

**SAMARA CALÇADO DE AZEVEDO**

**DETECÇÃO E REMOÇÃO AUTOMÁTICA DOS EFEITOS DAS SOMBRAS DE  
ÁREAS URBANAS EM IMAGENS MULTIESPECTRAIS COM ALTA RESOLUÇÃO  
ESPACIAL**



**Presidente Prudente**

**2018**

**SAMARA CALÇADO DE AZEVEDO**

**DETECÇÃO E REMOÇÃO AUTOMÁTICA DOS EFEITOS DAS SOMBRAS DE  
ÁREAS URBANAS EM IMAGENS MULTIESPECTRAIS COM ALTA RESOLUÇÃO  
ESPACIAL**

Tese de doutorado apresentada ao Programa de Pós-Graduação em Ciências Cartográficas da Faculdade de Ciências e Tecnologia — Universidade Estadual Paulista (UNESP), como parte dos requisitos para a obtenção do título de Doutor em Ciências Cartográficas. Área de concentração em aquisição, análise e representação de informações espaciais.

Orientador: Prof. Dr. Erivaldo Antônio da Silva

**Presidente Prudente**

**2018**

Ficha catalográfica elaborada pela Seção Técnica de Aquisição e Tratamento da Informação - Diretoria Técnica de Biblioteca e Documentação - UNESP, Campus de Presidente Prudente

Azevedo, Samara Calçado de.  
A988d      Detecção e remoção automática dos efeitos das sombras de áreas urbanas em imagens multiespectrais com alta resolução espacial / Samara Calçado de Azevedo. - 2018  
137 f.

Orientador: Erivaldo Antonio da Silva  
Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Ciências e Tecnologia, Presidente Prudente, 2018  
Inclui bibliografia

1. Detecção automática de sombras. 2. Inpainting. 3. Imagens de alta resolução espacial. I. Silva, Erivaldo Antonio. II. Universidade Estadual Paulista. Faculdade de Ciências e Tecnologia. III. Título.

Alessandra Kuba Oshiro Assunção  
CRB-8/9013

**CERTIFICADO DE APROVAÇÃO**

**TÍTULO: DETECÇÃO E REMOÇÃO AUTOMÁTICA DOS EFEITOS DAS SOMBRAS DE ÁREAS URBANAS EM IMAGENS MULTIESPECTRAIS COM ALTA RESOLUÇÃO ESPACIAL**

**AUTORA: SAMARA CALÇADO DE AZEVEDO**

**ORIENTADOR: ERIVALDO ANTONIO DA SILVA**

Aprovada como parte das exigências para obtenção do Título de Doutora em CIÊNCIAS CARTOGRÁFICAS, área: AQUISIÇÃO, ANÁLISE E REPRESENTAÇÃO DE INFORMAÇÕES ESPACIAIS pela Comissão Examinadora:



Prof. Dr. ERIVALDO ANTONIO DA SILVA

Departamento de Cartografia / Faculdade de Ciências e Tecnologia de Presidente Prudente




Prof. Dr. SEBASTIÃO MILTON PINHEIRO DA SILVA

Centro de Ciências Humanas, Letras e Artes / Universidade Federal do Rio Grande do Norte



Prof. Dr. WALLACE CORREA DE OLIVEIRA CASACA

Coordenadoria de Curso de Engenharia de Energia / Câmpus de Rosana



Prof. Dr. AYLTON PAGAMISSE

Departamento de Matemática e Computação / Faculdade de Ciências e Tecnologia de Presidente Prudente



Prof. Dr. JOSÉ ROBERTO NOGUEIRA

Departamento de Matemática e Computação / Faculdade de Ciências e Tecnologia de Presidente Prudente

Presidente Prudente, 30 de agosto de 2018

*À minha família e amigos,  
com carinho dedico.*

## **AGRADECIMENTOS**

Agradeço em primeiro lugar à Deus, pelas oportunidades guiadas até aqui e que me concedeu forças para que a vontade de concluir o trabalho fosse sempre maior que as dificuldades enfrentadas.

À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) pelo financiamento deste projeto de doutorado, por meio da concessão de bolsa de estudo e reserva técnica durante todo o período, tanto no Brasil (Processo nº 2013/25257-4), quanto no exterior (Processo BEPE nº 2015/26743-5).

Agradeço imensamente ao meu orientador Prof. Dr. Erivaldo Antonio da Silva, pela confiança depositada em mim para a conclusão de cada etapa desde a iniciação científica, pelo apoio incondicional, pelo incentivo, pelos ensinamentos e pela sincera amizade ao longo desses muitos anos. Ao Prof. Dr. Ramesh P. Singh, pela recepção na Chapman University e por todo apoio durante o período do doutorado sanduíche, pelos ensinamentos, pelo incentivo à pesquisa e pela contribuição valiosa no meu desenvolvimento como pesquisadora.

Agradeço também aos membros da banca, os professores Dr. Aylton Pagamisse, Dr. José Roberto Nogueira, Dr. Sebastião Milton Pinheiro da Silva e ao Dr. Wallace Correa de Oliveira Casaca pelas contribuições dadas para o aperfeiçoamento do trabalho. Em especial, o meu sincero agradecimento ao Wallace por sua disposição e auxílio, fornecendo dados e contribuindo com valiosas discussões e sugestões.

Ao Programa de Pós-Graduação em Ciências Cartográficas (PPGCC) e à Universidade Estadual Paulista (UNESP) pela infraestrutura e pelas oportunidades oferecidas. Aos professores do departamento de Cartografia e de Matemática e Computação da UNESP por todo ensinamento que contribuíram na minha formação acadêmica e científica. Agradeço também aos funcionários que tornaram-se amigos, em especial a Cida, Zilda, Cínthia e Tamae, por toda atenção e ajuda a qualquer hora.

Por fim e não menos importante, à minha família e aos meus amigos, pela paciência perante as minhas ausências, pelo apoio incondicional, pela confiança e incentivo depositados em meu trabalho, que muitas vezes foi maior do que a minha própria confiança. Infelizmente o espaço é curto para elencar todos que estão em meus pensamentos, mas os verdadeiros sabem quem são! Vocês são a minha base e o meu porto seguro!

Eu não poderia deixar de agradecer aos meus amigos do grupo de pesquisa e de vida, em especial à Miriam por ter despertado em mim a sementinha da pesquisa e que também me mostra o quão é importante cultivar as amizades boas para compartilhar os melhores

momentos da vida e ter muitas histórias juntas para contar! À Fernanda pelos conselhos, parcerias, conversas e risos. Ao Guilherme pela paciência, parceria e prontidão sempre para ajudar em qualquer assunto, e ao Renan pela amizade desde a graduação regada de muita conversa e parceria.

Agradeço aos muitos amigos e colegas que conquistei ao longo dessa trajetória no PPGCC, em especial à Tayná, Raquel, Chaenne, Crislaine, Mari, Gabi, Carioca, Gabriel, Prol, Vini, Bruno, Érico, Lucas e Paulo pela companhia, amizade, paciência, conselhos e momentos de descontração. Vocês além de amigos de profissão, são parte importante nesta caminhada e também da minha vida! Obrigada de coração!

E a todos, que de alguma forma contribuíram direta ou indiretamente para a realização deste trabalho, o meu sincero MUITO OBRIGADA!

## RESUMO

Imagens orbitais com alta resolução espacial abriram uma nova era na extração de informações, especialmente em ambientes urbanos, em que valiosas informações sobre as superfícies tornaram-se disponíveis e de forma detalhada. No entanto, a obtenção de informação em áreas urbanas complexas pode ser comprometida pela presença de sombras, que chegam a ocupar uma parte significativa da imagem, causando sérias interferências na sua análise. A remoção de sombras é, portanto, um tema importante e ainda não resolvido devido à dificuldade da tarefa, sendo necessária na etapa de pré-processamento de diversas aplicações. Este trabalho propõe o desenvolvimento de uma nova abordagem automática para a restauração de áreas de sombras em imagens de satélite multiespectrais com alta resolução espacial. A abordagem se divide em três etapas principais e sequenciais, sendo a primeira o pré-processamento, que consiste na conversão das imagens para reflectância aparente e na fusão das bandas para a geração de índices espectrais. Na segunda etapa, a detecção das áreas de sombras é realizada pela combinação do *top-hat* por fechamento com a injeção de um parâmetro de área, calculado em função do índice de sombras NSDVI (*Normalized Saturation-Value Difference Index*). As regiões de sombras são refinadas para a geração da máscara de sombras, a qual é utilizada na terceira etapa, como guia na restauração pelo inpainting automático. A estratégia de restauração pelo inpainting híbrido, adaptado para o contexto multiespectral, combina a difusão anisotrópica, ordem de preenchimento definida a partir de uma imagem *cartoon* e equação de transporte, e o preenchimento baseado em blocos por amostragem local. A avaliação experimental do método proposto foi realizada em um conjunto de 215 imagens, fruto do recorte de duas cenas dos satélites WorldView-2 (WV-2) e Pléiades-1B (PL-1B) sobre a área urbana de São Paulo. Os resultados mostraram uma boa performance da detecção de sombras pelo método proposto, alcançando uma acurácia global média de 94,20% e de 90,84%, para as imagens WV-2 e PL-1B, respectivamente, sendo inclusive superior, quando comparado com outros dois métodos propostos na literatura. A remoção dos efeitos das sombras obtido pelo inpainting, proporcionou uma restauração satisfatória e coerente de feições como vias e telhados, que ficaram melhor discerníveis pelo inpainting. Além disso, quando quantidades substanciais de áreas não contaminadas por sombras estão disponíveis, o inpainting aumentou as áreas úteis da imagem mais do que a restauração baseada em outras técnicas de transformação de intensidades, como o matching de histogramas. Assim, frente à necessidade de informações extraídas de imagens multiespectrais, espera-se que o método possa contribuir com a detecção e remoção automática dos efeitos de sombras em imagens multiespectrais com alta resolução espacial de áreas urbanas.

**Palavras-chave:** detecção automática de sombras, inpainting, melhoria radiométrica, morfologia matemática, imagens de alta resolução.

## ABSTRACT

High resolution satellite images has played an important role in information extraction especially in urban areas, since valuable information and higher level of details from surface become available with these images. Nevertheless, the task of extracting information from complex urban environment can be hampered by shadows, which can occupy a significant part into the image and, thus negatively affecting the image analysis. Therefore, due to the complexity of the problem, shadow removal is a crucial as one of the first pre-processing steps to enhance the performance of many subsequent steps and applications. The main goal of this thesis is to present a new automatic method for shadow removal in high spatial resolution satellite multispectral images. The proposed method comprises three main steps: the first one is the pre-processing, which includes the conversion of the target image to the top of atmosphere (TOA) reflectance and the image pansherpening to spectral indices generation. Secondly, a shadow pixels candidates' identification is performed, combining black-top-hat (BTH) transformation with area injunction driven by the normalized saturation-value difference index (NSDVI) mask. The obtained output is a shadow mask, which is used to properly guide our automatic inpainting-inspired strategy in the restoration step. In the third step, a hybrid inpainting-based strategy specifically adapted for the multispectral imagery context is applied to recover shadow areas, which unifies anisotropic diffusion, filling-in priority based on cartoon image representations, transport equation and block-based pixel replication using local dynamic sampling. The performance of our approach has been evaluated by taking 215 subset images from WorldView-2 (WV-2) and Pléiades-1B (PL-1B) that encompasses the city of São Paulo. The method achieves an overall accuracy on shadow detection up to 94.2%, for WV-2, and 90.84%, for PL-1B. The comparative results indicate that the proposed method outperforms two existing state-of-the-art methods. Shadow effects are mitigated by local inpainting method in which the satisfactory outputs demonstrate good coherence for highway and building rooftops recovery. Moreover, when largely non-contaminated areas are available in the image, the proposed approach improves significantly more areas of the image than the intensity-based transformation techniques, such as the histogram matching method. Once only multispectral imagery is required as input data, the approach can be suitable to support other remote sensing applications as well.

**Keywords:** Automatic Shadow Detection, Hybrid Inpainting, Shadow Enhancement, Mathematical Morphology, High Resolution Imagery

## LISTA DE FIGURAS

|                                                                                                                                                                                                         |    |
|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 1 - Sistema de imageamento por varredura linear (pushbroom). .....                                                                                                                               | 29 |
| Figura 2 - Resolução espacial dos principais satélites de observação terrestre. ....                                                                                                                    | 30 |
| Figura 3 - Característica da resolução espacial para diferentes sensores. ....                                                                                                                          | 31 |
| Figura 4 – Geometria de Aquisição dos dados. ....                                                                                                                                                       | 37 |
| Figura 5 – Exemplo da grande ocorrência de áreas de sombras em função da alta densidade de feições antrópicas sobre imagens com alta resolução espacial. ....                                           | 41 |
| Figura 6 – Diferentes contribuições na radiância medida pelo sensor para um alvo iluminado A e um sombreado B. ....                                                                                     | 42 |
| Figura 7 – Exemplo da decomposição em limiares. (a) Imagem f; (b) Superfície topográfica de f; (c) Zonas planas geradas pela decomposição em n limiares. ....                                           | 47 |
| Figura 8 - Exemplo do fechamento morfológico por área. (a) Imagem original 30x30 pixels; (b) Resultado do fechamento com atributo área $\lambda=50$ .....                                               | 49 |
| Figura 9 – Exemplo do comportamento das sombras no espaço HSV. (a) Imagem original WV-2; (b) Componente Saturação; (c) Componente Valor. ....                                                           | 59 |
| Figura 10 – Exemplos de imagens de SR com descontinuidades, informações faltantes e corrompidas. (a) Imagem do Landsat 7 ETM+ SLC-off ; (b) Porção da imagem contaminada por nuvens e (c) Sombras. .... | 60 |
| Figura 11 – Plotagem da transformação de intensidade pela função de potência (Equação 18) para diferentes valores de $\gamma$ . ....                                                                    | 62 |
| Figura 12 - Aplicação da correção gamma por Nakajima et al. (2003). (a) Imagem IKONOS original (banda PAN) com a presença de sombras e (b) Imagem corrigida. ....                                       | 63 |
| Figura 13 - Procedimento de transformação por especificação de histograma. ....                                                                                                                         | 65 |
| Figura 14 – Resultado da aplicação da especificação de histograma por Tsai et al. (2006). (a) Imagem aérea original com sombras e (b) Imagem corrigida. ....                                            | 66 |
| Figura 15 – Resultado da aplicação correlação linear [Chen et al., 2007]. (a) Imagem original do satélite QuickBird com sombras e (b) Imagem corrigida. ....                                            | 67 |
| Figura 16 - Descrição geral do processo de inpainting. ....                                                                                                                                             | 68 |
| Figura 17 - Exemplo da direção de propagação por linhas isocrômicas da imagem. ....                                                                                                                     | 69 |
| Figura 18 – Ilustração da abordagem de reconstrução baseada em exemplos proposta por Criminisi et al. (2004). ....                                                                                      | 71 |
| Figura 19: Localização das cenas utilizadas nos experimentos. ....                                                                                                                                      | 76 |
| Figura 20 - Exemplo de feições antrópicas e suas respectivas projeções de sombras presentes nas imagens WolrdView-2 e Pléiades-1B utilizadas. ....                                                      | 76 |
| Figura 21 – Fluxograma das principais etapas envolvidas no método de remoção de sombras. ....                                                                                                           | 78 |
| Figura 22 - Esquema ilustrando o processo de avaliação da fusão. ....                                                                                                                                   | 80 |
| Figura 23 – Estimativa de área por meio do índice espectral de sombras. ....                                                                                                                            | 82 |

