674	110	108	2	98,18	
2 ^a	900	806	137	135	2	100,00	
3 ^a	800	932	141	139	3	100,00	
4 ^a	700	1.157	154	151	3	92,31	
5 ^a	600	1.414	170	166	4	93,75	
6 ^a	500	1.857	186	181	5	93,75	
7 ^a	400	2.491	201	192	9	73,33	
8 ^a	300	3.850	220	205	15	68,42	
9 ^a	200	6.823	254	221	33	47,06	
10 ^a	150	10.470	281	228	53	25,93	
Pivôs Centrais de Referência		304	Acurácia Global (%)			75,00	

FONTE: O autor (2018).

A TABELA 14 apresenta os resultados da análise da qualidade da classificação em relação à área dos pivôs centrais detectados. Neste segundo experimento, assim como também foi alcançado no Experimento I, os resultados obtidos na classificação são muito próximos aos dados de referência, indicando a potencialidade do processo na detecção das áreas de interesse.

TABELA 14 – COMPARAÇÃO ENTRE AS ÁREAS DOS PIVÔS CLASSIFICADOS NO EXPERIMENTO II EM RELAÇÃO AOS PIVÔS DE REFERÊNCIA.

Medidas de posição					
Variável	Menor valor	Maior Valor	Média	Mediana	Moda
Hectares					
Classificação	5,27	143,651	37,018a**	30,105	17,224
Referência	4,52	135,131	38,246a**	33,577	18,081
Medidas de dispersão					
Variável	Amplitude	Variância¹	Desvio Padrão	EPM¹	CV(%)
Hectares					
Classificação	138,375	653,900	25,571	1,694	69,079
Referência	130,611	645,760	25,412	1,683	66,443
Soma					
Classificação	8.440,069 ha		Referência	8.720,126 ha	

FONTE: O autor (2018).

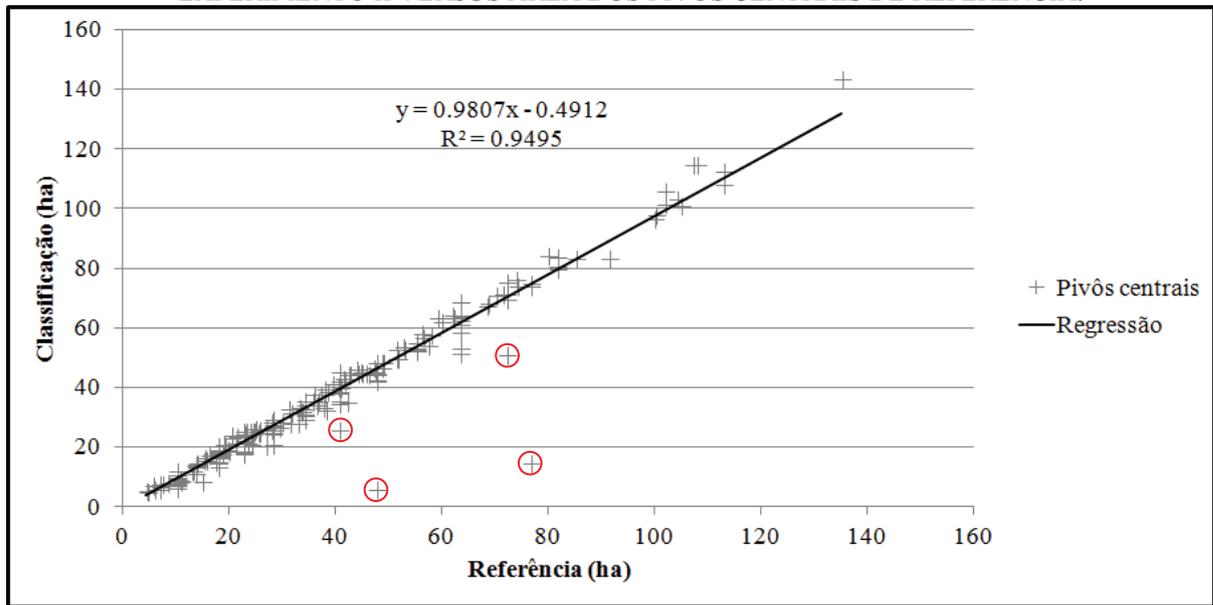
¹Variância é expressa em ha²; ²EPM – Erro Padrão Médio. ³A soma considerou apenas a área dos objetos corretamente classificados. **Significativo a 1% de probabilidade. Médias seguidas da mesma letra não diferem estatisticamente pelo Teste t de Student ($p < 0,01$).

Analisando a TABELA 14 se verifica nas medidas de posição, que os resultados obtidos na classificação para as métricas menor valores, média, mediana e moda apresentaram valores com diferenças de 0,75 ha, -1,228 ha, -3,472 ha e -0,857 ha, respectivamente, em relação aos dados de referência. A maior diferença encontrada nas métricas de posição se deu na medida “maior valor”, onde a diferença foi da ordem de 8,52 ha em relação aos valores de referência.

Nas medidas de dispersão, a amplitude dos pivôs centrais classificados apresentou diferença de 7,764 ha. O desvio padrão e o erro padrão médio tiveram diferenças de 0,159 e 0,011 ha, respectivamente. O coeficiente de variação (CV%) dos pivôs centrais classificados foram 2,636% superior ao CV% de referência. Por fim, a soma das áreas dos pivôs classificados apresentou uma omissão de 280,057 ha em relação à área de referência, sendo que esta diferença, em termos de pixels, é de aproximadamente 12.447, pixels.

A FIGURA 18 apresenta o diagrama de dispersão e correlação dos pares de área para os pivôs detectados no Experimento II. Os dados apresentaram correlação positiva de 97,44%, e a regressão foi obtida por meio de uma função linear, com coeficiente de determinação igual a 0,9495. Pode-se observar que, quase a totalidade dos pontos no diagrama está distribuída próxima à linha de tendência dos dados, com exceção de poucos pontos que representam os pivôs centrais que foram classificados de forma parcial, ou seja, durante os processos de segmentações e classificações não puderam ser isolados e classificados em sua totalidade. Os pontos em destaque no diagrama representam quatro exemplos de classificação parcial de área.

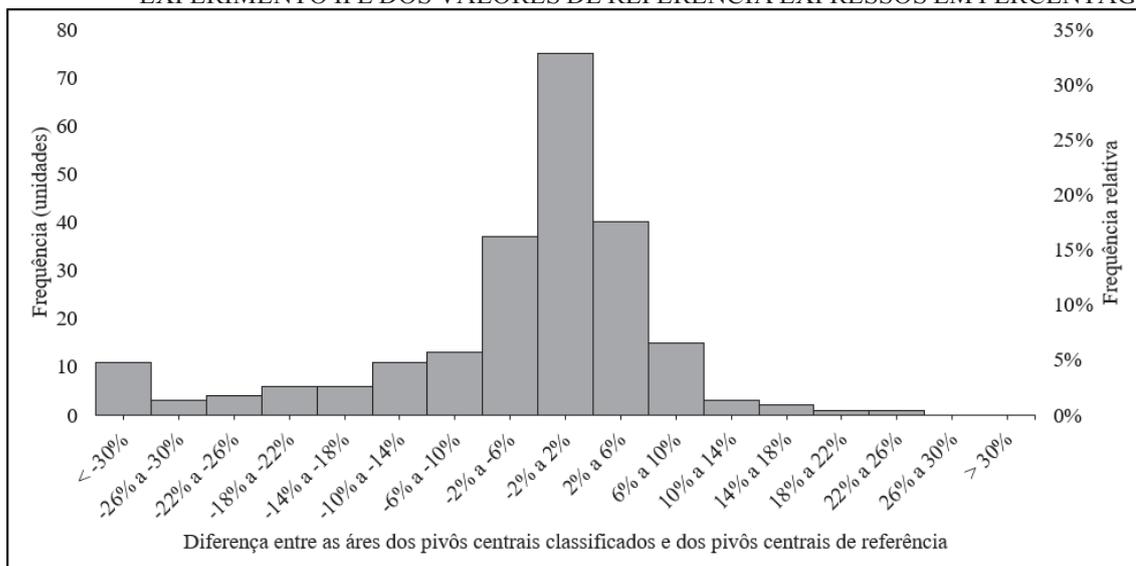
FIGURA 18 – DIAGRAMA DE DISPERSÃO DAS ÁREAS DOS PIVÔS CENTRAIS CLASSIFICADOS NO EXPERIMENTO II VERSUS ÁREA DOS PIVÔS CENTRAIS DE REFERÊNCIA.



FONTE: O autor (2018).

A FIGURA 19 apresenta o histograma da distribuição dos erros relativos entre as áreas dos pivôs centrais classificados e dos pivôs de referência. O histograma foi dividido em dezessete classes, sendo que cada uma contou com intervalo de 4% de diferença. A classe com o intervalo entre -2% e 2% apresentou a maior frequência, totalizando 75 ocorrências, seguida da classe com intervalo entre 2% e 6%, que teve frequência igual 40. Considerando o intervalo entre -6% e 6%, temos o total de 152 ocorrências, que representa 66,67%.

FIGURA 19 – HISTOGRAMA DA DIFERENÇA ENTRE A ÁREA DOS PIVÔS DETECTADOS NO EXPERIMENTO II E DOS VALORES DE REFERÊNCIA EXPRESSOS EM PORCENTAGEM.

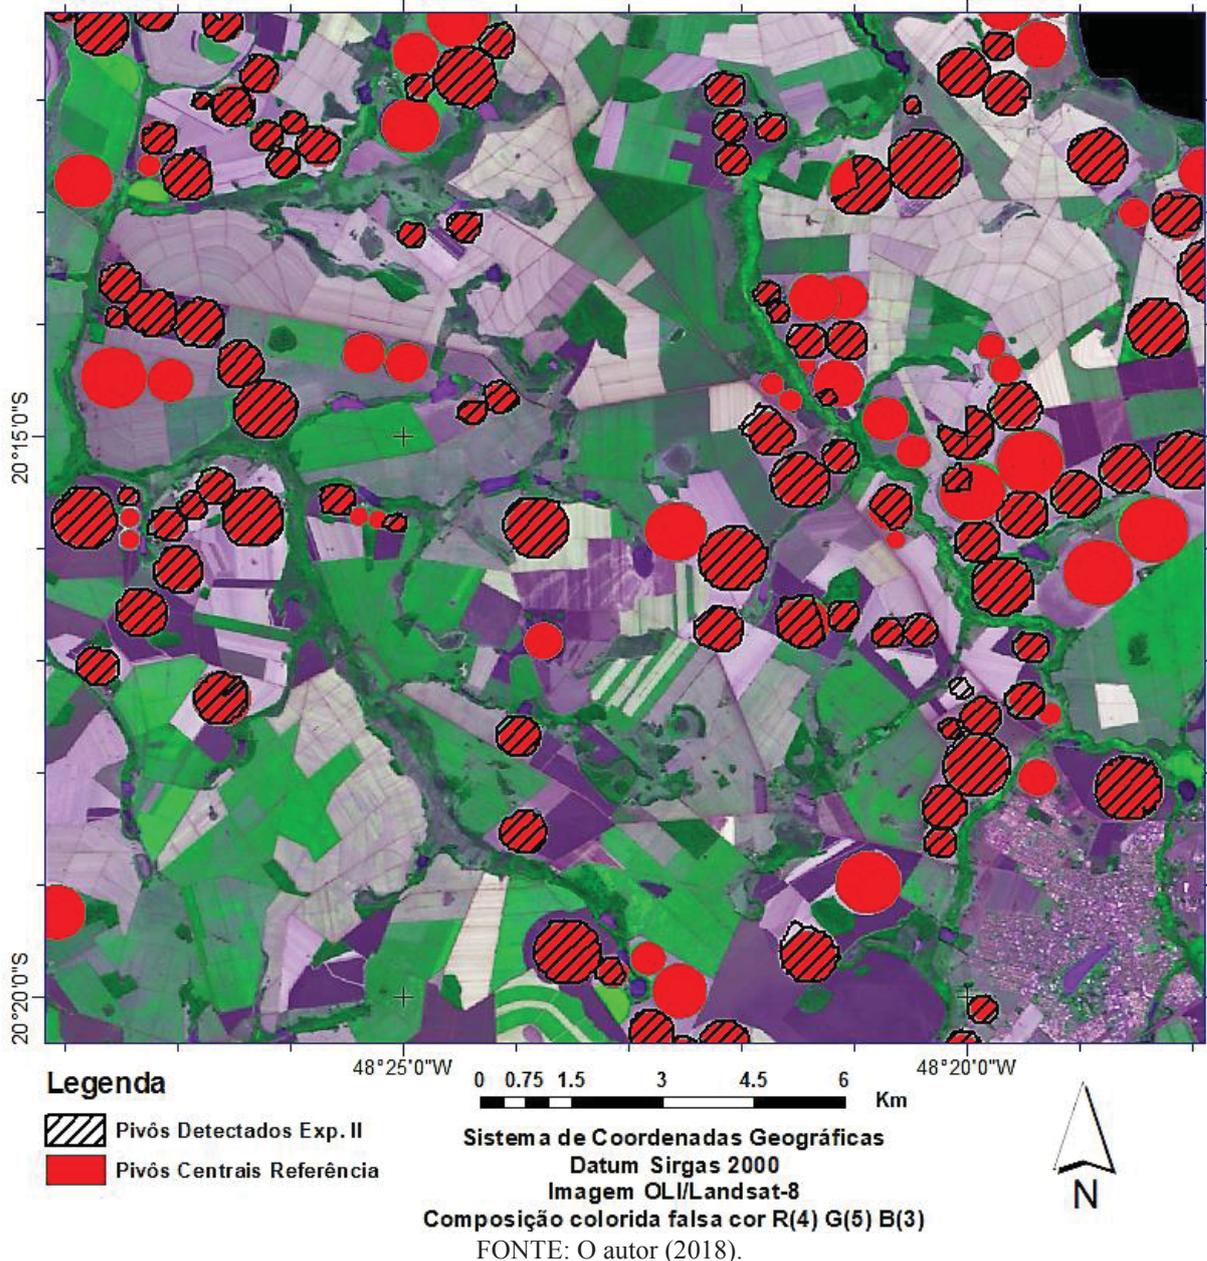


FONTE: O autor (2018).

Neste segundo experimento, assim como ocorreu no primeiro, a classificação utilizando apenas descritores de forma foi mais eficiente na detecção dos pivôs centrais completos. Dentre os 228 pivôs centrais detectados, apenas 7 são pivôs parciais.

A FIGURA 20 apresenta uma vista parcial da área de estudo com os pivôs centrais detectados nos processos de segmentações e classificações (hachurados) e os pivôs centrais mapeados manualmente (vermelho) utilizados como referência. Pode-se perceber na imagem que grande parte dos pivôs centrais pôde ser identificada e que, visualmente, apresentaram bastante semelhança com os pivôs de referência.

FIGURA 20 – VISTA PARCIAL DA ÁREA DE ESTUDO MOSTRANDO OS PIVÔS CENTRAIS CLASSIFICADOS NO EXPERIMENTO II E OS PIVÔS CENTRAIS DE REFERÊNCIA.



4.1.3 Experimento III

Na TABELA 15 são apresentados os resultados obtidos no Experimento III. Para cada etapa é mostrado a quantidade de objetos-imagem criados, classificados, corretamente classificados, os erros de classificação, a acurácia relativa em cada nível hierárquico e a acurácia global.

Na primeira etapa, o tamanho médio dos objetos-imagem criados foi de 9.713,11 pixels com desvio padrão de 14.497,87 pixels, e na décima etapa, o tamanho médio foi reduzido a 493,58 pixels com desvio padrão de 883,73 pixels. O tamanho médio dos objetos-imagem corretamente classificados na primeira etapa foi de 1.980,27 pixels, com desvio padrão de 1.143,99 pixels. Na décima etapa o tamanho médio foi de 1.807,69 pixels com desvio padrão de 1.220,84 pixels. A acurácia obtida até a sétima etapa de classificação foi superior a 75%. A nona e a décima etapa tiveram os valores de acurácia mais baixos, com 45,24% e 25,00% respectivamente. A acurácia global da classificação foi de 83,22%.

TABELA 15 – RESULTADOS DA CLASSIFICAÇÃO DO EXPERIMENTO III.

Tamanho da Imagem = 11.186.779 pixels							
Etapa	Fator de Escala	Objetos-imagem				Acurácia relativa (%)	
		Criados	Classificados	Corretamente classificados	Erros de classificação		
1 ^a	1000	597	138	135	3	97,83	
2 ^a	900	727	169	162	7	87,10	
3 ^a	800	846	173	166	7	100,00	
4 ^a	700	1.005	184	176	8	90,91	
5 ^a	600	1.268	202	191	11	83,33	
6 ^a	500	1.651	218	206	12	93,75	
7 ^a	400	2.327	234	218	16	75,00	
8 ^a	300	3.546	256	231	25	59,09	
9 ^a	200	7.167	298	250	48	45,24	
10 ^a	150	11.356	310	253	57	25,00	
Pivôs Centrais de Referência		304	Acurácia Global (%)			83,22	

FONTE: O autor (2018).

A TABELA 16 apresenta os resultados da análise da qualidade da classificação em relação à área dos pivôs centrais detectados. Neste terceiro experimento, bem como nos anteriores, foi alcançado na classificação, resultados próximos aos valores de referência, indicando o bom desempenho do processo na identificação das feições de interesse.

TABELA 16 – COMPARAÇÃO ENTRE AS ÁREAS DOS PIVÔS CLASSIFICADOS NO EXPERIMENTO III EM RELAÇÃO AOS PIVÔS DE REFERÊNCIA.

Medidas de posição					
Variável	Menor valor	Maior Valor	Média	Mediana	Moda
Hectares					
Classificação	4,66	145,193	40,841a	34,875	7,830
Referência	4,52	135,131	42,101a	36,706	40,682
Medidas de dispersão					
Variável	Amplitude	Variância*	Desvio Padrão	EPM**	CV(%)
Hectares					
Classificação	140,536	754,590	27,470	1,730	67,260
Referência	130,611	754,195	27,463	1,730	65,231
Soma					
Classificação	10.291,923 ha		Referência	10.609,348 ha	

FONTE: O autor (2018).

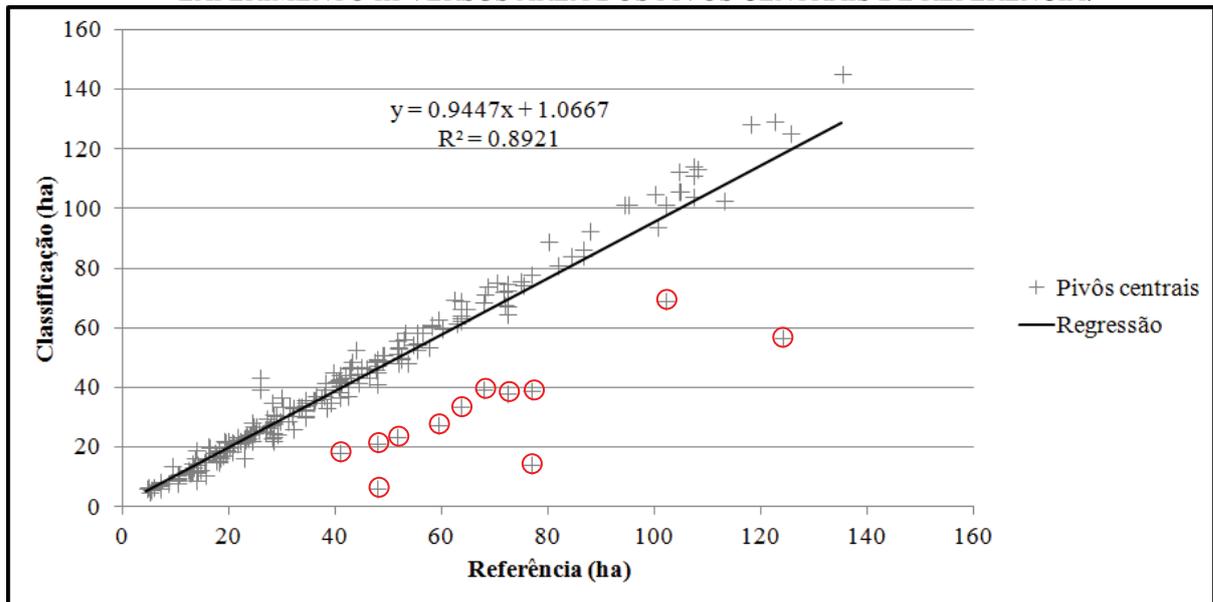
¹Variância é expressa em ha²; ²EPM – Erro Padrão Médio. ³A soma considerou apenas a área dos objetos corretamente classificados. **Significativo a 1% de probabilidade. Médias seguidas da mesma letra não diferem estatisticamente pelo Teste t de Student ($p < 0,01$).