|                                                                                                                                                                                                                                                                                                             |     |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Figura 24 – Ilustração das características obtidas pela decomposição da imagem Pléiades 29_9. (a) Imagem original; (b) campo das direções de uma amostra (em amarelo) de (a); (c) componente cartoon de (a) e (d) campo de direções da mesma amostra (em amarelo) de (c). ....                              | 85  |
| Figura 25 - Ilustração do esquema de preenchimento por blocos através da amostragem dinâmica. ...                                                                                                                                                                                                           | 88  |
| Figura 26 - Resultado da conversão dos NDs para valores físicos. (a) Imagem WV-2 PAN original; (b) Imagem WV-2 PAN corrigida; (c) Composição colorida normal original e (d) Composição colorida normal corrigida. ....                                                                                      | 89  |
| Figura 27 - Resultado da conversão dos NDs para valores físicos. (a) PL-1B PAN original; (b) PL-1B PAN corrigida; (c) Composição colorida normal original e (d) Composição colorida normal corrigida. ....                                                                                                  | 90  |
| Figura 28 - Resultado da fusão aplicados ao conjunto de imagens WV-2 (a-c) e PL-1B (d-f).....                                                                                                                                                                                                               | 91  |
| Figura 29 - Desempenho da detecção para o conjunto de imagens WV-2.....                                                                                                                                                                                                                                     | 94  |
| Figura 30 - Melhores desempenhos apresentados pelo método sobre as imagens WV-2. (a) Imagem original 12_29, (b) Resultado da detecção e (c) Resultado sobreposto na composição falsa cor; (d) Imagem original 20_51, (e) Resultado da detecção e (f) Sobreposição do resultado na composição falsa cor..... | 95  |
| Figura 31 - Resultado com menor desempenho do conjunto de imagens WV-2. (a) Composição falsa cor da imagem original 44_31; (b) GT da imagem; (c) Resultado da detecção e (d) Sobreposição do resultado na composição falsa cor.....                                                                         | 96  |
| Figura 32 - Desempenho da detecção para o conjunto de dados PL-1B. ....                                                                                                                                                                                                                                     | 96  |
| Figura 33 - Melhor desempenho apresentado pelo método sobre o conjunto de imagens PL-1B. (a) Composição falsa cor da imagem original 14_44; (b) Resultado da detecção e (c) Resultado sobreposto na composição falsa cor .....                                                                              | 97  |
| Figura 34 - Resultado com menor desempenho do conjunto de imagens PL-1B. (a) Composição falsa cor da imagem original 54_23; (b) GT da imagem; (c) Resultado da detecção e (d) Sobreposição do resultado na composição falsa cor.....                                                                        | 97  |
| Figura 35 - Exemplo do bom desempenho do método de detecção frente à alvos que se confundem com sombras como (a) carros, (b) piscinas e (c) corpo d'água. ....                                                                                                                                              | 98  |
| Figura 36 - Dois exemplos de resultados da detecção de sombras obtidos sobre imagens WV-2. Primeira linha: (a) Imagem original WV-2 11_24; (b) Resultado da detecção e (c) GT da imagem. Segunda linha: (d) Imagem original WV-2 29_27; (e) Resultado da detecção e (f) GT da imagem. ....                  | 99  |
| Figura 37 - Dois exemplos de resultados da detecção de sombras obtidos sobre imagens PL-1B. Primeira linha: (a) Imagem original PL-1B 10_41; (b) Resultado da detecção e (c) GT da imagem. Segunda linha: (d) Imagem original PL-1B 48_40; (e) Resultado da detecção e (f) GT da imagem. ....               | 99  |
| Figura 38 – Comparação da Acurácia Global da detecção pelo método proposto com dois métodos existentes na literatura sobre o conjunto de imagens: (a) WW-2 e (b) PL-1B.....                                                                                                                                 | 101 |

|                                                                                                                                                                                                                                                                 |     |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Figura 39 – Análise comparativa de desempenho apresentado pelos métodos. (a) Composição colorida falsa cor da imagem WV-2 43_41 e (b) Sobreposição dos resultados; (c) Composição colorida falsa cor da imagem WV-2 8_40 e (d) Sobreposição dos resultados..... | 102 |
| Figura 40 - Análise comparativa de desempenho apresentado pelos métodos. (a) Composição colorida falsa cor da imagem PL-1B 7_46 E (b) Sobreposição dos resultados.....                                                                                          | 103 |
| Figura 41 – Avaliação do desempenho da abordagem sobre feições de textura de SR. (a) e (d) Imagens originais; (b) e (e) Áreas simuladas a serem recuperadas; (c) e (f) Imagens restauradas.....                                                                 | 105 |
| Figura 42 – Resultado da reconstrução pelo inpainting guiado por máscara. (a) e (d) Imagens originais; (b) e (e) Domínio de inpainting por máscaras manuais; (c) e (f) Imagens reconstruídas.....                                                               | 106 |
| Figura 43 – Detalhes da reconstrução apresentada na Figura 42. ....                                                                                                                                                                                             | 106 |
| Figura 44 – Inpainting automático e restauração de imagens WV-2 2_32. (a) Imagem Original; (b) Imagem restaurada; (c-e) Detalhes da reconstrução.....                                                                                                           | 108 |
| Figura 45 - Inpainting automático e restauração de imagens WV-2 19_49. (a) Imagem Original; (b) Imagem restaurada; (c-e) Detalhes da reconstrução.....                                                                                                          | 108 |
| Figura 46 - Inpainting automático e restauração de imagens WV-2 49_30. (a) Imagem Original; (b) Imagem restaurada; (c-e) Detalhes da reconstrução.....                                                                                                          | 109 |
| Figura 47 - Restauração da imagem PL-1B 8_8 pelo inpainting automático. (a) Imagem Original; (b) Imagem restaurada; (c-e) Detalhes da reconstrução.....                                                                                                         | 110 |
| Figura 48 - Restauração da imagem PL-1B 16_57 pelo inpainting automático. (a) Imagem Original; (b) Imagem restaurada; (c-e) Detalhes da reconstrução.....                                                                                                       | 110 |
| Figura 49 - Restauração da imagem PL-1B 2_23 pelo inpainting automático. (a) Imagem Original; (b) Imagem restaurada; (c-e) Detalhes da reconstrução.....                                                                                                        | 111 |
| Figura 50 – Limitação do método automático de inpainting na reconstrução de imagens com sombras presentes em grande parte da imagem. (a) Imagem original WV-2 36_31; (b) Imagem original PL-1B 48_40; (c) e (d) Imagens reconstruídas inadequadamente. ....     | 113 |
| Figura 51 – Comparação com técnicas de melhoria de intensidade. (a) Imagem original WV-2 19_49; (b) Imagem restaurada pela CG, (c) pela LC, (e) pelo HM e (e) pelo inpainting .....                                                                             | 114 |
| Figura 52 - Comparação com técnicas de melhoria de intensidade. (a) Imagem original PL-1B 8_8; (b) Imagem restaurada pela GC, (c) pela LC, (d) pelo HM e (e) pelo inpainting. ....                                                                              | 114 |
| Figura 53 – Detalhes da comparação entre os resultados das técnicas de restauração extraídos da Figura 50 (a-e) em amarelo e de 51 (a-e) em vermelho.....                                                                                                       | 115 |
| Figura 54 - Reconstrução de áreas extensas de sombras pelos métodos de transformação de intensidades. (a) Imagem original WV-2 36_31; resultado da restauração por: (b) GC, (c) LC e (d) HM. ....                                                               | 116 |
| Figura 55 – Área de sobreposição entre a imagem de referência (PL-1A 2013) e a imagem utilizada nos experimentos (PL-1B 2015). ....                                                                                                                             | 117 |
| Figura 56 – Comparação dos valores de intensidade RGB referente a amostras de pixels de três alvos de SR. (a) Valores RGB em condições de sombras; (b) Valores RGB após a restauração; (c) Valores RGB                                                          |     |

|                                                                                                                                                                                                                                                                                                           |     |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| na imagem de referência sem sombras; (d) Valores RGB para alvos do mesmo tipo sob condições de iluminações normais na imagem 2015. ....                                                                                                                                                                   | 118 |
| Figura 57 - Comparação análoga à Figura 56 para outros pontos dos mesmos tipos de alvos de SR analisados. (a) Valores RGB em condições de sombras; (b) Valores RGB após a restauração; (c) Valores RGB na imagem de referência sem sombras; (d) Valores RGB para alvos do mesmo tipo da imagem 2015. .... | 119 |
| Figura 58 – Resultado da classificação não-supervisionada pelo k-médias. (a) Imagem original WV-2 13_49 e (b) sua classificação; (c) Imagem (a) restaurada e (d) sua classificação; (e) Imagem original WV-2 19_49 e (f) sua classificação; (g) Imagem (e) restaurada e (f) sua classificação. ....       | 120 |
| Figura 59 – Resultado do índice NDVI após a restauração da imagem. (a) Imagem original PL-1B 55_34; (b) Imagem (a) restaurada; (c) NDVI aplicado às bandas de (a) e (d) NDVI aplicado às bandas de (b). ....                                                                                              | 122 |

## LISTA DE TABELAS

|                                                                                                                                                 |     |
|-------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Tabela 1 - Informações sobre a geometria de aquisição. ....                                                                                     | 77  |
| Tabela 2 - Metadados das bandas do sensor WorldView-2. ....                                                                                     | 79  |
| Tabela 3 - Metadados das bandas do sensor Pléiades-1B. ....                                                                                     | 79  |
| Tabela 4 - Estatísticas das 5 bandas após a conversão para reflectância. ....                                                                   | 90  |
| Tabela 5 – Métricas de qualidade para avaliar as distorções dos métodos de fusão CP e GS aplicados sobre as imagens WV-2 e Pléiades-1B. ....    | 92  |
| Tabela 6 - Valores médios dos índices de acurácia calculados na avaliação quantitativa da detecção. ....                                        | 93  |
| Tabela 7 - Acurácia da detecção nas imagens mostradas na Figura 36 e Figura 37. ....                                                            | 100 |
| Tabela 8 - Análise comparativa das taxas de acurácia da detecção para o índice NSDVI, o método de Movia et al. (2016) e o método proposto. .... | 101 |
| Tabela 9 – Informações dos resultados e parâmetros adotados na reconstrução. ....                                                               | 112 |
| Tabela 10 - Informações sobre a geometria de aquisição da imagem de referência. ....                                                            | 118 |

## LISTA DE ABREVEATURAS E SIGLAS

BTH - *Black Top-Hat*

EE - Elemento Estruturante

EVI - *Enhanced Vegetation Index*

CC - Coeficiente de Correlação

CP - Componentes Principais

DCT – Transformada Discreta do Cosseno

EDP – Equações Diferenciais Parciais

ERGAS - *Relative Global Dimensional Synthesis Error*

ENVI - *Environment for Visualizing Images*

EVI - *Enhanced Vegetation Index*

FN – Falso Negativo

FP – Falso Positivo

FWHM - Largura Completa na Metade do Máximo

GC - *Gamma Correction*

GSD - *Ground Sample Distance*

GS - *Gram-Schmidt*

GT- *Ground Truth*

HM – *Histogram Matching*

HSI - *Hue, Saturation and Intensity*

HSV- *Hue, Saturation, and Value*

IFOV- *Instantaneous Field of View*

LC – *Linear Correlation*

LUT – *Look Up Table*

MDT - Modelo Digital de Terreno

MDS - Modelo Digital de Superfície

MM - Morfologia Matemática

MS - Multiespectral

ND - Nível Digital

NDVI - *Normalized Difference Vegetation Index*

NIR - Infravermelho Próximo

NRMSD - *Normalized Root Mean-Square Deviation*

NSDVI - *Normalized Saturation-Value Difference Index*

nSI - *Normalized Shadow Index*  
PAN - Pancromática  
PDI - Processamento Digital de Imagens  
PL-1A - Pléíades-1A  
PL-1B – Pléíades-1B  
PMI - Processamento Morfológico de Imagens  
QUAC - *Quick Atmospheric Correction*  
REM - Radiação eletromagnética  
RGB - *Red, Green and Blue*  
RMSE - *Root Mean Squared Error*  
SLC - *Scan Line Corrector*  
SR- Sensoriamento Remoto  
SSD - *Sum of Squared Differences*  
TN – *True Negative*  
TOA – *Topo da Atmosfera*  
TP – *True Positive*  
TV- *Total Variation*  
UIQI - *Universal Image Quality Index*  
UTM – Universal Transversa de Mercator  
WBI – *Water Body Index*  
WGS84 - *World Geodetic System 1984*  
WV-2 – WorldView-2

## SUMÁRIO

|                                                                                        |           |
|----------------------------------------------------------------------------------------|-----------|
| <b>1. INTRODUÇÃO .....</b>                                                             | <b>17</b> |
| <b>1.1 Caracterização do Problema.....</b>                                             | <b>17</b> |
| <b>1.2 Hipótese e Objetivos .....</b>                                                  | <b>19</b> |
| <b>1.3 Trabalhos Relacionados e Potencial de Contribuição .....</b>                    | <b>20</b> |
| <b>1.4 Estrutura da Tese .....</b>                                                     | <b>26</b> |
| <b>2. FUNDAMENTAÇÃO TEÓRICA.....</b>                                                   | <b>27</b> |
| <b>2.1 Sensoriamento Remoto do Ambiente Urbano.....</b>                                | <b>27</b> |
| 2.1.1 Características dos Sensores e Imagens.....                                      | 28        |
| 2.1.2 Influências Radiométricas .....                                                  | 34        |
| 2.1.3 Influências da Geometria de Aquisição.....                                       | 36        |
| 2.1.4 O Problema de Sombras em Imagens.....                                            | 39        |
| 2.1.4.1 Características Gerais.....                                                    | 41        |
| <b>2.2 Processamento Digital de Imagens Orbitais com Alta Resolução Espacial .....</b> | <b>43</b> |
| 2.2.1 Processamento Morfológico de Imagens.....                                        | 43        |
| 2.2.1.1 Filtros Morfológicos .....                                                     | 45        |
| 2.2.1.2 Filtragem Morfológica por Atributo .....                                       | 48        |
| 2.2.1.3 Transformação Top-hat.....                                                     | 50        |
| 2.2.2 Fusão de Imagens .....                                                           | 51        |
| 2.2.2.1 Componentes Principais.....                                                    | 52        |
| 2.2.2.2 Gram-Schmidt.....                                                              | 53        |
| 2.2.2.3 Métricas para Análise da Qualidade da Fusão .....                              | 54        |
| 2.2.3 Índices Espectrais .....                                                         | 57        |
| <b>2.3 Restauração de Informações em Dados de Sensoriamento Remoto .....</b>           | <b>59</b> |
| 2.3.1 Transformações de Intensidades em Imagens .....                                  | 60        |
| 2.3.2 Restauração de Imagens por Inpainting Digital.....                               | 67        |
| 2.3.2.1 Métodos de Inpainting .....                                                    | 69        |
| <b>3. MATERIAIS E MÉTODO .....</b>                                                     | <b>74</b> |
| <b>3.1 Materiais.....</b>                                                              | <b>74</b> |
| 3.1.1 Recursos Computacionais e Softwares .....                                        | 74        |
| 3.1.2 Imagens Multiespectrais .....                                                    | 75        |

|                                                                                |            |
|--------------------------------------------------------------------------------|------------|
| <b>3.2 Metodologia Proposta.....</b>                                           | <b>77</b>  |
| 3.2.1 Pré-processamento .....                                                  | 78         |
| 3.2.2 Abordagem para Detecção Automática de Sombras .....                      | 81         |
| 3.2.2.1 Avaliação do Método de Detecção .....                                  | 82         |
| 3.2.3 Abordagem para a Restauração dos Pixels de Sombras .....                 | 83         |
| 3.2.3.1 Determinação da Prioridade de Preenchimento .....                      | 85         |
| 3.2.3.2 Amostragem Dinâmica Local e Alocação de Blocos .....                   | 86         |
| <b>4. EXPERIMENTOS, RESULTADOS E AVALIAÇÃO .....</b>                           | <b>89</b>  |
| <b>4.1 Pré-processamento.....</b>                                              | <b>89</b>  |
| <b>4.2 Desempenho do Método de Detecção .....</b>                              | <b>93</b>  |
| 4.2.1 Análise Comparativa da Detecção .....                                    | 100        |
| <b>4.3 Experimentos do Método de Restauração Proposto.....</b>                 | <b>104</b> |
| 4.3.1 Experimento 1 – Reconstrução Semi-automática Guiada por Máscara Manual . | 104        |
| 4.3.2 Experimento 2 – Reconstrução Automática das Imagens WV-2 e PL-1B .....   | 107        |
| 4.3.2.1 Comparação com as Técnicas de Transformação de Intensidades .....      | 113        |
| 4.3.2.2 Avaliação dos Resultados da Restauração .....                          | 116        |
| <b>5. CONCLUSÕES E RECOMENDAÇÕES .....</b>                                     | <b>123</b> |
| <b>REFERÊNCIAS .....</b>                                                       | <b>127</b> |

## 1. INTRODUÇÃO

### 1.1 Caracterização do Problema

Os dados fornecidos por Sensoriamento Remoto (SR), como as imagens de satélites, têm ganhado notoriedade nos últimos anos, devido à capacidade deles em fornecer detalhes e informações sobre a superfície terrestre. A preocupação atual com as mudanças climáticas e seus efeitos é um dentre os muitos motivos que levaram ao aumento no interesse nesses dados. Na prática, a obtenção de imagens de satélites contribui para o entendimento de muitos fenômenos que ocorrem na Terra e até mesmo, em outros planetas. Isto reflete diretamente em melhorias e no desenvolvimento de novos sensores, como vem acontecendo de maneira acelerada nos últimos anos. Desde que as primeiras imagens para o monitoramento da Terra foram obtidas do espaço, a melhoria na resolução espacial passou de 80 metros para 35 centímetros, e tem sido a característica com maior destaque na evolução dos sensores ópticos orbitais (JACOBSEN, 2005; TOTH e JÓZKÓW, 2016).