Pela análise da TABELA 16 se observa nas medidas de posição, que na classificação o maior pivô central detectado apresentou área de 145,193 ha, enquanto que o maior valor de referência indicou área igual a 135,131 ha, assim, na classificação deste objeto-imagem houve incremento de 10,062 ha. O menor pivô central detectado apresentou diferença de apenas 0,14 ha em relação à referência. O tamanho médio dos pivôs centrais classificados foi 1,26 ha menor que o tamanho médio dos pivôs centrais de referência, no entanto, não diferem estatisticamente pelo teste “t” de Student, ao nível de significância de 1%.

Nas medidas de dispersão, a amplitude dos pivôs centrais classificados apresentou diferença positiva de 9,925 ha. As demais variáveis apresentaram valores muito próximos ou iguais aos valores de referência. Por fim, a soma das áreas dos pivôs classificados apresentou uma omissão de 317,425 ha, ou de 3%, em relação à área de referência, sendo que esta diferença, em termos de pixels, é de aproximadamente 14.108 pixels.

A FIGURA 21 apresenta o diagrama de dispersão e correlação dos pares de área para os pivôs detectados no Experimento III. Os dados apresentaram correlação positiva de 94,45%, e a regressão foi obtida por meio de uma função linear, com coeficiente de determinação igual a 0,8921. Pode-se observar que, quase a totalidade dos pontos no diagrama está distribuída próxima à linha de tendência dos dados, com exceção de alguns pontos, localizados abaixo da linha de tendência, que representam os pivôs centrais que foram classificados de forma parcial, ou seja, durante os processos de segmentações e classificações não puderam ser isolados e classificados em sua totalidade. Os pontos em destaque no diagrama representam doze exemplos de classificação parcial de área.

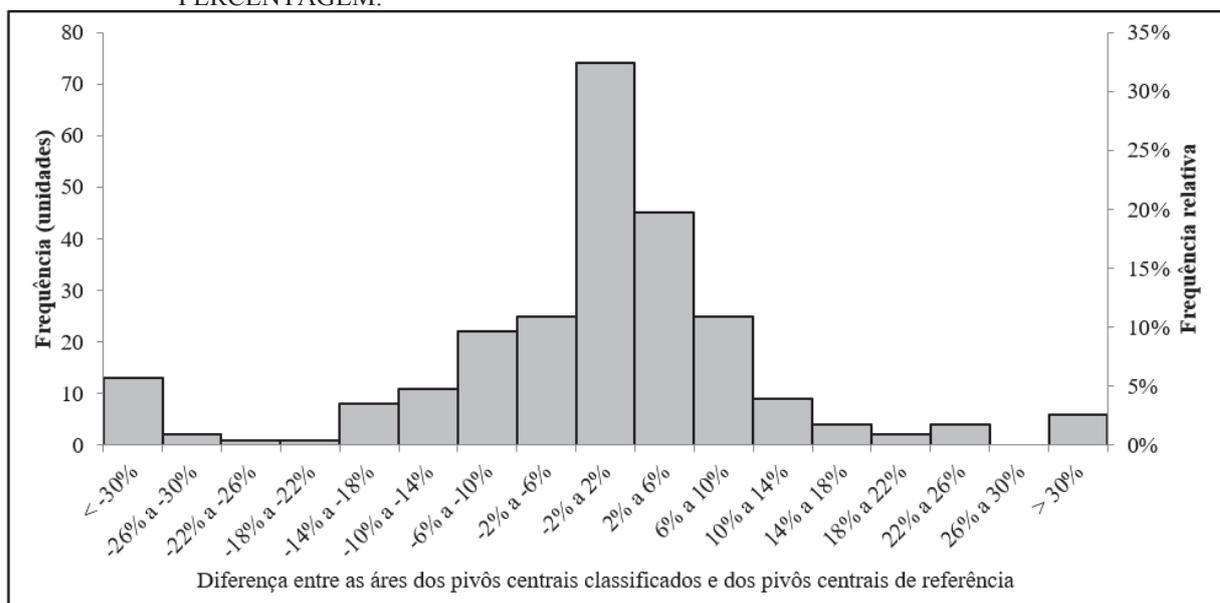
FIGURA 21 – DIAGRAMA DE DISPERSÃO DAS ÁREAS DOS PIVÔS CENTRAIS CLASSIFICADOS NO EXPERIMENTO III VERSUS ÁREA DOS PIVÔS CENTRAIS DE REFERÊNCIA.



FONTE: O autor (2018).

A FIGURA 22 apresenta o histograma da distribuição dos erros relativos entre as áreas dos pivôs centrais classificados e dos pivôs de referência. O histograma foi dividido em dezessete classes, sendo que cada uma contou com intervalo de 4% de diferença. A classe com intervalo de -2% a 2% apresentou a maior frequência, totalizando 74 ocorrências, representando 29,37% dos dados. Em seguida, a segunda maior frequência ocorreu na classe de 2% a 6% de erro, com 17,86% dos dados.

FIGURA 22 – HISTOGRAMA DA DIFERENÇA ENTRE A ÁREA DOS PIVÔS DETECTADOS NO EXPERIMENTO III E DOS VALORES DE REFERÊNCIA EXPRESSOS EM PERCENTAGEM.

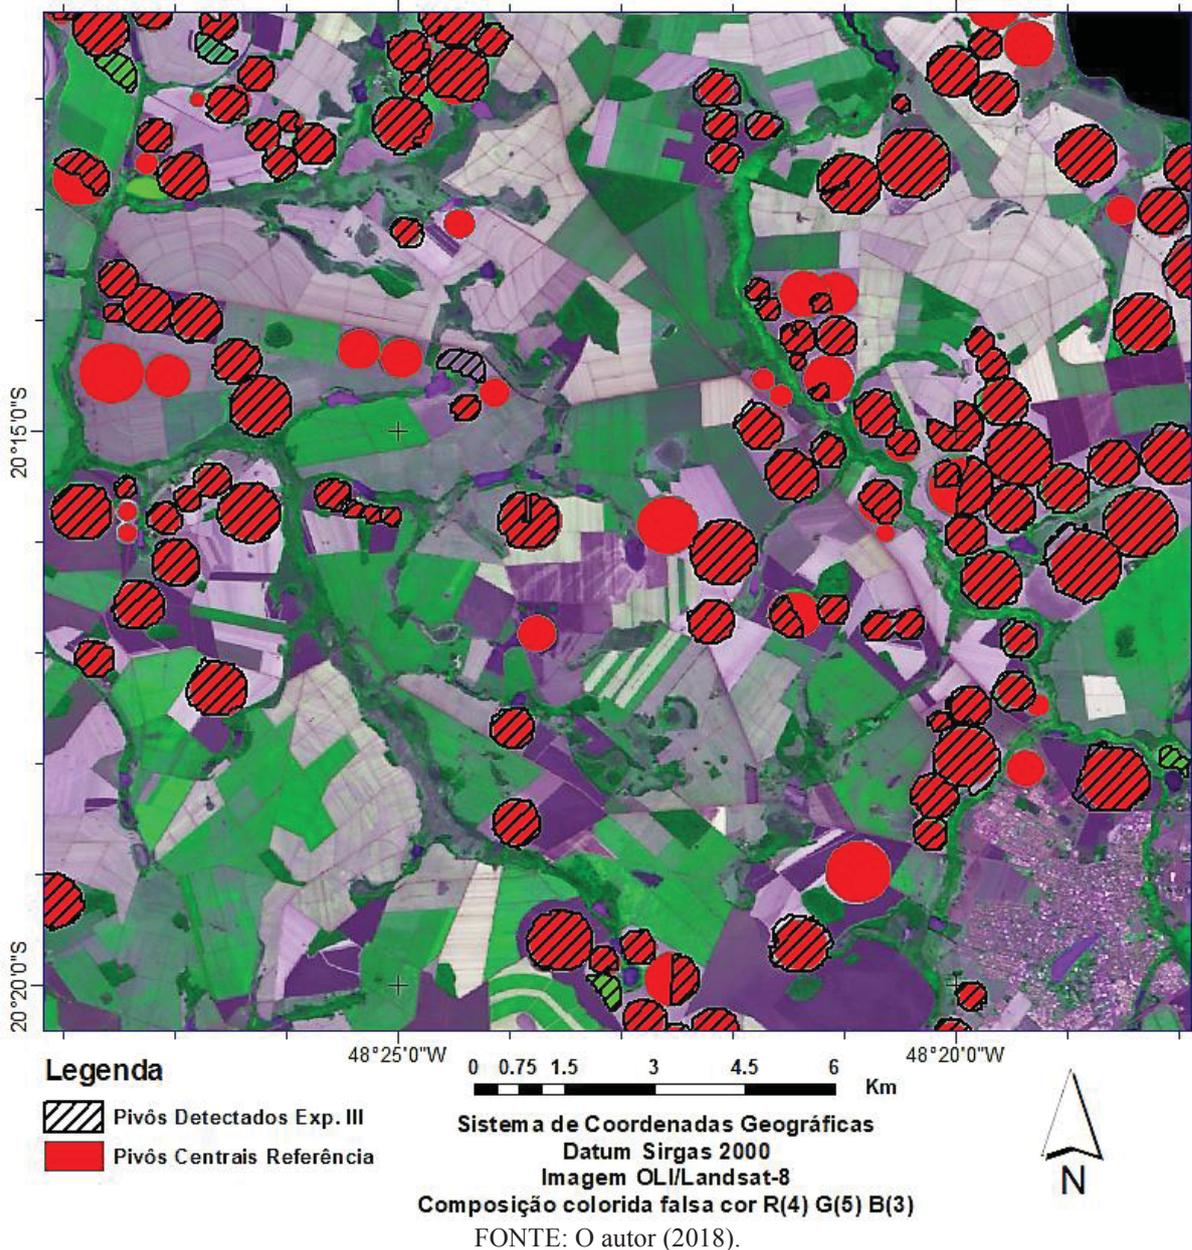


FONTE: O autor (2018).

No terceiro experimento, percebe-se que o uso combinado de outros tipos de descritores, além dos de forma, favoreceu positivamente a classificação de pivôs centrais, de forma especial os pertencentes às classes dos pivôs parciais. Neste experimento foi possível detectar 17 pivôs parciais.

A FIGURA 23 apresenta uma vista parcial da área de estudo com os pivôs centrais detectados nos processos de segmentações e classificações (hachura) e os pivôs centrais mapeados manualmente (vermelho) utilizados como referência. Percebe-se na imagem que grande parte dos pivôs centrais pôde ser identificada e que, visualmente, apresentaram bastante semelhança com os pivôs de referência.

FIGURA 23 – VISTA PARCIAL DA ÁREA DE ESTUDO MOSTRANDO OS PIVÔS CENTRAIS CLASSIFICADOS NO EXPERIMENTO III E OS PIVÔS CENTRAIS DE REFERÊNCIA.



4.2 DISCUSSÃO

A TABELA 17 apresenta a comparação geral entre os três experimentos realizados neste estudo. Os resultados obtidos foram de acordo com a expectativa, pois se espera que quanto maior o uso de recursos da classificação orientada a objetos seja utilizado, maior seja a acurácia da classificação.

Neste estudo, o uso dos recursos de GEOBIA foi realizado de forma gradual, ou seja, o segundo experimento utilizou mais recursos que o primeiro, e o terceiro mais que o segundo. No Experimento I foi utilizada uma série temporal de imagens com resolução espacial de 30 metros e a classificação foi realizada apenas com descritores de forma. Já o Experimento II foi realizado com a série temporal composta de imagens fusionadas, onde a resolução espacial foi melhorada para 15 metros, com isso, pode-se observar aumento na quantidade de objetos-imagem classificados, sendo possível aumentar em 13 unidades o número de pivôs centrais detectados, e em quase 5% a acurácia global da classificação em relação ao primeiro experimento.

No Experimento III, observa-se que o uso combinado de descritores de forma, espectral e textural, contribuiu positivamente na classificação, sendo possível detectar um maior número de pivôs centrais, aumentando a acurácia global da classificação, reduzindo o número de objetos-imagem classificados erroneamente e obtendo as maiores relações entre o número total de objetos-imagem classificados e o número de pivôs centrais detectados, conseqüentemente, obtendo também a melhor relação entre a área total detectada e a área total de referência.

TABELA 17 – COMPARATIVO GERAL QUANTITATIVO ENTRE EXPERIMENTOS.

	EXPERIMENTO I	EXPERIMENTO II	EXPERIMENTO III
Nº de Níveis Hierárquicos	8	10	10
Nº de Objetos-imagem Classificados (A)	299	281	310
Nº de Pivôs Detectados (B)	215	228	253
Relação A/B	0,7191	0,7625	0,8161
Acurácia Global	70,72%	75,00%	83,22%
Área Total Detectada* (C)	8.033,030 ha	8.440,069 ha	10.291,923 ha
Área Total Referência (D)	11.803,667 ha	11.803,667 ha	11.803,667 ha
Relação C/D	0,6806	0,7150	0,8719

FONTE: O autor (2018).

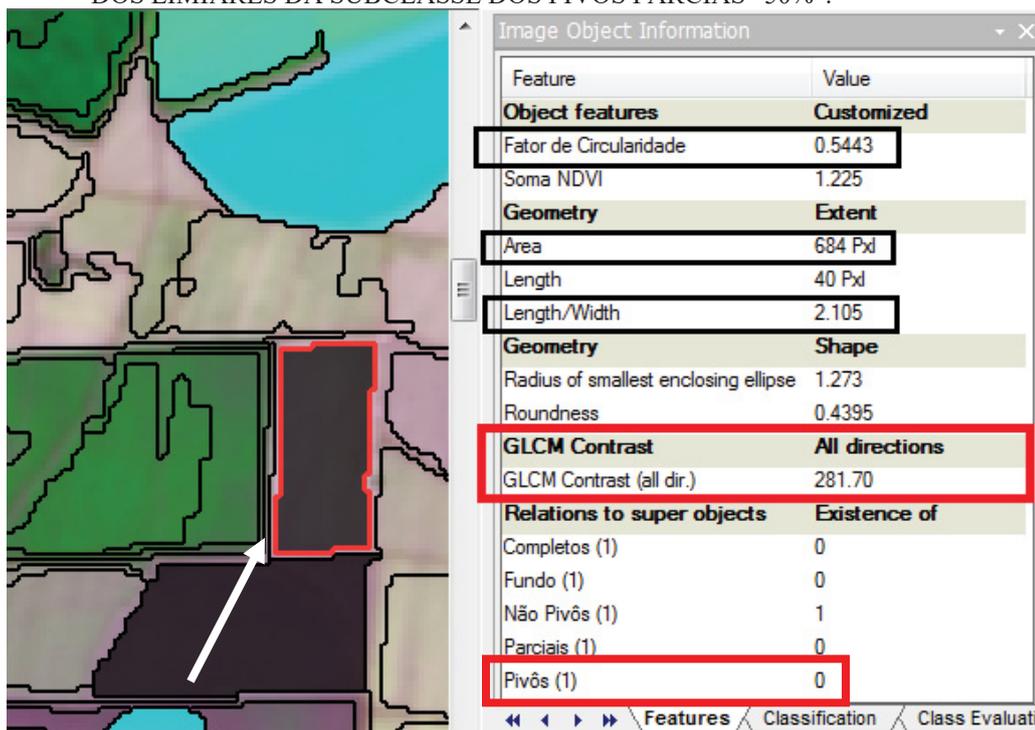
*Soma da área de todos os pivôs centrais corretamente classificados.

Nos Experimentos I e II, o uso somente de descritores de forma, teve sua maior eficiência para classificar pivôs centrais completos, ou seja, aqueles que possuem forma circular

completa, e apenas os pivôs parciais cuja proporção era acima de 60% pôde ser classificado de forma satisfatória. Já no Experimento III, também foi possível classificar pivôs parciais com proporção de 50%, sendo que isto só foi possível graças ao uso combinado de descritores de forma, espectrais e textural, que puderam evitar a classificação errônea de objetos-imagem nesta subclasse, visto que diversos objetos-imagem com formas próximas de um retângulo apresentaram valores para os descritores de forma dentro dos limites definidos para a subclasse dos pivôs parciais “50%”.

A FIGURA 24 ilustra esta situação, onde um objeto-imagem possui os descritores de forma dentro dos limites estabelecidos para a subclasse dos pivôs parciais “50%”, mas que devido ao uso de descritor textural foi reclassificado para a classe dos “Não Pivôs”. Desta forma, no Experimento III, foram classificados 14 pivôs parciais com proporção de 50%, ao passo que nos demais experimentos, tal classificação não foi possível.

FIGURA 24 – OBJETO-IMAGEM COM FORMA RETANGULAR E DESCRITORES DE FORMA DENTRO DOS LIMIARES DA SUBCLASSE DOS PIVÔS PARCIAS “50%”.