A combinação da resolução espacial com a periodicidade (resolução temporal) dos dados fornecidos por esses sensores, tem sido suficiente para que sejam utilizados no gerenciamento das atividades humanas e em estudos sobre a organização espacial das cidades (WANG et al., 2018). Contudo, ao mesmo tempo que as imagens de alta resolução espacial permitiram distinguir objetos relativamente pequenos, elas também introduziram novos desafios, tanto no processamento, quanto na tarefa de analisá-las. Técnicas de classificação tradicionais na literatura, tiveram sua eficácia comprometida frente ao aumento da variação intraclasse introduzida pelo detalhamento das feições urbanas. O aumento na quantidade de informação discernível acarretou em muitos resultados indesejados, como a grande quantidade de sombras formadas pelo bloqueio da iluminação por feições presentes na superfície (ADELINE et al., 2013).

Por ser um elemento inerente às imagens e que ocorre de maneira natural no processo de aquisição das mesmas, o interesse no reconhecimento de sombras está presente na literatura há mais de três décadas. O trabalho pioneiro de Irvin e McKeown (1989), por exemplo, propôs a determinação da altura e da estrutura de edifícios, por meio do reconhecimento de suas sombras. No entanto, mais recentemente, as sombras são vistas como um obstáculo, que se ignoradas, resultam em abordagens com distorções radiométricas e erros na estimação das propriedades dos alvos (ADELINE et al., 2013). Dependendo de fatores como a época do ano, horário de aquisição e posição geográfica, as sombras podem chegar a ocupar cerca de 30 a 35% da área útil da imagem (MOVIA et al., 2016). O resultado é a redução, ou

em alguns casos, total omissão de informações da superfície (DARE, 2005), cujos efeitos prejudicam diretamente técnicas de Processamento Digital de Imagens (PDI), métodos de visão computacional, de reconhecimento de padrões e na extração automática de feições como rodovias (LI et al., 2016), edifícios (OK, 2013) e veículos (ASAIDI, 2014).

A identificação e remoção dos efeitos das sombras tornou-se, portanto, uma etapa fundamental de pré-processamento em aplicações com imagens obtidas por câmaras terrestres convencionais (XU et al., 2006), por imagens de sequência de vídeo (SANIN et al., 2012; AL-NAJDAWI et al., 2012), imagens aéreas (ADELINE et al., 2013) e imagens orbitais (DARE, 2005; SONG e ZHANG, 2015). Para a remoção dos efeitos ocasionados pelas sombras, é preciso primeiramente identificar onde essas áreas ocorrem na imagem, por meio da sua detecção. Devido ao grande número de situações em que há a interferência direta das sombras nas imagens, muitas são as abordagens propostas na literatura para detectá-las. Alguns trabalhos utilizam dados 3D e informações a priori sobre a fonte de iluminação na modelagem, para a obtenção da posição das sombras. Contudo, a disponibilidade desses dados, o custo de obtenção (como no caso de dados LiDAR) e a dependência da qualidade dos mesmos é um fator limitante na sua aplicação (WANG et al., 2018).

Por outro lado, existem métodos que são baseados apenas em características espectrais para identificar áreas de sombras. A principal evidência fornecida por sombras em qualquer tipo de imagem é a redução drástica da radiância registrada entre regiões da imagem em relação aos seus vizinhos, ao longo de todo espectro eletromagnético (ADELINE et al., 2013; AL-NAJDAWI et al., 2012). Muitas técnicas que exploram este fato já foram propostas, no entanto, todas falham ou possuem algum tipo de ressalva quando consideram apenas o padrão de resposta na detecção. Essa limitação ocorre principalmente na análise de cenas orbitais complexas, como imagens de alta resolução espacial sobre áreas densamente povoadas, que possuem muitas feições com respostas espectrais similares as das sombras (como o asfalto de algumas rodovias e telhados que absorvem energia), ou seja, com baixo padrão de resposta e são erroneamente confundidas com sombras. Além disso, há uma limitação entre a acurácia da detecção e a automatização do método (ADELINE et al., 2013).

Ao que concerne à remoção dos efeitos de sombras, poucas abordagens são encontradas em virtude da complexidade da tarefa. Em geral, técnicas de transformação de intensidades são utilizadas no intuito de melhorar o sinal registrado em áreas de sombras. A premissa considerada é de que mesmo baixa, a reflectância registrada em áreas de sombras possuem informações úteis a respeito dos alvos devido às contribuições da atmosfera, de alvos vizinhos e pelo aumento do intervalo dinâmico dos atuais sensores, como QuickBird,

Worldview, Pléiades, tornando a tarefa de recuperação da área de sombra possível (LIU e YAMAZAKI, 2012). No entanto, as metodologias propostas ainda falham na tarefa de melhoria da visualização da informação sob efeitos de sombras, principalmente pela falta de tratamento de sombras em aplicações como a de mapeamento do uso e cobertura da terra de áreas urbanas e classificação de imagens. Em geral, nestes casos as áreas que contém sombras são desconsideradas do processo de classificação, ou simplesmente, são classificadas como sombras, apesar de não serem feições naturais da superfície. A rotulação de sombras como uma das classes evidencia que os alvos oclusos não foram considerados no mapeamento temático, reduzindo a veracidade e qualidade deste processo (ZHOU et al., 2009).

Assim, dada a dificuldade e a sua grande relevância teórica, a literatura ainda é carente de métodos robustos na identificação e remoção automática de sombras em imagens de satélites com alta resolução espacial (TIAN et al., 2016; WANG et al., 2018; SILVA et al., 2018). Neste contexto, esta pesquisa tem como principal objetivo a proposição de uma abordagem que promova automaticamente, a detecção e a restauração de áreas de sombras presentes em imagens de satélites adquiridas sobre áreas urbanas densas. No método proposto para a detecção de sombras, foram explorados o uso combinado das características espectrais, baseadas no processo físico de formação das sombras nas imagens, e de características contextuais, por meio de operadores morfológicos. A máscara binária resultante do processo de detecção é utilizada como guia para a restauração dos pixels sob efeito de sombras no método proposto de inpainting automático. A abordagem de restauração tem como intuito, a utilização de informações e características somente locais, não impondo limitações como a necessidade de outras fontes de dados de entrada, sem ser a própria imagem, de maneira a potencializar seu uso em processos subsequentes e contribuir como uma etapa de pré-processamento para várias aplicações, como a classificação e segmentação de imagens de satélites.

## **1.2 Hipótese e Objetivos**

O objetivo principal deste trabalho é desenvolver um método automático para remover os efeitos de áreas sombreadas em imagens multiespectrais orbitais com alta resolução espacial, com foco em áreas urbanas densas. A abordagem se baseia na hipótese de que é possível identificar e remover os efeitos de sombras automaticamente, por meio das propriedades radiométricas e informações de contexto que elas apresentam e, que se encontram disponíveis nas imagens multiespectrais de alta resolução espacial sobre áreas urbanas

complexas. Tendo em vista a hipótese apresentada, os seguintes objetivos específicos foram estabelecidos e desenvolvidos nesta tese:

- Estudar e desenvolver uma metodologia para a detecção automática de sombras por meio das informações disponíveis em imagens multiespectrais;
- Testar e avaliar diferentes técnicas de fusão de imagens para geração de bandas multiespectrais de alta resolução espacial;
- Estudar, testar e avaliar a contribuição de diferentes combinações de índices espectrais para o aumento na discriminação de sombras;
- Avaliar a qualidade da detecção de sombras;
- Estudar, testar e adaptar um método híbrido para o inpainting de imagens de satélites, visando a restauração automática da imagem contendo sombras;
- Estudar, implementar e avaliar as principais técnicas de transformação de intensidades para a compensação de áreas sombreadas;
- Comparar os resultados obtidos pelo inpainting e pelas técnicas de transformação de intensidades implementadas;
- Desenvolver uma abordagem que incorpore as etapas de detecção e restauração de maneira automática;

### 1.3 Trabalhos Relacionados e Potencial de Contribuição

As sombras são elementos inerentes às imagens, que ocorrem devido ao bloqueio direto da fonte de iluminação. A maioria dos métodos de detecção de sombras, utilizam o baixo valor de intensidade dos pixels, como premissa básica para a detecção das sombras. Contudo, existem algumas hipóteses levantadas que se aplicam à um domínio ou ambiente específico, e passam a não ser diretamente aplicáveis em outras situações (SANIN et al., 2012). Em aplicações com imagens aéreas ou orbitais, hipóteses são levantadas em função das propriedades que as sombras detêm em espaço de cores invariantes devido às contribuições da atmosfera (POLIDORO et al., 2003; TSAI, 2006). Atrelado a isso, não existe na literatura, até o momento, um método único para detecção de sombras e que seja robusto para imagens adquiridas em qualquer tipo de plataforma ou diferentes aplicações (ADELINE et al., 2013).

Tradicionalmente, devido às informações que são utilizadas, os métodos de detecção de sombras são separados em métodos baseados em modelos e métodos baseados em propriedades. Adeline et al. (2013), posteriormente, incluiu mais duas categorias: os métodos baseados em propriedades físicas e os métodos baseados em aprendizado de máquina.

Os métodos baseados em modelos são métodos geométricos que permitem projetar a posição em que as sombras ocorrem na imagem, com base no conhecimento da posição da fonte de iluminação e dos elementos que compõem a superfície. A localização das áreas de sombras é então resolvida matematicamente, utilizando para isto, modelos tridimensionais da cena, por exemplo, modelos digitais de terreno (MDT) e de superfície (MDS), e informações sobre a posição solar (ângulo de elevação e azimuth solar) no instante de aquisição da imagem. Em trabalhos como Nakajima et al. (2002), Li et al. (2004), Zhan et al. (2005) e Fazan e Dal Poz (2008) são utilizados dados de varredura a laser para a geração do MDT/MDS, que quando combinados com os ângulos de iluminação, realizam a projeção das sombras, as quais são analisadas conforme sua visibilidade na imagem fornecidas pelas informações de altura disponíveis no MDS.

Apesar de fornecer a posição das sombras de maneira precisa pela resolução matemática de modelos projetivos, a aplicação dos métodos baseados em modelos se limita à disponibilidade das informações e dos dados necessários para alimentar os modelos. Além disso, a acurácia do resultado depende diretamente da qualidade dos dados empregados, o que muitas vezes é um obstáculo em aplicações práticas da área. Dentre os problemas reportados pela literatura, encontra-se a sensibilidade dos métodos em relação à diferença entre a resolução do MDS e do elemento de resolução espacial da imagem (GSD – *Ground Sample Distance*). Em áreas urbanas densas com alta heterogeneidade de materiais, diferentemente das imagens de alta resolução espacial, os modelos tridimensionais acabam não conseguindo representar de maneira fiel a variabilidade da cena. Mesmo que se realize uma reamostragem do modelo de elevação para aumentar a resolução e compatibilizá-lo com a imagem, o processo de interpolação pode suavizar certos detalhes e a acurácia dos resultados fica comprometida (SALVADOR et al., 2004; ADELINE et al., 2013).

Nos métodos baseados em propriedades, nenhuma informação a priori ou dado de entrada é necessário, já que as hipóteses levantadas pelos métodos são baseadas em informações que as sombras fornecem na imagem. A principal característica utilizada é o baixo valor de intensidade que as sombras possuem na imagem. A partir dessa premissa, supondo-se que haja uma separação bem definida entre sombras e os demais alvos no histograma da imagem, alguns trabalhos como Dare (2005), Chen et al., (2007), Yamazaki et al. (2009) utilizam-se do método de limiarização de histograma para detectar as sombras. No entanto, a seleção do melhor limiar acaba não sendo trivial, devido à variabilidade de classes presentes na imagem, que produzem histogramas com formatos diferentes. Assim, apesar de ser uma maneira simples de obter a segmentação das sombras, o método de limiarização apresenta problemas de falsas detecções de

alvos, que mesmo sob condições normais de iluminação, possuem baixa resposta espectral. Etapas adicionais foram propostas a fim de corrigir esse tipo de problema, como o uso de informações de textura, bordas e a combinação de canais diferentes (ARÉVALO et al., 2008).

Outra característica é o fato das sombras realçarem os efeitos do espalhamento atmosférico de Rayleigh em sua resposta, o qual satura as regiões sombreadas no azul e com baixo valor de intensidade. Ao observar este efeito físico, Polidoro et al. (2003) realizaram a diferença pixel a pixel entre a componente intensidade (I) e saturação (S) para a segmentação de sombras em imagens aéreas e orbitais. Melhorando os índices de Polidoro et al. (2003), Tsai (2006) propôs a detecção de sombras por uma razão espectral entre as componentes *hue* e intensidade em diferentes modelos de cores. Chung et al. (2009) adicionaram uma função exponencial à razão espectral proposta por Tsai (2006), aliada à uma sequência de limiares para refinar as áreas de sombras detectadas, proporcionando um aumento na separação das áreas de interesse dos demais alvos da imagem. Os resultados mostraram melhorias nos índices de detecção quando comparado aos trabalhos de Tsai (2006) e Huang et al. (2004). Arévalo et al. (2008) propuseram a segmentação das sombras baseada também nas propriedades de modelos de cores invariantes, por meio do algoritmo de crescimento por regiões e observando, principalmente, a componente  $c_3$  do espaço de cor  $c_1c_2c_3$  (GEVERS e SMEULDERS, 1999).

Movia et al. (2016) também propuseram uma abordagem para segmentar sombras baseada em características disponíveis no espaço de cores  $c_1c_2c_3$  e RGB. O método foi uma adaptação do método proposto por Duan et al. (2013), e contou com uma etapa inicial de pré-identificação de candidatos à pixel de sombras no índice de corpo d'água calculado (WBI-*Water Body Index*). Em seguida, sombras foram identificadas com base em requisitos impostos da análise conjunta das estatísticas da primeira componente principal (PC1), calculada a partir das imagens no espaço de cores RGB, e na componente  $c_3$  sobre os pixels pré-selecionados pelo WBI.