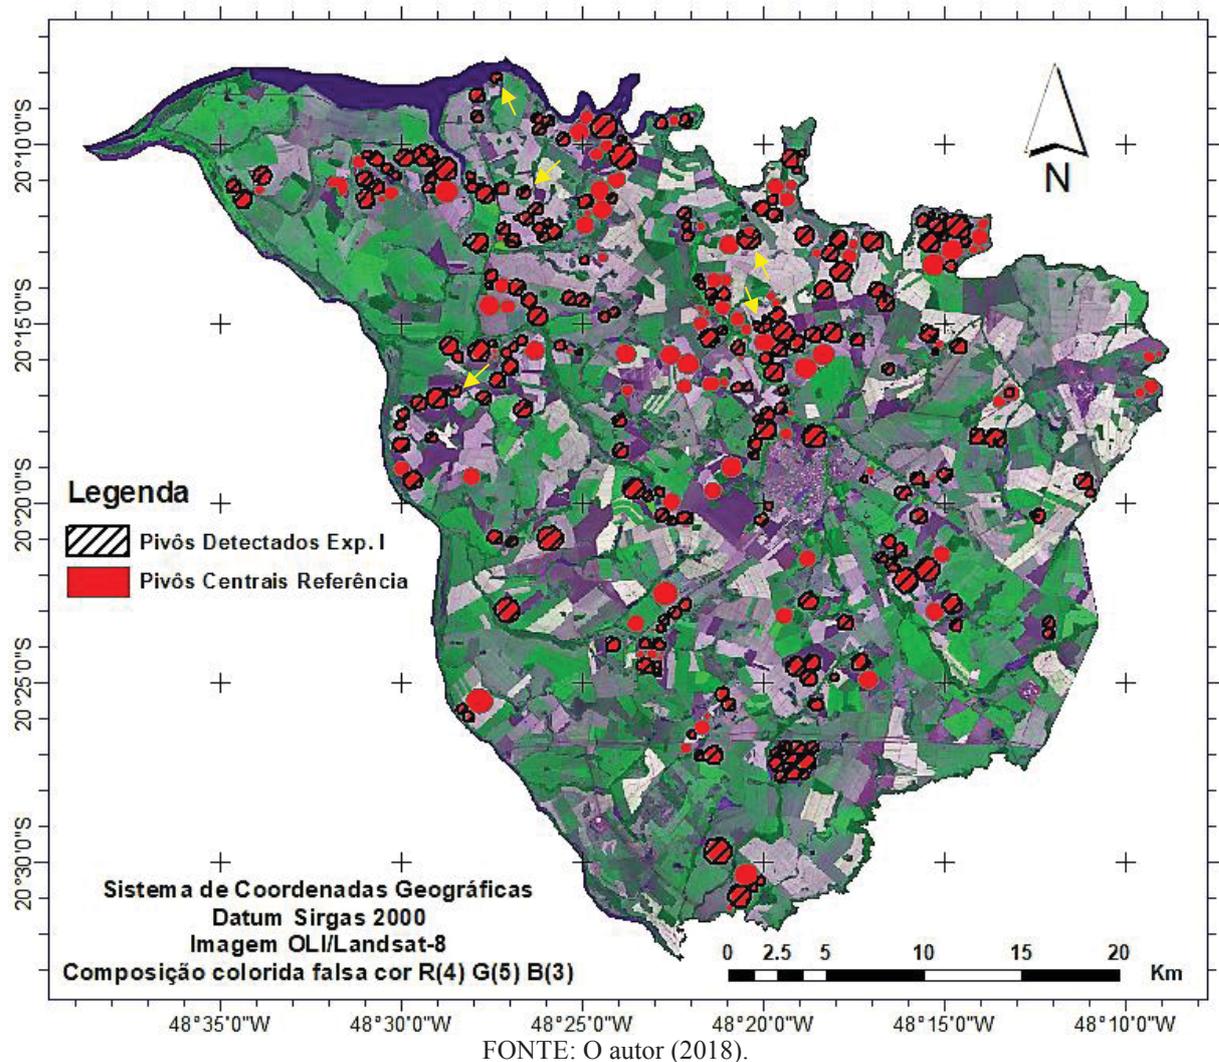
FONTE: O autor (2018).

Vale ressaltar que, apesar do uso de descritores espectrais e textural no Experimento III terem favorecidos a acurácia na classificação de pivôs parciais “50%”, todos os pivôs centrais, inclusive os parciais foram classificados apenas com descritores de forma, sendo que para os pivôs pertencentes à subclasse “Completos” o descritor de forma que teve a maior importância na identificação destes objetos-imagem foi o “Raio da menor elipse envolvente”.

Já para os pivôs parciais, grande destaque deve ser dado para o descritor “*Fator de Circularidade*”, que foi implementado pelo autor e desempenhou importante papel na determinação da proporcionalidade dos pivôs parciais e possibilitou a diferenciação destes com os demais objetos-imagem presentes na imagem.

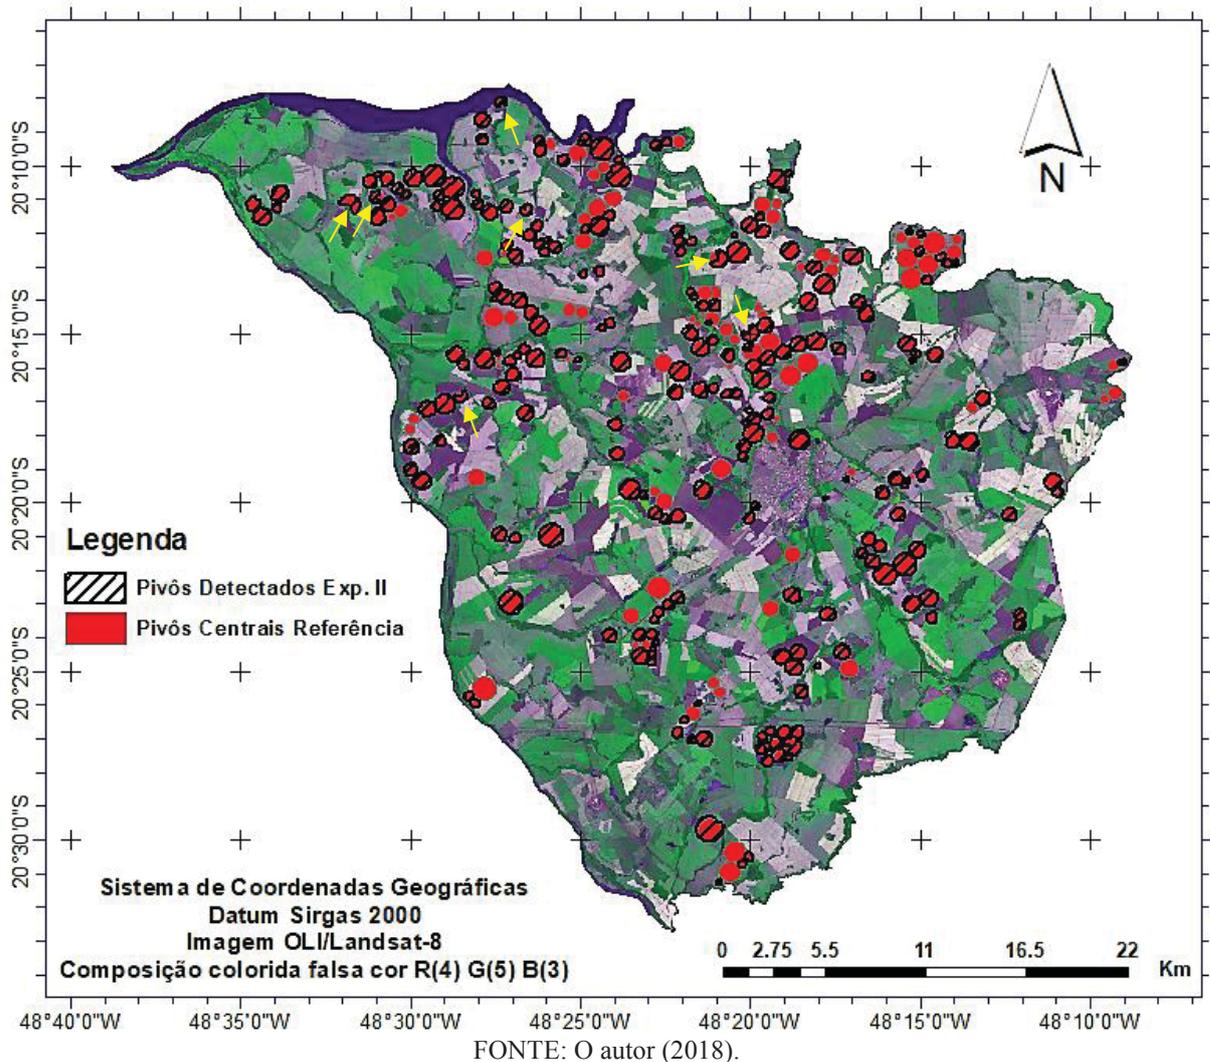
A FIGURA 25 mostra toda área de estudo com os pivôs detectados no Experimento I, são destacados por meio de setas os pivôs parciais que puderam ser classificados. No primeiro experimento apenas cinco pivôs parciais puderam ser identificados. A maior limitação observada no primeiro experimento, tanto para identificar pivôs parciais quanto pivôs completos, se deu pela baixa resolução espacial da imagem, pois apesar de ser possível distinguir visualmente diversos pivôs centrais os processos de segmentação e classificação não puderam identificar vários objetos de interesse.

FIGURA 25 – PIVÔS CENTRAIS DETECTADOS NO EXPERIMENTO I.



No Experimento II a limitação pela resolução espacial das imagens foi amenizada, o que favoreceu a detecção de mais pivôs completos e parciais, como pode ser observado na FIGURA 26. No entanto, assim como no Experimento I, alguns pivôs completos que facilmente são identificados visualmente nas imagens não foram isolados e classificados.

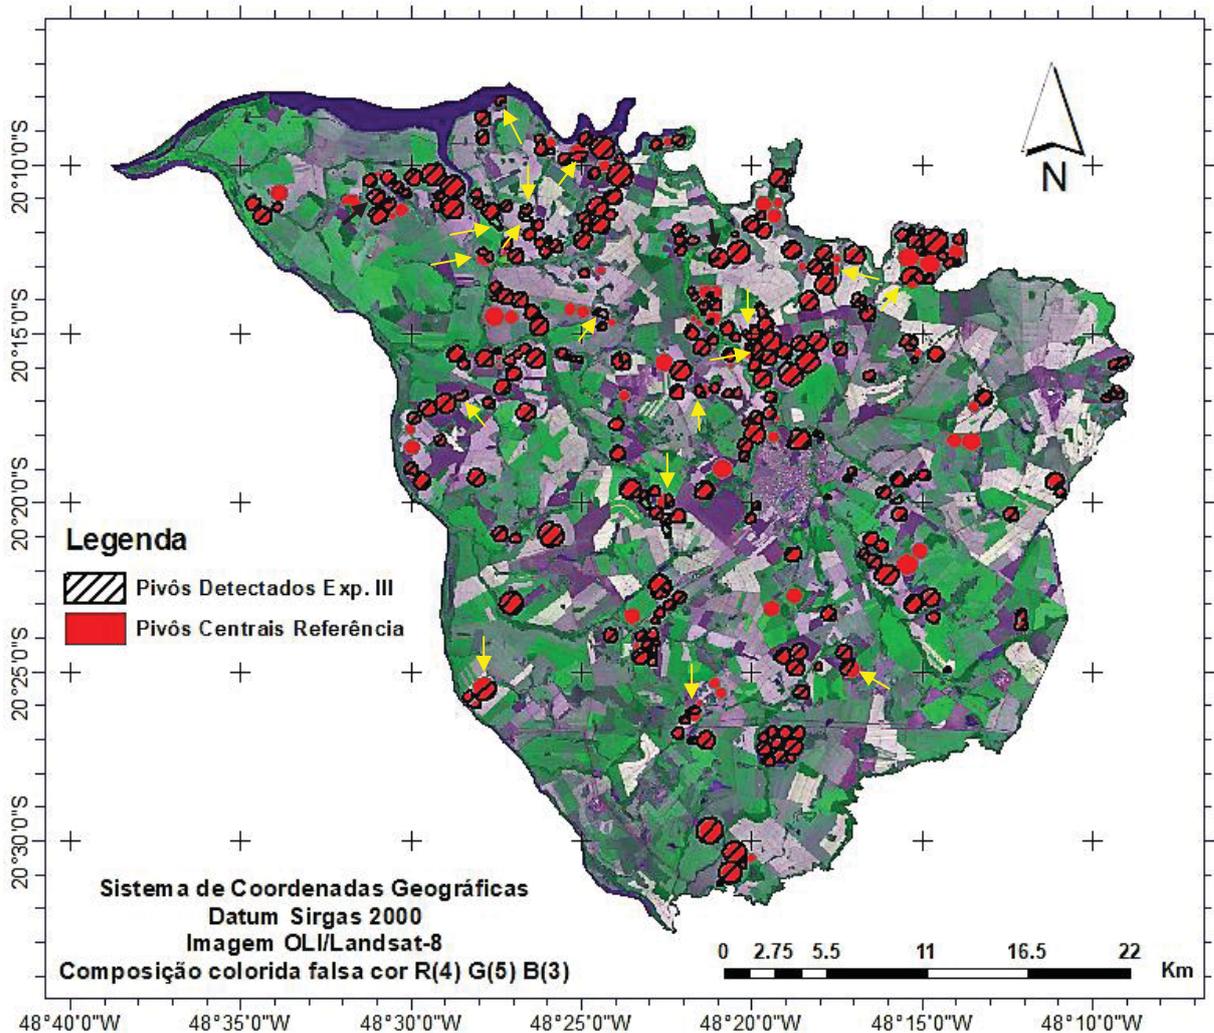
FIGURA 26 – PIVÔS CENTRAIS DETECTADOS NO EXPERIMENTO II.