Azevedo (2014) explorou o baixo padrão de respostas das sombras por meio da filtragem morfológica top-hat por fechamento de área para realçar padrões escuros da imagem, realizando a detecção das sombras em imagens pancromáticas com alta resolução espacial. No entanto, trata-se de um método semi-automático, uma vez que tem a necessidade da definição do parâmetro de área como entrada para a detecção, o qual foi definido de maneira empírica a partir de testes realizados. Recentemente, Silva et al. (2018) utilizaram da razão espectral entre os canais L (luminosidade) e *hue* no modelo de cores CIELCh, seguido da aplicação multinível do método de Otsu (1979) e operadores morfológicos para detectar as sombras em imagens aéreas RGB. Embora tenham mostrado melhores resultados na discriminação de sombras ao

utilizarem o espaço CIELCh do que o método de Tsai (2006), a detecção de alvos com comportamento espectral semelhantes às sombras ainda persiste, evidenciados pela alta taxa de falsos positivos.

Técnicas baseadas em aprendizado de máquina também têm sido utilizadas para a detecção de sombras (LEVINE e BHATTACHARYYA, 2005). No entanto, esses métodos requerem dados de treinamento para o algoritmo, que nem sempre estão prontamente disponíveis e muitas vezes necessitam da intervenção manual para isto. Além disso, possuem um alto custo computacional e são cena-dependentes, ou seja, uma vez que o algoritmo é treinado sobre uma imagem, dificilmente irá gerar bons resultados em outro conjunto de dados (ADELINE et al., 2013).

A proposição de uma metodologia que se utiliza das informações contidas apenas na imagem de entrada, garante que não haja restrição para o domínio de aplicação. Além disso, a busca de métodos automáticos e com baixo custo computacional visa contribuir com muitas aplicações que necessitem da remoção de sombras, pois se houvesse a necessidade de outros tipos de dados, como dados 3D por exemplo, estes implicariam na limitação da abordagem por outros métodos.

Uma vez detectadas, o próximo passo para os métodos que visam tratar os efeitos degenerativos das sombras, consiste na restauração/reconstrução da imagem, em particular das áreas sombreadas. Utilizadas aqui como sinônimos, a restauração/reconstrução de imagens tem despertado o interesse de pesquisadores da área de processamento de imagens, devido às diversas aplicações nas quais são capazes de resolver. No âmbito do SR óptico, o tópico de restauração/reconstrução tem sido um tema recorrente, devido aos inúmeros problemas que ocorrem no processo de aquisição da imagem, como a oclusão por nuvens e sombras. Uma abordagem que tem sido frequentemente observada na literatura, é a utilização de dados de referências em substituição às partes da imagem corrompida por nuvens ou sombras. Informações espectrais disponíveis em outras bandas não contaminadas (LI et al., 2015), ou adquiridas em diferentes épocas como as imagens multitemporais (LIN et al., 2014), têm sido uma solução comumente adotada na reconstrução de imagens de satélites. Nesses tipos de abordagens, os métodos baseiam-se na correlação existente entre as bandas, como no primeiro caso, e também na suposição de que não há mudanças significativas da cobertura da Terra em um curto período de tempo entre a aquisição das imagens (a corrompida e a de referência), como no caso da segunda abordagem.

Embora a reconstrução de imagens pela extração de informações complementares tenha apresentado bons resultados, nem sempre imagens multiespectrais e multitemporais da

mesma área estão totalmente disponíveis, limitando sua aplicação em experimentos com dados reais (LI et al., 2015). No contexto de imagens com alta resolução espacial, esta preocupação se torna ainda maior, devido à aquisição comercial no qual a maioria dos dados está condicionado, que muitas vezes pode limitar sua amplitude de aplicação, além de menor disponibilidade em escala multitemporal do que quando comparados, por exemplo, ao sistema Landsat, com mais de 40 anos na observação terrestre.

Os métodos que não necessitam de informações complementares, chamados de métodos baseados em correlações espaciais, utilizam no processo de restauração as informações disponíveis nas partes remanescentes da imagem que não sofreram nenhum tipo de dano. Para isto, informações locais e não-locais disponíveis nas imagens são utilizadas para corrigir os efeitos indesejados. Trata-se dos métodos mais tradicionais de reconstrução de imagens, os quais consideram que os dados faltantes ou corrompidos e as demais partes das imagens, compartilham das mesmas propriedades estatísticas e geométricas (SHEN et al., 2015).

Para a restauração de sombras a partir dos métodos baseados em correlações espaciais, duas vertentes são encontradas na literatura. A primeira utiliza técnicas de transformação de intensidades visando a melhoria radiométrica nas áreas afetadas por sombras, por meio de realces ou manipulação de histogramas. Nesse sentido, métodos como correção *gamma* (GC – *Gamma Correction*) (NAKAJIMA et al., 2003; SARABANDI et al., 2004), especificação de histograma (HM - *Histogram Matching*) (TSAI et al., 2006) e correlação linear (LC – *Linear Correlation*) (SARABANDI et al., 2004; CHEN et al., 2007) são tradicionais na literatura para corrigir sombras de áreas urbanas. Mais recentemente, outro método de correlação linear por decomposição de Cholesky também foi utilizada na compensação de sombras (LORENZI et al., 2012). Em geral, as técnicas baseadas na transformação de intensidades não proporcionam um aumento da visibilidade das feições encobertas por sombras. Apesar da baixa demanda computacional, esses métodos deixam a desejar ao considerar futuras aplicações que envolvem a utilização de imagens sem sombras. No entanto, pelo fato dos métodos proporem a melhoria da informação já existente na imagem, supondo que as respostas dos objetos sob sombras são passíveis de serem recuperadas, nenhuma informação é criada ou inserida, eliminando qualquer tipo de inserção de erros no processo de restauração, mas que ainda compromete a qualidade visual da imagem.

Na outra frente de abordagem estão os métodos que buscam completar as informações corrompidas pela presença de sombras. Diferentemente das técnicas de transformações de intensidades, estas técnicas, também conhecidas com técnicas de preenchimento (*fill-in*), não consideram a existência de informações nas áreas de sombras.

Neste sentido, abordagens como o inpainting de imagens têm se mostrado eficiente no preenchimento de informações faltantes ou corrompidas, por meio da propagação de informações da vizinhança para preencher as partes corrompidas. Existem poucas abordagens que utilizam o inpainting na restauração de imagens de SR, sendo a maioria dos trabalhos voltados para reconstrução de nuvens e sombras de nuvens. Maalouf et al. (2009), por exemplo, propuseram o uso da transformada *Bandelet*, com o objetivo de melhor representar o fluxo geométrico das estruturas, facilitando o preenchimento e assim realizar a reconstrução de imagens contaminadas por nuvens. Cheng et al. (2014) propuseram um modelo de inpainting não-local baseado no princípio da variação total (TV – *Total Variation*) com o uso de múltiplas bandas. Os experimentos realizados sobre imagens de SR mostraram que o método conseguiu recuperar com fidelidade espectral, linhas de pixels faltantes, faixa de pedestres, e remover toponímias de mapas digitais. No entanto, quando submetido a imagens texturizadas e com feições de superfície complexas, o algoritmo apresentou suavização excessiva nas regiões recuperadas. Lorenzi et al. (2011) propôs três estratégias apoiadas no inpainting de imagens para reconstruir dados faltantes em imagens orbitais de alta resolução espacial, como IKONOS e QuickBird. As estratégias utilizadas visam tornar robusta a busca de blocos similares à região a ser recuperada, incluindo critérios sobre propriedades da imagem como a variância local, transformações isométricas e estratégia de processamento multiresolução. O método é um dos pioneiros a lidar com o inpainting de imagens com alta resolução espacial aplicados a alvos urbanos (não sombras), no entanto, se mostra sensível ao tamanho da área a ser reconstruída, chegando a obter grandes erros de propagação da informação à medida que o domínio de inpainting aumenta. Além disso, a busca de blocos em diferentes resoluções da imagem aumenta a demanda computacional do método. Estratégias de buscas locais de blocos, assim como reconstrução de grandes áreas de sombras em áreas urbanas, praticamente inexistem na literatura. Além disso, faltam estudos das implicações da propagação de informação por inpainting em áreas de sombras de imagens de SR, assim como da avaliação espectral da reconstrução, já que na maioria dos métodos espaciais, dados de referência não estão disponíveis.

Neste sentido, o presente trabalho aborda os principais desafios na reconstrução de imagens urbanas de alta resolução espacial, que é a presença maciça de sombras, as quais ocupam grande parte das imagens e limitam seu uso efetivo. A contribuição da pesquisa reside no desenvolvimento de alternativas que promovem a recuperação da informação, independentemente do tamanho e localização das sombras, de modo a obter uma restauração mais fiel com a superfície. Dessa forma, a detecção e restauração de áreas de sombras de

maneira automática é um tema relevante e de interesse atual, o qual poderá contribuir para subseqüentes aplicações de classificação do uso e cobertura do solo, segmentação, extração e reconhecimento automático de objetos, obtenção de índices espectrais, reconstrução tridimensional entre outros (DARE, 2005; LORENZI et al., 2012; ADELINE et al., 2013, WANG et al., 2018).

#### **1.4 Estrutura da Tese**

Os tópicos abordados nesta Tese estão dispostos em cinco capítulos. No primeiro capítulo, foi apresentado a natureza do problema de estudo e sua contextualização frente aos principais métodos de detecção e remoção de sombras propostos na literatura, assim como elucida os objetivos e as contribuições do trabalho. No Capítulo 2 são apresentados os principais fundamentos teóricos necessários para o entendimento da abordagem. Os materiais e o método proposto são descritos no Capítulo 3. No Capítulo 4 são apresentados os experimentos e resultados obtidos, juntamente com as discussões envolvidas em cada etapa. Por fim, o Capítulo 5 apresenta uma síntese do trabalho e sua contribuição, bem como as conclusões e recomendações para trabalhos futuros.

## 2. FUNDAMENTAÇÃO TEÓRICA

### 2.1 Sensoriamento Remoto do Ambiente Urbano

As tecnologias que permitem observar o espaço-objeto a distância, sem que haja um contato físico entre o sensor e o objeto, referem-se ao chamado Sensoriamento Remoto (SR) (NOVO, 2010). O termo espaço objeto em SR é amplo, e inclui todos os tipos de objetos dos quais se pretende extrair alguma informação. Neste trabalho, o estudo restringe-se à observação da superfície terrestre, mais especificamente ambiente urbano, onde se encontra a organização espacial da cidade (CORRÊA, 2002). O estudo e análise de áreas urbanas representam um dos maiores desafios em SR, pois são compostas por um conjunto diversificado de materiais (vegetação, grama, concreto, asfalto, telhados, água, solo, etc.), cuja discriminação envolve tarefas complexas quando comparado aos ambientes naturais (HEROLD et al., 2003a).

Em SR, os sistemas sensores imageadores, independentemente do nível de aquisição, são os instrumentos responsáveis por registrar a radiação eletromagnética (REM), resultante da interação com os objetos da superfície, e convertê-la em um sinal digital (NOVO, 2010). A partir da análise dessas imagens, é possível obter informações sobre feições imageadas pelo sensor. As fotografias aéreas são as fontes de dados de SR pioneiras em estudos voltados ao mapeamento do uso e cobertura da terra. Embora elas continuem sendo importantes na análise urbana, devido à sua alta resolução e cobertura flexível, os recentes desenvolvimentos incorporados aos sensores orbitais têm alcançado resoluções competitivas e compatíveis com o mapeamento urbano (SCHOWENGERDT, 2007).

O primeiro satélite para observação e estudo da Terra foi o ERTS-1, posteriormente renomeado para Landsat 1, lançado pelos Estados Unidos há mais de 40 anos. Muitos países, desde então, despertaram o interesse sobre a potencialidade em obter características geográficas das diversas regiões terrestres a partir do espaço, sendo atualmente mais de 30 países com essa capacidade (MENESES e ALMEIDA, 2012; BELWARD e SKØIEN, 2014). Entretanto, até o fim da década de 1990, as imagens disponíveis não possuíam resolução espacial suficiente para discriminar os alvos dentro do ambiente intra-urbano.

Com os avanços na tecnologia de construção dos sensores, o progresso introduzido pelas pesquisas espaciais e o desenvolvimento comercial, tornou possível a aquisição de imagens orbitais com alta resolução espacial. O lançamento dos satélites comerciais, IKONOS em 1999 e o QuickBird em 2001, com sensores com resolução espacial da ordem de 1 m, representaram um avanço significativo em relação à resolução espacial dos seus antecessores, que não ultrapassavam 30 m (NOVO, 2010). A principal vantagem dessa nova geração de

sensores orbitais, além do alto nível de detalhe, é a possibilidade de coleta de dados de grandes áreas em pouco tempo, com uma cobertura repetitiva e imagens periódicas de qualquer área do planeta (LORENZZETTI, 2015).

A disponibilidade de sensores e imagens com diferentes características aumentou exponencialmente, sendo que alguns elementos básicos em relação às características específicas de cada sensor os qualificam para determinadas aplicações e devem ser consideradas (NOVO, 2010; TOTH e JÓZKÓW, 2016).

### 2.1.1 Características dos Sensores e Imagens


Existem algumas formas de classificar os sistemas de SR, seja pelo nível de aquisição (terrestre, aéreo e orbital), pelo tipo de dado que produz (imagem, gráficos ou tabelas), ou até mesmo pela fonte de energia que utiliza (passivo ou ativo). Quando se trata do mapeamento de áreas urbanas, a frequência de revisita de um sensor, dada pela sua resolução temporal, deve ser considerada, pois é fundamental para acompanhar a evolução ou mudanças que ocorrem na superfície. Porém, existem algumas características intrínsecas aos sensores, que influenciam a natureza dos dados coletados e a sua finalidade. As principais características das imagens coletadas por sensores óticos, segundo Mather (2004) podem ser resumidas em termos de suas resoluções: espacial, espectral e radiométrica. Muitos são os sistemas que oferecem uma ampla gama desses parâmetros, de modo a atender as necessidades de diferentes usuários desses dados (SCHOWENGERDT, 2007).

A resolução espacial define o nível de detalhe que uma imagem fornece, ou seja, o menor objeto que pode ser discernível na mesma. Ela pode ser compreendida também em termos geométricos, como o tamanho da área vista pelo ângulo do campo de visada instantâneo do sensor (IFOV, do inglês *Instantaneous Field of View*) para uma dada altitude. No terreno, a projeção do IFOV é o chamado elemento de resolução do terreno (GSD, do inglês *Ground Sample Distance*) e também se relaciona com a resolução espacial (NOVO, 2010). Quanto menor o tamanho do IFOV, maior a capacidade do sensor em diferenciar os menores objetos que integram a cena e, portanto, maior a resolução espacial. Áreas com alta variabilidades de tipos de objetos, como as áreas urbanas, exigem uma alta resolução espacial, sendo a característica mais importante nos estudos das feições urbanas, segundo Jensen e Cowen (1999).

A resolução espacial muitas vezes é confundida com o tamanho do pixel. Ambos os termos são equivalentes somente quando a imagem é vista em resolução plena, ou seja, que

nenhum tipo de reamostragem tenha ocorrido no processo de aquisição ou processamento da imagem. Pixel representa uma taxa de amostragem no terreno, que mede o valor da radiância de objetos no espaço geométrico do GSD (MENESES e ALMEIDA, 2012). Uma imagem digital é constituída por uma grade de pixels adquiridos por sensores imageadores. A maioria dos recentes sistemas comerciais presentes em plataformas orbitais, como o do IKONOS, WorldView e Pléiades carregam sensores do tipo varredura linear (*pushbroom*), cuja ilustração é apresentada na Figura 1. Os sensores de varredura linear possuem milhares de elementos detectores (geralmente do tipo CCD)<sup>1</sup> arranjados em linha e dispostos perpendicularmente à direção do movimento da plataforma, que formam a imagem a partir da varredura do terreno (SCHOWENGERDT, 2007; MENESES e ALMEIDA, 2012). Essa tecnologia tem permitido obter imagens com resolução espacial cada vez melhor, pois a aquisição simultânea da imagem, linha a linha, permite um tempo maior para realizar a medida da radiância, resultando em uma melhoria na razão sinal/ruído (MATHER, 2004; RICHARDS, 2012). Além disso, graças ao rápido processo de varredura desse sistema, as condições de iluminação se mantêm constante para toda cena imageada (POLI et al., 2015).

Figura 1 - Sistema de imageamento por varredura linear (*pushbroom*).



Fonte: Adaptado de Meneses e Almeida (2012).


Desde o lançamento do primeiro satélite da série Landsat, as percepções em relação à resolução espacial passaram por mudanças, pois o que era considerado alta resolução na década de 1970, certamente nos dias de hoje, quatro décadas depois, não é mais considerado (BELWARD e SKØIEN, 2015). O cenário atual é de constante desenvolvimento das

---

<sup>1</sup> do inglês *Charge Coupled Devices* - sensores digitais compostos por fotodetectores em estado sólido que captam a energia refletida e as quantificam como imagem (WOLF e DEWITT, 2000).

tecnologias associada aos satélites e aos sistemas sensores, introduzidos principalmente por frentes comerciais. A Figura 2 contextualiza a evolução dos principais satélites de observação terrestre lançados, desde a primeira geração da série Landsat.

Figura 2 - Resolução espacial dos principais satélites de observação terrestre.




Fonte: Adaptado de Persello (2010).

No começo do ano 2000, apenas o satélite Ikonos era capaz de obter imagens com resolução espacial menor que 2 metros. Em 2014, a autorização dada pelo governo dos Estados Unidos à *Digital Globe*, abriu uma nova era para as imagens de alta resolução, pois foi possível comercializar imagens menores de 0.5 metros, que já estavam disponíveis pelos satélites GeoEye-1 e WorldView-2, mas pela restrição imposta eram reamostradas. Oito meses após o anúncio, imagens pancromáticas com resoluções de 31 cm já eram comercializadas pela empresa, adquiridas pelo WorldView3 lançado em agosto de 2013 (BELWARD e SKØIEN, 2015; SATELLITE IMAGING CORPORATION, 2015).

É fato que uma melhor resolução espacial apresente valiosas informações sobre a superfície e aumenta o potencial da extração de informações temáticas detalhadas (cobertura e uso da terra e feições cartográficas). A Figura 3 exemplifica o aumento da resolução espacial das imagens orbitais obtidas por diferentes sensores. Nota-se que com o aumento da resolução espacial de 30 metros para 31 centímetros, mais classes de uso e cobertura do solo são distinguidas e vão sendo mais facilmente identificadas dentre os diversos elementos que compõe a imagem.

Figura 3 - Característica da resolução espacial para diferentes sensores.



Porém, a discriminação de objetos a partir das imagens envolve outros requisitos além da resolução espacial, como o conhecimento das propriedades espectrais dos materiais e a relação delas com as características registradas. Para Richards (2012), a aquisição de imagens simultâneas em diferentes intervalos de comprimentos de ondas do espectro eletromagnético (chamados de bandas ou canais) é a característica mais importante das imagens fornecidas pelo SR. Dessa forma, para o mapeamento de cada objeto presente na imagem, deve-se considerar também a resolução espectral do sistema sensor que adquiriu a imagem.

A resolução espectral é definida como a largura completa da metade do máximo (FWHM) da resposta de um sensor a uma fonte de luz monocromática (JENSEN, 2009). Dessa forma, quanto mais fina for a resolução espectral, mais estreita será a faixa de comprimento de onda para um determinado canal ou banda. Os avanços introduzidos ao SR permitiram o desenvolvimento de sensores capazes de adquirir dados em centenas de bandas ou mais, abrangendo a região do visível e do infravermelho. Os sensores com esta capacidade são conhecidos como sensores hiperespectrais e são ditos de alta resolução espectral (JENSEN, 2009). Segundo Weng et al. (2012), os sensores com alta resolução espectral têm maior potencial para fornecer informações detalhadas sobre a natureza e as propriedades físicas de diferentes materiais presentes na superfície.

Portanto, um sistema de SR ideal deveria possuir alta resolução espectral, adquirindo dados em centenas de bandas e com o mais alto nível de detalhe possível, ou seja, alta resolução espacial (LILLESAND e KIEFER, 2007). Entretanto, existem limitações na prática que impedem a alta sensibilidade por parte dos sensores. De acordo com Schowengerdt (2007), ambas as características estão relacionadas ao equilíbrio entre o nível de sinal/ruído e a dimensão do IFOV, definidos na concepção do sistema sensor. O aumento na resolução espectral requer bandas mais estreitas, o que provoca uma redução na magnitude do sinal recebido e na relação sinal/ruído. Uma maneira de melhorar essa relação é aumentar o IFOV, pois quanto maior for o IFOV, maior o tempo captando a energia radiante dos alvos e mais forte o sinal recebido. Porém, o aumento no tamanho do IFOV diminui a resolução espacial do sensor e deteriora a capacidade da imagem em representar detalhes espaciais mais finos. Outra dificuldade associada ao desenvolvimento de um “super” sensor é devido ao aumento considerável no volume de dados adquiridos, e na capacidade de transmissão por parte dos sistemas. Além disso, no caso dos sensores hiperespectrais, a alta correlação espectral entre as bandas tem criado problemas para o processamento e análise de dados urbanos (HEROLD, 2003b).

Muitos dos sistemas satélites óticos de SR que possuem alta resolução, adquirem dados em poucas bandas, por isso são chamados de multiespectrais, cujos intervalos das bandas geralmente estão limitados às faixas espectrais do visível e do infravermelho. Esses satélites carregam sistemas duais de imageamento com resoluções diferentes. Por exemplo, Ikonos, QuickBird, Pléiades, possuem um módulo de imageamento multiespectral, com quatro bandas (azul, verde, vermelho e infravermelho próximo) e baixa resolução espacial, em torno de 2 a 4 metros; o outro módulo, denominado pancromático (PAN), possui resolução espacial igual ou melhor que 1 metro e é sensível à radiação em um intervalo espectral relativamente amplo (normalmente abrangendo a região do visível e a do infravermelho próximo). A vantagem em estabelecer esses sistemas duais de imageamento é a possibilidade de utilizar os métodos de fusão, para integrar a alta resolução espectral e espacial fornecidas pelas imagens multiespectrais e pancromática, respectivamente.

Uma nova frente de observação foi almejada com o lançamento do WorldView 3 em 2014, terceiro satélite da série WorldView da *Digital Globe*, que permitiu adquirir informações em um número expressivo de bandas para um satélite multiespectral. Contudo, as reais contribuições dessas bandas não foram exploradas até o momento, e ao que diz respeito à resolução espacial, não foram observados grandes avanços, uma vez que as restrições residem nos limites físicos de construção do sensor.

O aumento na capacidade dos sistemas multiespectrais em detectar as variações da intensidade de radiância espectral, denominada resolução radiométrica, também foi um dos progressos observados nas últimas décadas. A resolução radiométrica está associada ao número de níveis de radiância que o detector pode discriminar, cujo processo pode ser chamado de quantização. Quanto maior for o número de níveis de radiância, maior a resolução radiométrica do sensor. Por exemplo, sensores que fornecem imagens com 8 bits de resolução radiométrica, comportam  $2^8$  intensidades diferentes para cada pixel, ou seja, 256 níveis de cinza. As imagens com  $2^1$  intensidades comportam apenas 2 níveis de cinza e são ditas binárias. A maioria dos sistemas comerciais atuais possuem resolução radiométrica de 11 bits, salvo a constelação Pléiades, que conseguem quantizar a radiância em 12 bits, ou seja, em 4096 níveis.

Frente aos desenvolvimentos e a disponibilidade cada vez maior dos dados de SR, muitos são os fatores a serem levados em conta na escolha de um sensor, como o tipo de informação que se deseja obter, a escala do mapeamento, a necessidade de aplicação, a disponibilidade de algoritmos e softwares adequados e os custos envolvidos (NOVO, 2010; WENG, 2012). No que se refere ao mapeamento do ambiente urbano e identificação dos alvos intra-urbanos, estudos como Jensen e Cowen (1999) sugerem que a alta resolução espacial é a característica mais importante a ser considerada. A maior vantagem dessas imagens é a redução de pixels que apresentam mistura espectral, pois quanto menor for o tamanho do IFOV, menor a contribuição de resposta espectral de diferentes materiais em um pixel e maior a quantidade de pixels puros (com um só objeto) (WENG et al., 2012).

Contudo, Herold et al. (2003a) e Herold et al. (2004) apontam que somente com uma alta resolução espectral é possível diferenciar os tipos de objetos do espaço intra-urbano. Isto porque muitos dos alvos presentes nas áreas urbanas possuem materiais similares em sua composição, como o hidrocarboneto, por exemplo, que pode ser encontrado em rodovias asfaltadas e alguns tipos de cobertura de telhados. As aplicações que se preocupam em identificar esses tipos de alvos se tornam ainda mais complexas, devido ao comportamento não-lambertiano<sup>2</sup> da maioria das superfícies dos alvos urbanos, o que dificultaria a tarefa de estabelecer um padrão de resposta que os caracterize e identifique em faixas limitadas do espectro (WENG, 2012).

Dessa forma, o desenvolvimento de algoritmos que combinem alta resolução espacial e espectral possui melhores perspectivas de resultados na extração de informações detalhadas sobre o ambiente urbano. Além disso, segundo Weng (2012), informações

---

<sup>2</sup> A reflexão da REM varia de acordo com o ângulo de iluminação e posição do sensor.

adicionais como textura e contexto são geralmente necessárias a fim de obter sucesso na identificação dos alvos intra-urbanos e na classificação de áreas urbanas.

### 2.1.2 Influências Radiométricas

Existem outros fatores, além das características do sensor, que interferem na qualidade da imagem. Os dados espectrais adquiridos por sensores aéreos ou orbitais podem conter distorções tanto na geometria, quanto na medida dos valores de níveis digitais (NDs) da imagem, chamadas de distorções radiométricas. As distorções radiométricas são causadas, principalmente, por falhas ocorridas nos instrumentos e limitações decorrentes do processo de imageamento. Em geral, segundo Novo (2010) e Richards (2012), o resultado dessas distorções envolve dois tipos de erros nas imagens:

- A distribuição de níveis digitais (ND) na imagem não corresponde à distribuição de radiância da cena imageada;
- A variação relativa do ND num dado pixel, nas diferentes bandas, não corresponde ao comportamento espectral dos alvos na cena;

Os dados adquiridos pelo SR aéreo/orbital são substancialmente degradados pela presença da atmosfera. As distorções referentes a atmosfera estão relacionadas principalmente aos processos de absorção e espalhamento da energia pelos constituintes atmosféricos (oxigênio, gás carbônico, vapor d'água, ozônio, aerossóis, entre outros). Embora o efeito da absorção seja útil no SR hiperespectral para determinar algumas feições, no caso dos sensores multiespectrais é comum os dados serem adquiridos nas chamadas janelas atmosféricas. Contudo, o espalhamento permanece nos dados como efeito aditivo da atmosfera, atenuando a intensidade, a distribuição espectral e a trajetória da radiância registrada pelo sensor. De acordo com Meneses e Almeida (2012), o tipo de espalhamento depende das relações entre o comprimento de onda da radiação e o tamanho das partículas atmosféricas. Dessa forma, a radiância recebida pelo sensor possui a energia refletida não somente pelo alvo, mas também da energia espalhada pela atmosfera que não interagiu com a superfície. Contribuições difusas de alvos vizinhos e múltiplas reflexões podem ainda ocorrer, mas geralmente são de menor importância, porque a magnitude da radiação é reduzida em cada reflexão (SCHOWENGERDT, 2007).

A maioria dos sistemas sensores fornece imagens em ND ou também chamados valores de brilho, convertidos proporcionalmente à intensidade do sinal recebido. Essa conversão é realizada de maneira diferente pelo sensor para cada banda, levando em conta a

resolução radiométrica do sensor. Como consequência, tem-se uma incompatibilidade entre os NDs de diferentes bandas, até mesmo entre as bandas do mesmo sensor, tornando inviável a comparação e análise do comportamento espectral dos alvos. Os métodos que buscam obter correlação com bibliotecas espectrais, assim como comparar várias imagens da mesma região tomadas em diferentes épocas, necessitam converter os NDs em valores físicos, de modo a recuperar os valores da potência registrada (SCHOWENGERDT, 2007).

A grandeza física que permite caracterizar espectralmente os alvos é a reflectância, motivo de interesse devido sua independência da irradiância<sup>3</sup> solar. Contudo, no processo para obter a reflectância, deve-se primeiro converter os NDs em valores de radiância, também chamada de radiância aparente ou radiância no topo da atmosfera (TOA). A solução reside na calibração radiométrica dos dados, que permite transformar os valores de NDs em valores de radiância aparente para cada banda. Um modelo linear com parâmetros de ganho e *offset* é geralmente utilizado na calibração radiométrica dos sensores CCD, conforme apresentado na Equação 1 (SCHOWENGERDT, 2007).

$$L_0(\lambda) = (ND(\lambda) - offset(\lambda)) / G(\lambda) \quad (1)$$

Em que  $L_0(\lambda)$  representa a radiância medida pelo sensor em uma determinada faixa espectral ( $\lambda$ ) convertida pelo sensor para o valor de ND ( $\lambda$ );  $offset(\lambda)$  e  $G(\lambda)$  referem-se aos parâmetros estabelecidos como forma de compensar respectivamente, a corrente escura do detector e a saturação de valores medidos (RICHARDS, 2012). A determinação desses parâmetros é feita no pré-lançamento do sensor e assumidos como constantes. Porém, eles certamente mudam com a influência de uma série de fatores externos, principalmente no caso dos sensores orbitais expostos a altitudes elevadas. A atualização dos coeficientes de calibração pode ser realizada a partir de procedimentos em campo, com o objetivo de determinar os valores de radiância máxima e mínima registradas pelo sensor, por meio de objetos ou superfícies de referência identificadas no terreno. Maiores informações sobre esses procedimentos podem ser obtidas em Ponzoni et al., (2015).

A conversão da imagem para valores  $L_0(\lambda)$  permite que bandas de um mesmo sensor ou de sensores diferentes possam ser comparadas, uma vez que os valores estão na mesma escala e representam valores físicos. Mesmo com a calibração radiométrica dos dados, permanecem as influências das características espectrais da fonte e a interferência da atmosfera

---

<sup>3</sup> Fluxo radiante solar incidente na superfície do terreno por área de superfície, medido em watts por metro quadrado (W/m<sup>2</sup>) (MENESES e ALMEIDA, 2012).

sobre os valores  $L_0(\lambda)$ . A reflectância torna-se então a grandeza física de maior interesse para ser utilizada na avaliação das propriedades espectrais dos objetos, nas diferentes bandas espectrais. Trata-se da razão entre a quantidade de energia radiante que deixa uma unidade de área no terreno (Radiância) pela quantidade de energia incidente naquela área (Irradiância), medida no mesmo instante de tempo (MENESES e ALMEIDA, 2012). Os dados obtidos por sensores aéreos/orbitais e convertidos em valores físicos de  $L_0(\lambda)$  pela Equação 1, podem então ser transformados para reflectância estratosférica ( $\rho_\lambda$ ) no topo da atmosfera (TOA) pela Equação 2 (MILTON, 1987; UPDIKE e COMP, 2010).

$$\rho_\lambda = \frac{\pi \cdot L_0(\lambda) \cdot d^2}{E(\lambda) \cdot \cos \theta} \quad (2)$$

em que  $L_0(\lambda)$  a radiância aparente;  $d$  a distância Sol-Terra em unidades astronômicas;  $E(\lambda)$  a irradiância média do Sol no TOA e  $\theta$  o ângulo zenital solar. Os valores de reflectância no TOA variam de 0 a 1. Com a imagem convertida em reflectância no TOA, também chamada de reflectância aparente, tem-se a correção de variações como a distância Terra-Sol e do efeito cosseno do ângulo solar zenital devido a diferença de tempo entre a aquisição dos dados. Assim, torna-se possível, por exemplo, realizar operações aritméticas entre bandas de um mesmo sensor ou entre bandas de diferentes sensores.