No Experimento III, o uso de descritores espectrais e textural além dos descritores de forma favoreceu o processo de identificação de pivôs centrais, pois foi neste experimento onde se obteve os melhores resultados. Na FIGURA 27 se pode observar o maior número de pivôs centrais detectados em comparação aos experimentos anteriores. Os pivôs parciais são destacados com setas negras. Alguns pivôs parciais que foram detectados no Experimento II aparecem como pivôs completos no Experimento III (destacados por setas pretas), isto se deu em função de processo de resegmentação e classificação, por meio do algoritmo *Image Object*

Fusion, que pode fusionar dois objetos-imagem vizinhos, que atendam a uma condição imposta pelo usuário. Nestes casos, a condição imposta foi que os objetos fusionados tivessem o valor do descritor de forma “*Raio da menor elipse envolvente*” menor ou igual ao limite superior estabelecido para a classe dos pivôs completos, ou seja, $\leq 1,16$.

FIGURA 27 – PIVÔS CENTRAIS DETECTADOS NO EXPERIMENTO III.

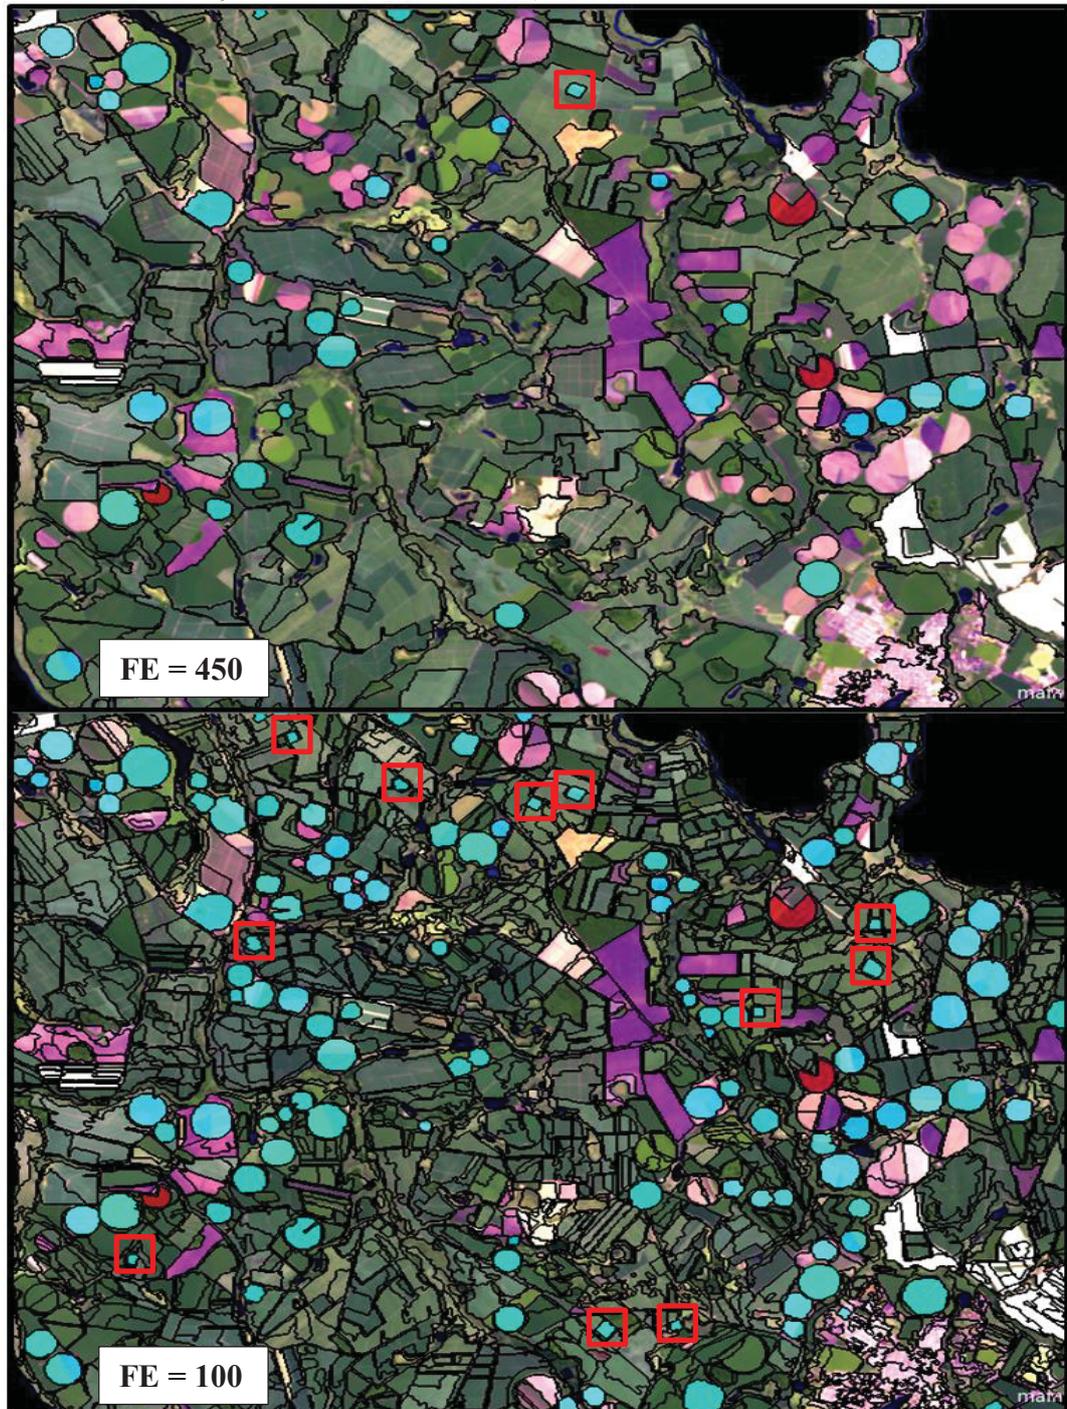


FONTE: O autor (2018).

Observa-se que a primeira etapa de todos os experimentos foi a que identificou a maior quantidade de pivôs centrais, sendo equivalente a 30,7% do total no Experimento I, 47,37% no Experimento II e 53,36% no Experimento III. Em todos os experimentos, foi observado que as maiores acurácias de classificação ocorreram nas primeiras etapas, onde foram utilizados os maiores fatores de escala. No Experimento I foi obtida acurácia acima de 80% até a quinta etapa, onde o fator de escala foi igual a 250. Nos Experimentos II e III se obteve acurácia acima de 70% até a sétima etapa (FE = 400). Isto indica que pode existir correlação entre o tamanho médio dos objetos de interesse e o tamanho médio dos objetos-imagem criados na segmentação,

de forma que a acurácia seja maior nos níveis onde existe melhor compatibilidade. A FIGURA 28 exemplifica esta situação, mostrando que nos níveis segmentados com menor fator de escala a acurácia da classificação é menor. Os objetos-imagem classificados incorretamente são destacados em quadro vermelho.

FIGURA 28 – COMPATIBILIDADE ENTRE O FATOR DE ESCALA E A ACURÁCIA NA CLASSIFICAÇÃO DE PIVÔS CENTRAIS, EXEMPLO DO EXPERIMENTO I.



FONTE: O autor (2018).