### 2.1.3 Influências da Geometria de Aquisição


O conhecimento sobre o comportamento espectral dos alvos presentes na superfície é a chave para extrair informações dos dados de SR, pois possibilita discriminar diferentes tipos de materiais por meio de suas reflectâncias. Contudo, este comportamento varia amplamente, uma vez que a reflectância de um alvo não é função somente das características inerentes a ele, mas também sofre com influência de muitos fatores externos. Dessa forma, mesmo que cada material da superfície da Terra tenha um comportamento particular nas quantidades da radiação refletida, absorvida e transmitida, somente a análise isolada da curva espectral de determinado alvo não fornece informações sobre ele (MATHER, 2004; NOVO, 2010).

Um dos fatores que influenciam na reflectância dos alvos é a maneira como eles são adquiridos, pois as variações na geometria de aquisição interferem na quantidade de energia captada pelo sensor. Além disso, o comportamento não lambertiano da maioria dos alvos

naturais, aliado ao fato de que grande parte dos sensores ópticos captam a energia refletida sob um ângulo particular de observação, resulta em inúmeros erros nas estimativas da reflectância. Por exemplo, quando se trata da reflectância da vegetação, diferentes geometrias resultam em diferentes quantidades dos valores de reflectância. Maiores valores de reflectância são observados quando o sensor e a fonte de iluminação estão alinhados, pois, o sensor observa a porção mais iluminada dos alvos, caracterizada como região preferencial do retroespalhamento (LIESENBERG, 2005). Nessa configuração pode ainda ocorrer valores máximos de reflectância, chamado de efeito *hot spot*, que altera significativamente valores de brilho em certas regiões da imagem e aparecem extraordinariamente claras.

Portanto, o conhecimento da geometria de aquisição é de suma importância na análise dos dados, pois os valores de reflectância variam em função do ângulo entre a superfície e a iluminação incidente (MENESES e ALMEIDA, 2012). Os principais parâmetros que descrevem a geometria fonte-sensor-alvo são apresentados na Figura 4, onde é possível destacar a geometria de incidência, dada pelos ângulos zenital ( $\theta_F$ ) e azimutal ( $\phi_F$ ) da fonte, e a geometria de visada, representada pelos ângulos zenital ( $\theta_S$ ) e azimutal ( $\phi_S$ ) do sensor (MATHER, 2004). Novo (2010) destaca os principais efeitos das variáveis da geometria sobre os dados de SR. Um desses efeitos é a diminuição da irradiância solar com o aumento de  $\theta_F$ , pois quanto mais perto do horizonte está a fonte, menor será a quantidade de energia incidente sobre a superfície, alterando a reflectância dos objetos devido suas propriedades anisotrópicas (HONKAVAARA et al., 2012).

Figura 4 – Geometria de Aquisição dos dados.



Fonte: Adaptado de Mather (2004).

Os efeitos na mudança da geometria de aquisição sobre os valores tem sido motivo de estudos por diversas aplicações. O estudo realizado por Moura (2012) identificou uma sensibilidade associada à variação de índices espectrais da vegetação, como o EVI (*Enhanced Vegetation Index*) e o NDVI (*Normalized Difference Vegetation Index*), decorrente da mudança no ângulo e na direção de visada, que não estão necessariamente associadas às características físicas ou à atividade fotossintética dos dosséis da vegetação. Essa inconsistência pode resultar em monitoramento não confiável da dinâmica da vegetação e produzir incertezas na estimativa de produtos secundários. As sombras resultantes da configuração geométrica e densidade do dossel também são apontadas pelo autor, como um fator responsável por alterar a resposta dos índices de vegetação. Os efeitos das sombras no dossel serão maiores quanto menor o ângulo de elevação solar, enquanto maiores proporções de sombras de dossel e solos são vistas pelo sensor, há uma diminuição nos valores de reflectância que acabam influenciando em uma estimativa equivocada das propriedades dos objetos e interpretação dos dados.

Os impactos de diferentes ângulos de elevação solar em processos fotogramétricos foram investigados por Honkavaara et al. (2012). Imagens aéreas em diferentes altitudes (2, 3 e 4 km) foram tomadas com elevação solar considerada normal (44-48°) e baixa (25-28°), com o intuito de avaliar o efeito dessa configuração na correspondência de imagens e geração de MDS. Embora os histogramas apresentem similaridades entre as imagens sob diferentes configurações sem haver degradação no desempenho dos métodos, foram encontrados problemas nas respostas espectrais em áreas de sombras e erros aleatórios nas medidas de altitudes nessas áreas. Os produtos gerados a partir destas imagens, como o MDS, também apresentaram problemas de correspondências nas regiões de sombras, introduzindo artefatos que acarretam em erros na análise dos dados.

Dessa forma, as imagens obtidas com ângulo zenital solar ( $\theta_F$ ) alto, possuem maior influência por parte das áreas de sombras e como consequência, qualidade inferior em processos que fazem uso dessas imagens. O problema das sombras tem se tornado cada vez mais frequente com a disponibilidade de imagens com alta resolução espacial. O alto nível de detalhes, principalmente em cenas de áreas urbanas, introduz sombras decorrentes de objetos elevados sobre a superfície, como é o caso de sombras de edifícios, vegetação, pontes e carros.

A ocorrência de efeitos indesejados no ambiente urbano como as sombras, tem representado desafios para procedimentos automáticos e extração de informações, aumentando o interesse atual em técnicas invariantes à presença de sombras, conforme comentado por Honkavaara et al. (2012) e mostrado por Song et al. (2015). As características e ocorrência das

sombras nas imagens devem ser, portanto, entendidas e tratadas como uma etapa necessária do pré-processamento, assim como ocorre com a correção dos efeitos atmosféricos, a fim de remover efeitos indesejáveis e servir como uma fonte confiável para os demais processos que irão fazer uso dessas imagens.

#### 2.1.4 O Problema de Sombras em Imagens

A extração de informações das imagens de SR está condicionada ao entendimento dos efeitos e fatores que interferem na sua análise, pois como visto, o valor da reflectância depende não somente das propriedades espectrais e espaciais dos alvos, mas também das condições atmosféricas, das propriedades do sensor (resoluções), configuração geométrica fonte-sensor-alvo, da densidade e arranjo dos objetos na superfície e da natureza das sombras causadas por estes objetos em função dos ângulos de iluminação e de observação (SCHOWENGERDT, 2007; LIESENBERG, 2005). Mudanças em cada um desses fatores irão influenciar nas propriedades da imagem adquirida, bem como nas características das sombras nas imagens.

As sombras são efeitos formados na imagem devido ao bloqueio direto da fonte de iluminação, e resultam em uma mudança drástica nas condições de iluminação, quando comparado às regiões totalmente iluminadas. Quando há o bloqueio total, tem-se a chamada *umbra*, e a superfície aparece inteiramente escura e ofuscada. A região de transição entre a *umbra* e as áreas que foram iluminadas é chamada de *penumbra*. A ocorrência da penumbra está ligada ao fato da fonte de luz não ser pontual, cujo resultado é a difração dos raios de luz pelo objeto que provocou a oclusão, criando um limite indefinido de transição entre as regiões sombreadas e não sombreadas. O efeito da penumbra é observado, sobretudo em imagens de SR, uma vez que a fonte de luz não pode ser assumida como um ponto no infinito, sendo considerada como uma dificuldade adicional em metodologias de detecção de sombras (FUNK-LEA e STEEDEMAN, 1994; DARE, 2005; ARÉVALO et al., 2008; ADELIN et al., 2013).


A forma como se apresentam nas imagens pode ser usada para separar as sombras em: sombras próprias (do inglês *self shadows*) ou como sombras projetadas (do inglês *cast shadow*). As sombras próprias correspondem ao (s) lado (s) do próprio objeto que promove a oclusão da luz incidente e que não são iluminados. Já as sombras projetadas correspondem à projeção do próprio objeto que promove a oclusão da luz incidente sobre a superfície na qual ele está elevado. Embora seja uma classificação comum adotada por muitos autores, quando se

trata de imagens aéreas ou orbitais a distinção por parte do processamento acaba sendo insignificante (ARÉVALO et al., 2008; ADELINE et al., 2013).

Sombras são elementos inerentes às imagens, cuja ocorrência depende basicamente da configuração da geometria de aquisição e da topografia do terreno, que por sua vez é evidenciada pela presença de sombras. Esse destaque na topografia dada pelas sombras auxilia no processo de fotointerpretação, facilitando a sensação de tridimensionalidade para percepção cognitiva do ser humano (ARÉVALO et al., 2008). A ocorrência de sombras caracteriza também a presença de objetos elevados sobre a superfície que bloqueiam a iluminação, podendo ser utilizada como um elemento de contexto na identificação de edifícios (OK, 2013), por exemplo, além de fornecer informações geométricas a respeito de sua forma e tamanho.

No entanto, a presença de sombras vem se tornando um desafio em análise de imagens devido ao aumento na resolução espacial. O detalhamento de feições intra-urbanas, que não era possível com médias resoluções, atualmente introduz uma série de barreiras para distinguir classes de cobertura do solo. A grande quantidade de elementos elevados sobre a superfície, tais como edifícios, pontes, árvores, entre muitos outros discerníveis em áreas urbanas, introduzem mudanças drásticas de elevação na superfície, que por sua vez são responsáveis pelo bloqueio da fonte de iluminação incidente e ocorrência de uma porção significativa de sombras (WENG, 2012; ADELINE et al., 2013). O resultado é um impacto negativo na exploração das imagens com alta resolução espacial, em função da oclusão e perda de informação em áreas de sombras, como pode ser observado na Figura 5, o que contribui diretamente para reduzir a eficácia de métodos que visam a extração de informações da superfície (LORENZI et al., 2012; ADELINE et al., 2013). Além dessas, existem as sombras ocasionadas por nuvens que afetam a imagem independentemente da sua resolução (SHAHTAHMASSEBI et al., 2013). Para atenuar o efeito das sombras e aumentar as áreas úteis da imagem, o primeiro passo é distingui-las dos demais elementos que compõe a cena, com base no conhecimento de suas características e comportamento nas imagens.

Figura 5 – Exemplo da grande ocorrência de áreas de sombras em função da alta densidade de feições antrópicas sobre imagens com alta resolução espacial.




#### 2.1.4.1 Características Gerais

Em teoria, a falta da energia direta sobre a superfície indica falta de interação com os objetos e por consequência, falta de informações nas áreas afetadas por sombras. Assim, apesar de não ser um alvo de superfície, as respostas que chegam ao sensor (aéreo ou orbital) em relação à região de sombra é devido à contribuição difusa e ao aumento do intervalo dinâmico dos atuais sensores, que coletam informações da superfície, mesmo se elas estiverem oclusas (LIU e YAMAZAKI, 2012). Segundo o estudo mostrado por Adeline et al. (2013), a contribuição da luz difusa pode ser responsável por mais de 70% da radiância do sensor em áreas de sombras, sendo o espalhamento pela atmosfera ou por alvos vizinhos o principal responsável por essa contribuição. A radiância mostrou-se também dependente das propriedades espectrais dos materiais sob as sombras. A Figura 6 ilustra esses efeitos na radiância registrada pelo sensor para um alvo iluminado (A) e para um alvo sob a influência de sombra (B).

Logo, as áreas sombreadas realçam os efeitos atmosféricos que são capturados pelos sensores como se fossem respostas radiométricas dos alvos sombreados. Contribuições de alvos vizinhos e do espalhamento pelo ambiente nessas áreas são dependentes do tipo de material e seu comportamento espectral, chegando a mais de 50% da irradiância em sombras para cenários urbanos utilizados nos experimentos conduzidos por Adeline et al. (2013).

Figura 6 – Diferentes contribuições na radiância medida pelo sensor para um alvo iluminado A e um sombreado B.



Fonte: Adaptado de Adeline et al. (2013).

A principal evidência da presença de sombra em imagens é a redução drástica da radiância registrada entre regiões da imagem, em relação aos seus vizinhos, ao longo de todo espectro eletromagnético. Esse comportamento é único e observado em qualquer que seja o tipo da imagem (ADELINE et al., 2013; AL-NAJDAWI et al., 2012). Consequentemente, tem-se uma influência na radiometria da imagem e perda da qualidade espectral, em função da redução ou total omissão de informação da superfície imageada (DARE, 2005). A detecção dessas regiões de influência é a premissa na remoção dos seus efeitos, e a acurácia do resultado está diretamente ligada à acurácia do processamento da imagem (JIANG et al., 2013).

A existência de espaços de cores invariantes às mudanças nas condições da imagem incluindo, por exemplo, invariância à direção de visada, as superfícies dos objetos, condições de iluminação, tem se mostrado uma propriedade adequada na segmentação de sombras (ARÉVALO et al., 2008). A principal vantagem, segundo Adeline et al. (2013), é a possibilidade de alguns espaços de cores separar a radiância da cromaticidade, como por exemplo os espaços de cores HSI (*hue, saturation, intensity* - matiz, saturação, intensidade), HSV (*hue, saturation, value* - matiz, saturação, valor), RGB (red, green, blue – vermelho, verde, azul) normalizado e  $C_1C_2C_3$  (SALVADOR et al., 2014). Nesses espaços, a cromaticidade (matiz e a saturação) é independente da intensidade e, portanto, não é afetada pela redução de iluminação ocasionada por sombras (GONZALEZ e WOODS, 2010; MENESES e ALMEIDA,

2012). Assim, os índices propostos (Seção 2.2.1) para espaços de cores invariantes à intensidade, consideram que as sombras no processo físico de formação da imagem recebem, principalmente, a contribuição da atmosfera, apresentando alto valor na componente saturação e baixa intensidade.

## **2.2 Processamento Digital de Imagens Orbitais com Alta Resolução Espacial**

A disponibilidade da maioria das imagens em formato digital e o avanço na tecnologia computacional têm facilitado as análises e aumentado o interesse no Processamento Digital de Imagens (PDI), tornando possível a extração de informações de maneira mais ágil (SCHOWENGERDT, 2007).

No âmbito do SR aéreo e orbital, os recursos do PDI são vitais para a extração e análise de informação, devido ao grande volume de dados que integra uma cena e ainda maior em múltiplas bandas espectrais (MENESES e ALMEIDA, 2012). Dessa forma, as abordagens tiveram que lidar não somente com o padrão espectral, mas também com relações espaciais entre os objetos (BLASCHKE et al., 2014). A utilização do conceito objeto parte do princípio que a informação semântica para a interpretação de uma imagem não está presente no pixel, e sim em objetos da imagem e nas relações existentes entre eles (PINHO, 2005). Portanto, quando se lida com alta resolução espacial, em que os objetos da imagem são formados por muitos pixels, as relações entre pixels vizinhos passam ser fontes importante de informação para identificação desses objetos.