5 CONCLUSÃO

- A utilização de imagens tomadas durante o período de estiagem é de crucial importância para a detecção de áreas irrigadas, pois favorece a distinção entre as áreas de cultivo de não irrigadas;
- Imagens com resolução espacial de 30 metros possibilitaram a identificação de pivôs centrais, no entanto, apresentaram limitação para detectar áreas com tamanho abaixo de 100 pixels, ou seja, pivôs centrais que ocupam menos que 10 hectares. Porém, quando se utilizaram imagens fusionadas com resolução espacial de 15 metros, esta limitação foi minimizada;
- A segmentação multirresolução apresentou desempenho satisfatório no isolamento de áreas irrigadas por pivôs centrais, porém, indícios observados neste estudo sugerem que os fatores de escala devem ser escolhidos com base no tamanho dos objetos de interesse;
- Os descritores de forma “*Raio do menor círculo envolvente*”, “*Relação comprimento/largura*” e “*Circularidade*”, que estão disponíveis de forma nativa no software eCognition®, puderam classificar de modo eficiente somente as áreas irrigadas pertencentes à subclasse dos pivôs centrais completos. Os pivôs parciais só puderam ser classificados graças ao descritor de forma “*Fator de Circularidade*” que teve sua formulação desenvolvida neste estudo;
- No Experimento I a metodologia empregada possibilitou a identificação de 70,72% dos pivôs centrais passíveis de detecção. A área ocupada pelos pivôs detectados correspondeu a 97,26% da área ocupada pelos respectivos pivôs de referência;
- No Experimento II foram detectados 75% dos pivôs passíveis de identificação, e a área ocupada pelos pivôs classificados correspondeu a 96,79% da área dos respectivos pivôs de referência. O aumento no número de pivôs detectados em relação ao primeiro experimento foi em função da melhora da resolução espacial das imagens;
- No Experimento III foram classificados 83,22% dos pivôs que podiam ser identificados, sendo que a área dos pivôs detectados correspondeu a 97,01% da área dos respectivos pivôs de referência. O aumento do número pivôs

detectados é atribuído, principalmente, à detecção de pivôs parciais, que foi possibilitado devido ao uso combinado dos descritores de forma, especialmente o “*Fator de Circularidade*”, com descritores espectrais e textural, que desempenharam importante papel evitando que objetos-imagem alheios aos pivôs parciais fossem classificados erroneamente;

- A abordagem GEOBIA apresentou desempenho satisfatório na classificação de áreas irrigadas por pivôs centrais, sendo eficiente no reconhecimento e extração de padrões em imagens orbitais de média resolução espacial.

5.1 RECOMENDAÇÕES DE TRABALHOS FUTUROS

- Testar a metodologia desenvolvida neste estudo em outras áreas para se avaliar a eficácia na detecção de pivôs centrais;
- Estudar mais profundamente a definição de limiares para descritores de forma, espectrais e texturais para classificar áreas irrigadas por pivôs centrais, de modo que possam ser utilizados em áreas mais amplas e com maior diversidade de paisagens presente nas imagens;
- Estudos relacionados à segmentação multirresolução, no que diz respeito à definição de fatores de escala, de modo que exista a melhor compatibilidade entre os objetos-imagem gerados na segmentação e os objetos de interesse;
- Usar imagens com resolução espacial mais refinada para melhorar a acurácia na classificação de pivôs centrais que possuam área inferior a 10 hectares;
- Estudar e testar outros métodos automatizados de classificação de imagem para identificar áreas irrigadas por pivôs centrais, como por exemplo, aprendizado de máquina e árvore de decisão.

REFERÊNCIAS

AGÊNCIA NACIONAL DE ÁGUAS - ANA (BRASIL). **Levantamento da agricultura irrigada por pivôs centrais no Brasil - 2014**: relatório síntese. Brasília: ANA, 2016. 33 p.

_____. **Levantamento da Cana-de-Açúcar Irrigada na Região Centro-Sul do Brasil**. Brasília: ANA, 2017. 31 p.: il.

ANTUNES, A. F. B. **Classificação de ambiente ciliar baseada em orientação a objeto em imagens de alta resolução espacial**. 147 p. Tese (Doutorado em Ciências Geodésicas) – Setor de Ciências da Terra, Universidade Federal do Paraná, Curitiba, 2003.

ANTUNES, A. F. B.; CENTENO, J. A. S. **Aplicação de dados sensores remotos de alta resolução em zonas urbanas**. In: Blaschke, T. & Kux, H. Sensoriamento remoto e SIG avançados: novos sistemas sensores – métodos inovadores. 2ª ed. São Paulo: Oficina de Textos, 2007.

BAATZ, M.; SCHÄPE, A. **Object-oriented and multi-scale image analysis in semantic networks**. *2nd International Symposium: Operationalization of Remote Sensing*, 1–7, 1999.

BAATZ, M.; SCHÄPE, A. **Multiresolution Segmentation: an optimization approach for high quality multiscale image segmentation**. 2000. Disponível em: http://www.ecognition.com/sites/default/files/405_baatz_fp_12.pdf. Acesso em Maio de 2017.

BAATZ, M. et al. **eCognition Object Oriented Image Analysis – Guia do usuário**. Germany: Definiens Imaging, 2001.

BARSI, J. A. et al. The spectral response of the Landsat-8 operational land imager. **Remote Sensing**, 6(10), 10232–10251, 2014.

BASTIAANSEN, W. G. M.; MOLDEN, D. J.; MAKIN, I. W. Remote sensing for irrigated agriculture: Examples from research and possible applications. **Agricultural Water Management**, 46(2), 137–155, 2000.

BENZ, U. C. et al. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. **ISPRS Journal of Photogrammetry and Remote Sensing**, 58, 239–258, 2004.

BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, 65(1), 2–16, 2010.

BRUINSMA, J. **The resource outlook to 2050: by how much do land, water and crop yields need to increase by 2050?** Roma: FAO, 2009.

BELTRAN, C. M.; BELMONTE, A. C. Irrigated crop area estimation using Landsat TM imagery in La Mancha, Spain. **Photogramm. Eng. Remote Sensing**, 67, 1177-1184, 2001.

BERNARDO, S.; SOARES, A. A.; MANTOVANI, E. C. **Manual de irrigação**. Ed. 8, atualizada e ampliada. UFV: Viçosa, 2008, 625 p.

BRAGA, A. L.; OLIVEIRA, J. C. de. Identificação e quantificação de áreas irrigadas por pivô central utilizando imagens CCD/CBERS. *Anais... XII Simpósio Brasileiro de Sensoriamento Remoto, Goiânia, Brasil, 16-21, INPE, 53(9), 849–856, 2005.*

CASAROTI, C. J. **Deteção de alterações em área urbana litorânea a partir de imagens IKONOS-II de duas épocas utilizando uma abordagem híbrida**. Dissertação (Mestrado em Ciências Geodésicas) – Setor de Ciências da Terra, Universidade Federal do Paraná, Curitiba-PR, 2015.

CENTRO INTEGRADO DE INFORMAÇÕES AGROMETEOROLÓGICAS (CIIAGRO). **Balanco Hídrico**. Disponível em: <<http://www.ciiagro.sp.gov.br/monitoramentocafe/balancohidrico.htm>>. Acesso em 29 out. 2017.

COELHO, E. F.; FILHO, M. A. C.; OLIVEIRA, S. L. de. Agricultura irrigada: eficiência de irrigação e de uso de água. *Bahia Agrícola*, v.7, n.1, set. 2015.

CHRISTOFIDIS, D. Água, irrigação e agropecuária sustentável. *Revista de Política Agrícola*, Ano XXII, (1), 115–127, 2013.

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

DORREN, L. K. et al. Improved Landsat-based forest mapping in steep mountainous terrain using object-based classification. *Forest Ecology and Management*, vol. 183, p. 31-46, 2003.

DUVEILLER, G. et al. Deforestation in Central Africa: Estimates at regional, national and landscape levels by advanced processing of systematically-distributed Landsat extracts. *Remote Sensing of Environment*, vol.112, n.5, p. 1969-1981, 2008.

ECKHARDT, D. W., VERDIN, J. P., & LYFORD, R. G. (1990). Automated update of an irrigated lands GIS using SPOT HRV imagery. *Photogrammetric Engineering & Remote Sensing*, 56(11), 1515–1522.

FERREIRA, A. B. et al. Mapeamento e Quantificação das Áreas Irrigadas com a Técnica de Pivô Central na Bacia do Rio Paranaíba Brasil. *Anais... XII ENCUESTRO DE GEÓGRAFOS DE AMÉRICA LATINA*, Montevideo, 2009.

FERNANDEZ, G. A. V., SCHERER-WARREN, M., & JUNIOR, C. B. J. (2013). Taxas de uso em uma série histórica de pivôs centrais em uma bacia do Cerrado. *Anais... XVI Simpósio Brasileiro de Sensoriamento*, 320–331.

FERREIRA, E. et al. Cadastral Maps of Irrigated Areas by Center Pivots in the State of Minas Gerais, Using Cbers-2b/Ccd Satellite Imaging. *Engenharia Agrícola*, Jaboticabal, v.31, n.4, p.771-780, 2011.

FRIZZONE, J. A. Os métodos de irrigação. **Notas de aula**. Departamento de Engenharia de Biosistemas – ESALQ/USP, 2017.

GENELETTI, D.; GORTE, B.G.H. A method for object oriented land cover classification combining Landsat TM data and aerial photographs. **International Journal of Remote Sensing**, vol. 24, n. 6, p. 1273-1286, 2003.

GONZALEZ, R. C.; WOODS, R. **Processamento de Imagens Digitais**. Editora Edgard Blucher, São Paulo, 2001.

GROCHALA, A.; KEDZIERSKI, M. A method of panchromatic image modification for satellite imagery data fusion. **Remote Sensing**, vol. 9, n. 639, 2017. doi:10.3390/rs9060639

GUIMARÃES, D. P.; LANDAU, E. C. (2011). Mapeamento de Áreas Irrigadas por Pivôs Centrais no Estado de Minas Gerais. **Boletim de Pesquisa e Desenvolvimento**. Embrapa Milho e Sorgo, ISSN 1619-0154, 2011. 23 p.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. **IEEE Transactions on systems and cybernetics**, vol. SMC-3, n. 6, Novembro, 1973. p. 610 – 621.

IBGE – EMBRAPA. **Mapa de Solos do Brasil**. Rio de Janeiro: IBGE, 2001 - Escala 1:5.000.000.

IBGE. **Censo Agropecuário 2006**. Rio de Janeiro, 2007. Disponível em: <<http://www.sidra.ibge.gov.br>>. Acesso em 13 jul. 2017.