No contexto de modelagem das informações espaciais, o Processamento Morfológico de Imagens (PMI) oferece poderosas ferramentas de análise no domínio espacial, com a maioria dos operadores definidos com base em transformações de vizinhança da imagem, amplamente utilizada em tarefas como filtragem, segmentação, comparação de formas, etc. (ĆURIĆ et al., 2014).

### **2.2.1 Processamento Morfológico de Imagens**

O PMI tem sido utilizado em muitos contextos e aplicações como uma ferramenta não linear de processamento de dados baseado nos conceitos da Morfologia Matemática (MM), introduzidos há mais de 50 anos por Matheron e Serra (DOUGHERTY e LOTUFO, 2003). Trata-se de uma teoria para análise da forma e estruturas dos objetos, o que a torna também, uma técnica poderosa na análise de imagens (SOILLE, 2004).

A MM clássica se utiliza de um conjunto completamente conhecido denominado elemento estruturante (EE) para extrair informações, com base na geometria e topologia dos conjuntos desconhecidos da imagem. O EE pode ser considerado como uma máscara completamente definida (origem, forma, orientação e tamanho) que se desloca na imagem realizando transformações que permitem avaliar os conjuntos desconhecidos. As transformações levam em consideração a vizinhança do pixel analisado da imagem de entrada e a conectividade dada pela configuração do EE, cujo resultado é atribuído ao pixel correspondente na imagem de saída. Assim, a conectividade entre os pixels torna-se importante para estabelecer objetos e componentes de regiões em uma imagem (SOILLE, 2004).

Independente da forma de análise das estruturas da imagem, duas transformações fundamentais na MM são a erosão e a dilatação, das quais derivam-se a maioria dos operadores morfológicos. Erosão e dilatação são denotados por  $\varepsilon_b$  e  $\delta_b$ , respectivamente, onde  $b$  refere-se ao EE utilizado na operação. Ambos os operadores fundamentais podem ser definidos para imagens binárias, cujas operações são baseadas na teoria de conjuntos, e para as imagens em tons de cinza, com base na teoria dos reticulados, em que maiores informações podem ser obtidas em Dougherty e Lotufo (2003) e Soille (2004). A definição da erosão e dilatação para uma imagem  $f$  discreta em tons de cinza é dada pelas Equações 3 e 4, respectivamente (SOILLE, 2004).

$$\varepsilon_B(f) = \bigwedge_{b \in B} f_{-b}. \quad (3)$$

$$\delta_B(f) = \bigvee_{b \in B} f_{-b} \quad (4)$$

Na morfologia sobre imagens em tons de cinza, as transformações ocorridas nas imagens levam em consideração os valores de intensidade do pixel mais escuro (mínimo), como pode ser visto em  $\varepsilon_b$  (Equação 3), que considera o *ínfimo*  $\bigwedge$  dos valores do conjunto de pixels sob a influência de  $b$ ; e o valor mais claro (máximo) no caso da  $\delta_b$  (Equação 4) dada pelo *supremo*  $\bigvee$  dos valores do conjunto de pixels sob a influência de  $b$ . A dualidade desses operadores resultam em efeitos opostos sobre as imagens, enquanto a dilatação causa um clareamento e alargamento dos picos (padrões claros) da imagem, a erosão ocasiona um escurecimento e alargamento dos vales (padrões escuros). Mais informações sobre as operações básicas de *ínfimo* e *supremo*, assim como a formalização das relações de ordens estabelecidas para um reticulado completo podem ser encontradas em Facon (1996) e Soille (2004).

Quando aplicadas isoladamente, a erosão e a dilatação são transformações que não evidenciam características das imagens, pelo contrário, a erosão de uma imagem não apenas remove todas as estruturas que não contêm o elemento estruturante, mas também reduz todas às outras (SOILLE, 2004). Contudo, outros operadores morfológicos podem ser construídos a partir da combinação entre os operadores fundamentais.

### 2.2.1.1 Filtros Morfológicos

Os filtros morfológicos são exemplos de operadores não lineares derivados da erosão e dilatação, com a finalidade de remover seletivamente estruturas presentes na imagem, ao mesmo tempo em que preservam outros objetos. Trata-se de operações de vizinhanças, cujo resultado mostra como os objetos da imagem interagem com o EE definido (forma e tamanho). Os filtros morfológicos são definidos como transformações nas imagens que são idempotente e crescente (SOILLE, 2004):

- Uma transformação  $\Psi$  é *idempotente* se ao aplicá-la duas vezes para qualquer imagem, o resultado é equivalente a aplicá-la uma só vez:

$$\Psi \text{ é idempotente} \Leftrightarrow \Psi\Psi = \Psi.$$

- Uma transformação  $\Psi$  crescente é aquela que preserva a relação de ordem entre as imagens, ou seja:

$$\Psi \text{ é crescente} \Leftrightarrow \forall f, g, f \leq g \Rightarrow \Psi(f) \leq \Psi(g).$$

A importância dos filtros morfológicos reside nas propriedades que eles carregam, ou seja, a propriedade de idempotência garante que a perda de informação causada pela filtragem seja controlada e, a propriedade de crescimento preserva as relações de contraste. Além disso, a propriedade de crescimento preserva a relação de ordem das imagens quando são filtradas. A Abertura e o fechamento morfológico são transformações que satisfazem essas propriedades e, portanto, são filtros morfológicos.

### **Abertura e Fechamento**

O princípio da abertura morfológica  $\gamma$  representado pela Equação 5 (SOILLE, 2004), consiste em dilatar a imagem previamente erodida com o mesmo elemento estruturante  $B$ , porém refletido  $\tilde{B}$ . Já no caso do fechamento morfológico  $\phi$  dado pela Equação 6, o princípio é recuperar por meio da erosão, estruturas da imagem que foram previamente dilatadas.

$$\gamma_B(f) = \delta_B[(\varepsilon_B f)] \quad (5)$$

$$\phi_B(f) = \varepsilon_B[\delta_B(f)] \quad (6)$$


Os efeitos duais apresentados pela abertura e pelo fechamento são basicamente a simplificação da imagem de entrada filtrando, respectivamente, os objetos claros e escuros (levando em consideração a região de influência do EE) na cena, enquanto preserva as demais estruturas. As propriedades dos filtros morfológicos favorecem seu uso em imagens com alta resolução espacial e heterogeneidade de objetos, fornecendo uma redução de ruídos ao mesmo tempo em que preserva as características geométricas desses objetos da cena, mostrando-se adequados para várias aplicações do PDI (BENEDIKTSSON et al., 2003; MURA et al., 2008).

Ambos os filtros morfológicos são transformações intrinsecamente orientadas aos objetos da imagem, pois o processamento é focado em um EE com forma e tamanho definido. No entanto, a definição de apenas um EE com forma e tamanho rígido para extrair informações de toda a imagem, pode limitar certas aplicações em que os objetos de interesse se apresentam com variadas estruturas na imagem (forma, tamanho, orientação).

Com o aumento na resolução espacial, a necessidade de EE que analisam as características espaciais e espectrais é evidente e motivo de investigação em muitas aplicações (MURA et al., 2010; BENEDIKTSSON et al., 2011; ČURIĆ et al., 2014). Uma solução que vem mostrando resultados satisfatórios na análise de imagens com alta resolução são os operadores morfológicos que consideram EE adaptativos, também chamados componentes conectados. Um componente conectado X de uma imagem binária, é um conjunto de pixels no qual cada par de pixel é conectado segundo uma regra de conectividade formando um objeto que compartilha das mesmas características morfológicas (PESARESI e BENEDIKTSSON, 2001). Regras de conectividade 4 e 8 são as mais tradicionais e um pixel é dito adjacente a 4 ou oito dos seus pixels vizinhos, respectivamente. Em imagens em tons de cinza, os componentes conectados estabelecem relações de inclusão em cada zona plana da imagem (regiões com o mesmo valor de intensidade), formadas pela decomposição da imagem em limiares. A decomposição em limiares é uma forma hierárquica de representar as regiões da imagem em tons de cinza, onde cada nível (valor de intensidade) define uma seção transversal  $CS_n(f)$  da imagem. A Figura 7 exemplifica numericamente a construção de seções transversais. A imagem  $f$  ilustrada em (a) com altura 4 (níveis) e largura 8 resulta no relevo topográfico mostrado em (b). Assim, a primeira seção transversal  $CS_0(f)$  é formada pelos pixels com intensidades iguais ou maiores à menor intensidade, neste caso 0, contendo todo o domínio da imagem, como pode

ser visto em (c) com  $n=0$ . A próxima seção contém os pixels com intensidades maiores ou iguais a 50, formando os objetos mostrados em (c) com  $n=50$ , supondo uma conectividade de vizinhança-8, e assim sucessivamente. Ao final do processo de decomposição obtêm-se seções transversais com os máximos regionais de  $f$ .

Figura 7 – Exemplo da decomposição em limiares. (a) Imagem  $f$ ; (b) Superfície topográfica de  $f$ ; (c) Zonas planas geradas pela decomposição em  $n$  limiares.



Fonte: Adaptado de Silva (2009).

Esta abordagem permite uma análise mais flexível dos objetos formados em cada seção transversal obtida, assim como facilita operações de filtragem morfológica que consideram medidas/atributos, chamado de filtros morfológicos por atributos. A abertura por área é um exemplo de filtro morfológico por atributo, também chamado por Soille (2004) como abertura algébrica e possui as mesmas propriedades (crescente, idempotente e anti-extensiva) da abertura, mas não pode ser escrita com uma única erosão seguida por uma dilatação. Trata-se de uma ferramenta poderosa para filtrar componentes conectados de acordo com um parâmetro de área, utilizando-se para isso de análise flexível sobre as zonas planas da imagem. Outros tipos de atributos podem ser considerados na análise, com será visto na próxima seção, assim como seu operador dual fechamento por área (MURA et al., 2011).

## 2.2.1.2 Filtragem Morfológica por Atributo

Filtragem por atributo são transformações baseadas em operadores conectados que podem filtrar uma imagem removendo ou incorporando zonas planas, de acordo com um dado critério (atributo). Um critério genérico  $T$  pode ser definido como um mapeamento do conjunto de valores de  $S$  considerados por  $T$  para o par booleano {verdadeiro, falso}. O critério é então verificado em cada seção transversal, preservando os conjuntos conectados que satisfazem  $T$  (BREEN e JONES, 1996). Muitos são os critérios que podem ser utilizados e aplicados, já que permitem considerar uma gama de atributos, como por exemplo, área, perímetro, momentos, fatores de forma, entropia e desvio padrão. O emprego separadamente ou de maneira combinada depende do tipo de objeto e da aplicação. Exemplo da combinação de atributos na identificação e classificação de edifícios é mostrado em Mura et al. (2009).

Um dos operadores da filtragem por atributo é a abertura por área. A abertura por área  $\gamma_\lambda$ , segundo Soille (2004) é equivalente à união (ou supremo) de todas as aberturas com EEs conectados  $B$ , cujo tamanho em número de pixel é igual a  $\lambda$ :

$$\gamma_\lambda = \bigvee_i \{ \gamma_{B_i}(f) \} \quad (7)$$


O resultado da filtragem contém todas regiões conectadas por  $B_i$  que possuem área igual ou maior que  $\lambda$ . Em imagens binárias, o critério de área é avaliado de maneira crescente para toda a imagem, removendo os picos que não satisfazem o critério, ao mesmo tempo em que preserva os demais elementos da cena. A abertura por área é muito utilizada para remover algum tipo de ruído ou objetos conectados irrelevantes, cuja área seja menor que o parâmetro  $\lambda$ . No caso discreto, a área refere-se exclusivamente ao número de pixels. Em imagens em tons de cinza, o critério de área é avaliado de forma crescente em todas as seções transversais da imagem, filtrando os máximos regionais. Vale à pena ressaltar que além da área, outros atributos podem ser considerados na filtragem, cuja vantagem do uso de filtros com componentes conectados é a preservação das formas dos objetos e não inserção de novas bordas no resultado. Além disso, a análise dos componentes conectados para imagens com alta resolução geométrica é uma alternativa viável na extração de informações espaciais, garantindo as propriedades dos filtros morfológicos com menor complexidade computacional (MURA et al., 2009). Por serem operadores duais, o mesmo efeito, porém em relação aos vales da imagem, é encontrado no operador fechamento por área.

O fechamento por área  $\phi_\lambda$ , segundo Soille (2004) é equivalente à intersecção (ou ínfimo) de todos os fechamentos com o elemento estruturante  $B_i$ , cujo tamanho em número de pixel é igual a  $\lambda$ :

$$\phi_\lambda = \bigwedge_i \{ \phi_{B_i}(f) \} \quad (8)$$

O resultado da filtragem remove todas as estruturas escuras conectadas por  $B_i$  menores que  $\lambda$ . Na Figura 8 tem-se um exemplo da filtragem por fechamento de área igual a 50 pixels. Em (b) é possível notar a remoção de áreas conectadas menores que 50 pixels, considerando uma conectividade de vizinhança-8. Embora existam objetos menores que a área estabelecida, eles são considerados conectados com objetos adjacentes, dentro da conectividade estabelecida e a soma das áreas é maior que o limiar.

Figura 8 - Exemplo do fechamento morfológico por área. (a) Imagem original 30x30 pixels; (b) Resultado do fechamento com atributo área  $\lambda=50$ .



Fonte: Adaptado de Mura (2011).

Assim, de acordo com Vincent (1992), na abertura e no fechamento, as áreas dos máximos e mínimos regionais são analisadas, respectivamente, em cada seção transversal da imagem. A análise é feita primeiramente na seção transversal de maior limiar e segue até que as áreas restantes se tornem maior que o parâmetro estipulado. Isso é possível porque as transformações de abertura e fechamento de área são invariantes à decomposição em limiares. Uma transformação é dita invariante a decomposição em limiares se puder ser escrita como a soma das transformações de suas seções transversais, propriedade demonstrada na Equação 9 (SOILLE, 2004).

$$\Psi \text{ é invariante à decomposição em limiares} \Leftrightarrow \Psi = \sum_{t=1}^{k_{\max}} \Psi C S_t \quad (9)$$

Existem diversas formas para utilizar a filtragem por atributos, já que permite considerar vários atributos. Recentemente, tem sido utilizada na criação de perfis morfológicos, em imagens multiespectrais de alta resolução espacial (MURA et al., 2010), e perfis morfológicos estendidos, no caso de imagens hiperespectrais (BENEDIKTSSON et al., 2011). Quando combinada com algum tipo de operação com a imagem original, a filtragem por atributos pode proporcionar a recuperação de informações relevantes, como os padrões escuros, e ao mesmo tempo, eliminar informações irrelevantes e ruídos, como é o caso das combinações da transformação *top-hat* (FACON, 1996).

### 2.2.1.3 Transformação *Top-hat*

A remoção de estruturas irrelevantes por meio dos filtros morfológicos permite a redução da complexidade da cena, fator importante na análise de imagens com alta resolução espacial. Quando combinados com outras operações, a filtragem por atributo pode contribuir para evidenciar alvos de interesse, dentre os demais pertencentes à imagem. A transformação *top-hat*, assim como os filtros clássicos, tem a finalidade de obter estruturas relevantes nas imagens, aqui representada pelos padrões escuros, considerada como uma ferramenta útil na detecção de padrões claros e escuros. O objetivo consiste em recuperar estruturas relevantes das imagens através de operações aritméticas entre a imagem original e a imagem resultante de um processo de fechamento ou de abertura morfológica (SOILLE, 2004). Isto ocorre devido ao fato de que um fechamento ou uma abertura por atributo remove os mínimos e os máximos regionais não pertencentes a conectividade estabelecida. Os “resíduos” removidos podem ser recuperados, por meio da diferença aritmética com a imagem original.