IBGE. **Cidades**. Guaíra-SP. Disponível em: <<https://cidades.ibge.gov.br/brasil/sp/guaira/panorama>>. Acesso em 29 out. 2017.

IBGE. Estatísticas. **Produção Agrícola Municipal (PAM): Culturas temporárias e permanente**. Disponível em: .<<https://www.ibge.gov.br/estatisticas-novoportal/economicas/agricultura-e-pecuaria/2046-np-producao-agricola-municipal/9117-producao-agricola-municipal-culturas-temporarias-e-permanentes.html?&t=downloads>>. Acesso em 25 out. 2017.

INTERNATIONAL COMMISSION ON IRRIGATION AND DRAINAGE (ICID). **Annual Report**. 2016. Disponível em: <http://www.icid.org/ar_2016.pdf>

JOBIN, B., et al. Object-based classification as an alternative approach to the traditional pixel-based classification to identify potential habitat of the grasshopper sparrow. **Environmental Management**, vol. 41, n.1, p. 20-31, 2008.

KAINZ, W. **Fuzzy logic and applications in GIS**. ESRI International User Conference. Course Notes. 2005.

KERSKI, J. **A working definition of spatial thinking**. Disponível em: <<https://blogs.esri.com/esri/gisedcom/2013/05/24/a-working-definition-of-spatial-thinking/>>. Acesso em 13 set. 2017.

- KERSTING, A. P. B. **Mapeamento de obstáculos sob a faixa de domínio de linhas de transmissão usando uma abordagem orientada a objeto, tecnologia LIDAR e câmara digital de pequeno formato**. 173 p. Dissertação (Mestrado em Ciências Geodésicas) – Setor de Ciências da Terra, Universidade Federal do Paraná, Curitiba-PR, 2006.
- LANG, S. **Object-based image analysis for remote sensing applications: modeling reality – dealing with complexity**. In: Blaschke, T.; Lang, S. & Hay, G. J. *Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications*. Berlin: Springer, 2008.
- LIMA, J. E. F. W. et al. Variação da área irrigada por pivô central no Cerrado entre 2002 e 2013. **Item**, n. 104-105. ABID, 2015, 86 p.
- LOBELL, D. B. et al. Remote sensing of regional crop production in the Yaqui Valley, Mexico: Estimates and uncertainties. **Agriculture, Ecosystems and Environment**, 94(2), 205–220, 2003. [https://doi.org/10.1016/S0167-8809\(02\)00021-X](https://doi.org/10.1016/S0167-8809(02)00021-X).
- LU, D.; WENG, Q. A survey of image classification methods and techniques for improving classification performance. **International Journal of Remote Sensing**, 28(5), 823–870, 2007. <https://doi.org/10.1080/01431160600746456>.
- MARTINS, J. D. et al. Levantamento da área irrigada por pivô central no estado do rio grande do sul. **Irriga**, 21(2), 300–311, 2016.
- MELLO, J. L. P.; SILVA, L. D. B. da. Irrigação. **Notas de aula**. Departamento de Engenharia – Universidade Federal Rural do Rio de Janeiro, 2011. Disponível em: http://www.ufrj.br/institutos/it/deng/jorge/downloads/APOSTILA/Apostila%20IT%20157/Irriga%E7%E3o_Vers%E3o3.5.pdf. Acesso em Novembro de 2016.
- MENDES, A. A. T. **Irrigação: tecnologia e produtividade**. In: SIMPÓSIO INTERNACIONAL DE FRUTICULTURA IRRIGADA, 1998, Jales, SP.
- MENESES, P. R.; SANO, E. E. Classificação Pixel a Pixel de Imagens. In: MENESES, P. R.; ALMEIDA, T. (org.) **Introdução ao Processamento de Imagens de Sensoriamento Remoto**. Brasília: CNPq, 2012. 266 p.
- MIRANDA, J. I. **Processamento de imagens digitais: métodos multivariados em Java**. Campinas: Embrapa Informática Agropecuária, 2011.
- MYINT, S. W. et al. Comparison of remote sensing image processing techniques to identify tornado damage areas from landsat TM data. **Sensors**, vol. 8, n. 2, p. 1128-1156, 2008.
- NATH, S. S. et al. **A survey of image classification methods and techniques**. In: International Conference on Control, Instrumentation, Communication and Computational Technologies (ICCICCT), 554–557, 2014. <https://doi.org/10.1109/ICCICCT.2014.6993023>.
- NETO, M. S. A. **Balanço hídrico segundo Thornthwaite & Mather (1955)**. Comunicado Técnico – EMBRAPA, n. 34, junho de 1989, p. 1-18.

NEUBERT, M. Segment-based analysis of high resolution satellite and laser scanning data. **EnviroInfo: Sustainability in the Information Society**. Metropolis Verlag, Marburg, ISBN: 3-89518-370-9, 2001.

NEUBERT, M.; MEINEL, G. **Análise de dados do satélite Ikonos baseada em segmentação – Utilização do software de análise de dados eCognition para diferentes áreas-testes**. In: Blaschke, T. & Kux, H. Sensoriamento remoto e SIG avançados: novos sistemas sensores – métodos inovadores. 2ª ed. São Paulo: Oficina de Textos, 2007.

OZDOGAN, M., et al. Remote sensing of irrigated agriculture: Opportunities and challenges. **Remote Sensing**, 2(9), 2274–2304, 2010.

OZDOGAN, M.; GUTMAN, G. A new methodology to map irrigated areas using multi-temporal MODIS and ancillary data: An application example in the continental US. **Remote Sensing of Environment**, 112(9), 3520–3537, 2008.

PAX-LENNEY, M. et al. The status of agricultural lands in Egypt: The use of multitemporal NDVI features derived from Landsat TM. **Remote Sens. Environ.** 1996, 56, 8-20.

PILZ, H.; STROBLM, J. **Análise de impermeabilização com base em ortofotografias aéreas coloridas digitais através de processamento de imagens orientadas a objetos**. In: Blaschke, T. & Kux, H. Sensoriamento remoto e SIG avançados: novos sistemas sensores – métodos inovadores. 2ª ed. São Paulo: Oficina de Textos, 2007.

PRATT, W. K. **Digital Image Processing**. 4th Edition. New Jersey: John Wiley & Sons Inc., 2007.

RAM, B.; KOLARKAR, A. S. Remote sensing application in monitoring land-use changes in arid Rajasthan, **Int. J. Remote Sens.** 14(17), 3191-3220, 1993.

RUNDQUIST, D. C. et al. The Nebraska Center-Pivot Inventory - an Example of Operational Satellite Remote-Sensing on a Long-Term Basis. **Photogrammetric Engineering and Remote Sensing**, 55(5), 587–590, 1989.

SANO, E. et. al. Estimativa da variação na demanda de água para irrigação por pivô-central no Distrito Federal entre 1992 e 2002. **Revista Engenharia Agrícola**, 25(2), 508–515, 2005.

SCHIEWE, J.; TUFTE, L.; EHLERS, M. Potential and problems of multi-scale segmentation methods in remote sensing. **Geographische Informationssysteme**, 6: 34-39, 2001.

SCHMIDT, W. et al. Distribuição espacial de pivôs centrais no Brasil: I - Região Sudeste. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.8, n.2/3, p.330-333, 2004.

SOUZA, O. N. **Introdução à Teoria dos Conjuntos Fuzzy**. 2010. Disponível em: <www.ime.unicamp.br/~valle/PDFfiles/osmar10.pdf>. Acesso em outubro de 2017.

STRAHLER, A. H. et al. On the nature of models in remote sensing. **Remote Sensing of Environment** 20, 121–139, 1986.

TEDESCO, A. **Delimitação de Voçoroca com Imagens de Alta Resolução e ALS por meio de Árvore de Decisão e Geobia**. Tese (Doutorado em Ciências Geodésicas). UFPR (Universidade Federal do Paraná). Curitiba, 30 de Julho de 2015.

TILMAN, D., et al. Agricultural sustainability and intensive production practices. **Nature**, 418(8), 671–677, 2002. <https://doi.org/10.1038/nature01014>.

THORNTHWAITE, C.W.; MATHER, J.R. **The water balance**. Centerton, NJ: Drexel Institute of Technology - Laboratory of Climatology, 1955. 104p. (Publications in Climatology, vol. VIII, n.1)

TRIMBLE. **eCognition® Developer 8.8 - Reference Book**. 2012a.

TRIMBLE. **eCognition® Developer 8.8 - User Guide**. 2012b.

THENKABAIL, P. S.; SCHULL, M.; TURRAL, H. Ganges and Indus river basin land use/land cover (LULC) and irrigated area mapping using continuous streams of MODIS data. **Remote Sensing of Environment**, 95(3), 317–341, 2005. <https://doi.org/10.1016/j.rse.2004.12.018>.

UN DESA - United Nations, Department of Economic and Social Affairs. **World population prospects: the 2008 revision, highlights**. New York, 2009. (Working paper, ESA/P/WP.210).

USGS. United States Geological Survey. **User Guide**. Disponível em: <https://landsat.usgs.gov/sites/default/files/documents/espas_odi_userguide.pdf>. Acesso em 25 out. 2017.

WILLHAUCK, G. et al. Comparison of Object Oriented Classification Techniques and Standart Image Analysis for the Use of Change Detection between SPOT Multispectral Satellite Images and Aerial Photos. In. **Proceedings** of XIX ISPRS Congress. 16 a 23 de Julho de 2000. Amsterdã, Holanda. Páginas 214-221.

ZADEH, L. A. Fuzzy sets. **Information and Control**, 8(3), 338–353, 1965. [https://doi.org/10.1016/S0019-9958\(65\)90241-X](https://doi.org/10.1016/S0019-9958(65)90241-X).

ZADEH, L. A. Is there a need for fuzzy logic? **Information Sciences**, 178(13), 2751–2779, 2008. <https://doi.org/10.1016/j.ins.2008.02.012>.

ZONTA, J. H.; BEZERRA et al. Efeito da irrigação no rendimento e qualidade de fibras em cultivares de algodoeiro herbáceo. **Revista Caatinga**, 28(4), 43–52, 2015.