Considerando a principal característica das sombras nas imagens, as quais representam os menores valores de radiância em relação aos seus vizinhos, esses valores podem ser associados aos mínimos regionais. Dessa forma, o fechamento com o atributo área torna-se uma ferramenta de remoção das sombras, levando em conta a área e conectividade estabelecida. Com o *top-hat*, elas podem ser recuperadas e realçadas quando a diferença entre a imagem original e imagem com o resultado do *top-hat* é realizada. Por ser um operador extensivo, o resultado do fechamento é sempre maior do que a imagem original e assim, deve ser subtraído pela imagem original. Portanto, a transformação *top-hat* por fechamento (*BTH*, do inglês *Black Top-Hat*) consiste na diferença entre o fechamento da imagem original  $\phi(f)$  e a imagem original  $f$ , (SOILLE, 2004):

$$BTH(f) = \phi(f) - f \quad (10)$$

As propriedades dos filtros morfológicos considerando um atributo de crescimento como área, garantem seu uso na transformação *top-hat* clássica, assim como estabelecido para operações em imagens binárias e em tons de cinza, além de garantir a propriedade de idempotência, controlando a ocorrência de perdas significativas pela filtragem. Muitas funcionalidades do top-hat podem ser exploradas, como na extração de crateras, ou de pontos em nuvens de pontos laser (LI et al., 2014)

### 2.2.2 Fusão de Imagens

A impossibilidade de obter centenas de bandas com detalhes espaciais mais finos, imposta para manter o equilíbrio entre o nível de sinal/ruído e IFOV, faz com que a maioria dos sistemas sensores orbitais carreguem sistemas duais de imageamento. A técnica conhecida como fusão de imagem é uma alternativa para superar esse desafio e produzir uma imagem multiespectral com alta resolução espacial, por meio da combinação de diferentes imagens, coletadas por diferentes sensores (FONSECA et al., 2011). O resultado é uma imagem com características mais detalhadas e discerníveis, em que ambiguidades de classes são reduzidas, contribuindo para aumentar a capacidade de interpretação da imagem e a confiabilidade de técnicas como a classificação e extração de informações (POHL e GENDEREN, 1998). De acordo com Fonseca et al. (2011), a fusão é importante principalmente em áreas que possuem uma estrutura morfológica complexa, como as áreas urbanas, uma vez que objetos urbanos são determinados não somente por seus espectros, mas também por suas estruturas.

Para que o processo de fusão resulte em uma imagem com boa qualidade, alguns aspectos devem ser considerados, como o registro entre as imagens, de modo que elas possam representar a mesma área de cobertura. Para isto, geralmente toma-se a imagem de maior resolução espacial como referência e a imagem com maior resolução espectral é reamostrada. Caso as imagens tenham sido adquiridas no mesmo instante pelo mesmo sensor e as correções geométricas tenham sido realizadas, o processo de registro entre elas torna-se desnecessário (YUHENDRA et al., 2012). A correlação radiométrica entre as imagens também é um fator importante a fim de evitar possíveis imperfeições e distorções de cores quando o alcance espectral da banda pancromática, principalmente na região do infravermelho, não for compatível com a da multiespectral (SCHOWENGERDT, 2007).

Dentre os vários métodos de fusão de imagens existentes na literatura, alguns grupos foram criados para classificá-los (WANG et al., 2005). Na sequência são descritos dois

métodos de fusão comumente aplicados no SR, por permitir o uso de várias bandas na fusão, e que de acordo com a classificação proposta por Schowengerdt (2007), enquadram-se como técnicas de fusão de imagens no domínio espectral.

#### 2.2.2.1 Componentes Principais

As imagens adquiridas por sensores multiespectrais possuem informações redundantes, isto porque são coletadas em faixas do espectro eletromagnético próximas, onde a maioria dos objetos apresentam respostas espectrais similares. Uma maneira de representar toda a informação coletada, em um menor conjunto de dados não-correlacionados, é através da transformação por componentes principais (CP). As informações coletadas são reorganizadas em novas bandas, chamadas de componentes, onde o valor de nível digital é resultado de uma combinação linear dos dados originais (RICHARDS, 2012). A transformação é feita a partir da matriz de covariância dos dados originais, a qual permite encontrar um novo sistema de coordenadas no espaço multiespectral, onde as variâncias e a direção dos eixos são representadas pelos autovalores e autovetores, respectivamente.

Na transformação por CP não existe uma limitação de bandas de entrada. Embora o número de componentes após a transformação seja igual ao número de bandas originais, a vantagem está no fato da primeira componente ( $CP_1$ ) concentrar todas as informações comuns das bandas de entrada (POHL et al., 1998). As demais componentes carregam as informações espectrais da cena. Contudo, a maioria das informações é explicada pelas primeiras CP, sendo que quanto maior a ordem da componente, menor o conteúdo de informação contida nela. Além disso, uma propriedade fundamental desta transformação, segundo Schowengerdt (2007), é que ela preserva a variância total da imagem original. Dessa forma, a  $CP_1$  que tem a maior variância dos dados pode ser substituída pela banda pancromática, o que permite maximizar o efeito da alta resolução na imagem fusionada (FONSECA et al., 2011).

O método de fusão através de CP pode ser denominado como um método de substituição, uma vez que a primeira componente principal é substituída pela imagem pancromática (SCHOWENGERT, 2007). Neste caso, um ajuste entre a média e a variância da imagem pancromática com a  $CP_1$  também pode ser realizada antes da transformação, para que ambas fiquem o mais próximas possível e evite que distorções nas informações espectrais ocorram (GONZÁLEZ-AUDÍCANÁ et al., 2004). A combinação entre as técnicas espectrais e as do domínio espacial, como mostrado por González-Audícana et al. (2004), tem sido bastante

utilizada e permite obter imagens fusionadas com alto poder de resolução espacial e que ao mesmo tempo, mantém as informações espectrais originais dos dados multiespectrais.

A transformação inversa para o espaço original dos dados resulta em um relacionamento entre diferentes tipos de cobertura da terra que podem ser vistos mais claramente, do que através das bandas espectrais originais. Esta transformação, segundo Novo (2010), pode ser considerada como uma técnica de realce de dados, pois tornam explícitas informações de interesse, sem gerar novos dados. Segundo Mather (2004), esta técnica de estatística multivariada tem mostrado ser particularmente efetiva quando aplicado em imagens temporais para identificar mudanças na superfície. Contudo, a escolha da área representada na imagem deve ser levada em consideração, uma vez que os dados são gerados a partir da matriz de covariância e, a aplicação da transformação em regiões muito homogêneas acaba não evidenciando informações de interesse.

#### 2.2.2.2 Gram-Schmidt

O processo de fusão de imagens utilizando o método Gram-Schmidt (GS) utiliza-se da manipulação sobre vetores com o objetivo de torná-los ortogonais, para obter um novo conjunto de dados não correlacionados, assim como acontece no método por CP. O método de GS também está inserido dentro do grupo de métodos no domínio espectral, e a substituição de componentes também é realizada, a fim de obter uma imagem de melhor poder de resolução espacial e com as informações espectrais originais preservadas (MAURER, 2013).

O primeiro passo do processo consiste na simulação de uma banda pancromática de baixa resolução espacial. Na literatura são apresentadas duas formas para realizar essa simulação. A primeira forma consiste em combinar as informações das bandas multiespectrais em uma única banda PAN de baixa resolução espacial, calculando para isso, pesos apropriados para a contribuição de cada banda no processo de combinação. Na segunda forma de simulação, a banda a PAN de alta resolução é suavizada, sub-amostrada por um fator apropriado e interpolada até atingir a resolução compatível com as demais bandas (LABEN e BROWER, 2000).

A transformação pelo método de GS é então aplicada na banda simulada e nas demais bandas multiespectrais, sendo a banda simulada considerada como primeira banda na transformação. O resultado é um conjunto de bandas não-correlacionadas e ortogonais entre si, sem a presença de informação redundante. A primeira banda resultante da transformação GS é então substituída pela banda pancromática original, após essa ter suas estatísticas combinadas

com a primeira. A aplicação da transformação GS inversa resulta, portanto, em um novo conjunto de bandas multiespectrais com melhor resolução espacial (MAURER, 2013).

Portanto, todas as bandas multiespectrais podem ser utilizadas neste método, assim como no caso do método por CP. Contudo, pode haver problemas de distorções espectrais quando a banda PAN não possuir cobertura total sobre as bandas multiespectrais. O resultado é uma banda simulada que não reflete a resposta espectral das bandas multiespectrais.

### 2.2.2.3 Métricas para Análise da Qualidade da Fusão

Em geral, os resultados da aplicação de diferentes métodos de fusão podem ser avaliados de forma qualitativa, por meio da análise visual, e quantitativamente, através de medidas matemáticas. A avaliação qualitativa, de acordo com Yuhendra et al. (2012), é baseada na comparação visual entre as características espectrais da imagem multiespectral original e uma imagem de referência, que é assumida como sendo ideal. Dentre as características consideradas estão os tons presentes em ambas as imagens, o contraste, a saturação, a textura e os detalhes espaciais, que leva em consideração a análise visual da imagem com maior resolução espacial (FONSECA et al., 2011).

Os métodos qualitativos envolvem uma avaliação subjetiva do resultado, uma vez que na análise visual é feito um julgamento pessoal por parte do intérprete humano, adicionando incertezas ao processo. Isto não ocorre na avaliação quantitativa, já que as métricas levam em consideração indicadores de qualidade que medem a semelhança espectral e espacial entre imagens. Uma dificuldade associada aos métodos de avaliação é a falta de imagens com alta resolução espacial e espectral para serem empregadas como referência na análise dos métodos. Mediante a ausência dessa imagem ideal de referência, a maioria dos trabalhos faz a comparação entre as características espectrais da imagem multiespectral com a imagem fusionada, para avaliação da qualidade espectral, e entre o resultado da fusão e a imagem pancromática para avaliar a qualidade espacial.

Dessa forma, as imagens originais podem ser adotadas como referência na comparação e avaliação dos métodos de fusão. Os principais índices considerados para avaliação do processo de fusão são o CC, RMSE, ERGAS e UIQUI, que serão apresentados na sequência, onde adotou-se nas formulações “ $f$ ” para a imagem fusionada e “ $r$ ” para a imagem de referência.

## a) Coeficiente de Correlação (CC)

O Coeficiente de correlação, calculado conforme a Equação 11, mede a associação linear entre duas variáveis, sendo empregado neste caso, como uma medida de similaridade estatística entre a imagem fusionada e a de referência (AIAZZI et al., 2011).

$$CC = \frac{\sigma_{r,f}}{\sqrt{\sigma_r \sigma_f}} = \frac{\sum_{i=1}^n (x_{r_i} - \bar{x}_r)(x_{f_i} - \bar{x}_f)}{\sqrt{\sum_{i=1}^n (x_{r_i} - \bar{x}_r)^2} \sqrt{\sum_{i=1}^n (x_{f_i} - \bar{x}_f)^2}} \quad (11)$$

Na formulação utiliza-se: a covariância ( $\sigma_{r,f}$ ) entre a i-ésima banda fusionada e a de referência; o desvio-padrão da banda original ( $\sigma_r$ ) e o desvio-padrão da banda fusionada ( $\sigma_f$ ). Trata-se de um índice muito utilizado na literatura, pois permite avaliar, dentre outras várias aplicações, se as imagens resultantes da fusão sofreram ou não alterações significativas em relação as imagens originais. O valor da correlação pode variar de -1 a 1, de modo que um valor próximo a 1 indica que as imagens são altamente correlacionadas.

## b) RMSE

O RMSE (do inglês *Root Mean Squared Error*) mede a fidelidade do resultado da fusão em relação a imagem original, através do cálculo pixel a pixel, das diferenças entre elas. A soma dessas diferenças ao quadrado dividido pelo tamanho da imagem permite encontrar as variações introduzidas pelo processo de fusão. No RMSE, como mostra a Equação 12, a raiz quadrada do erro é calculada e obtém-se a dispersão dessas distorções ocorridas (ALPARONE et al., 2007; YUHENDRA et al., 2012).

$$RMSE = \sqrt{\frac{\sum_{i=1}^M \sum_{j=1}^N (I_F(i, j) - I_R(i, j))^2}{M \times N}} \quad (12)$$

Em que  $I_R(i, j)$  representa o pixel da imagem de referência e  $I_F(i, j)$  o pixel da imagem fusionada;  $M \times N$  é o tamanho da imagem. Valores próximos a 0 indicam alta semelhança entre as imagens e, por conseguinte, quanto menor o valor de RMSE, maior a qualidade espectral da imagem fusionada.

## c) ERGAS

O índice ERGAS (do inglês *Relative Global Dimensional Synthesis Error*) definido pela Equação 13, foi proposto por Wald (2000), e oferece um indicador global de qualidade da imagem resultante da fusão.

$$ERGAS = 100 \frac{h}{l} \sqrt{\frac{1}{N} \sum_{i=1}^n \left( \frac{RMSE_i^2}{\mu_{m_i}^2} \right)} \quad (13)$$

Na formulação,  $h/l$  é a razão entre as resoluções espaciais da imagem pancromática e multiespectral;  $N$  o número de bandas multiespectrais empregadas e  $\mu_{m_i}$  a média da  $i$ -ésima banda envolvida na fusão, além do índice RMSE descrito anteriormente pela Equação 12. Assim como ocorre para o índice RMSE, quanto menor for o valor do índice ERGAS, maior a qualidade espectral e menor a distorção ocasionada pelo método de fusão avaliado.

## d) UIQI

O índice UIQI (do inglês *Universal Image Quality Index*), assim como os demais índices apresentados, representa uma medida de similaridade entre imagens. Contudo, o índice UIQI possui destaque por realizar a modelagem de qualquer distorção da imagem, através da combinação de características locais como a perda de correlação, distorção radiométrica e distorção no contraste. Isto torna o índice independente das condições das imagens de entrada, podendo ser aplicado em várias outras aplicações dentro do PDI. Assim, conforme proposto por Wang e Bovik (2002), o índice UIQI é dado por:

$$UIQI = \frac{\sigma_{r,f}}{\sigma_r \sigma_f} \times \frac{2\mu_r \mu_f}{\mu_r^2 + \mu_f^2} \times \frac{2\sigma_r \sigma_f}{\sigma_r^2 + \sigma_f^2} \quad (14)$$

onde  $\sigma_{r,f}$  é a covariância entre a imagem de referência e a fusionada;  $\sigma_r$  e  $\sigma_f$  são os desvio-padrões de  $r$  e  $f$ , assim como  $\mu_r$  e  $\mu_f$  são as médias de  $r$  e  $f$ , respectivamente. Na formulação, o primeiro termo  $\sigma_{r,f}/\sigma_r \sigma_f$  representa o coeficiente de correlação entre a imagem de referência e a fusionada; o segundo termo mede a proximidade entre as médias das imagens  $r$  e  $f$  e o terceiro termo mede a similaridade do contraste entre elas. As estatísticas pertinentes são calculadas localmente para aumentar a capacidade de discriminação de todos os fatores. O

cálculo é realizado através de uma janela móvel de tamanho  $N \times N$ , sendo a média de todos valores utilizada como um único índice global. O valor do índice UIQI, assim como no caso da correlação, também pode variar de -1 a 1, sendo que o valor ideal UIQI=1 é obtido, se e somente se, ambas as imagens avaliadas forem idênticas para todos os pixels da imagem.

### 2.2.1 Índices Espectrais

Operações entre bandas multiespectrais são amplamente utilizadas no SR para a extração de informações dos alvos presentes na superfície. Trata-se de transformações simples, como razões, somas e diferenças de pixels, em que o alvo de interesse apresenta comportamento antagônico (PONZONI et al., 2012). A identificação dessa relação inversa da reflectância é obtida muitas vezes, a partir das medidas hiperespectrais que fornecem o espectro dos alvos, que por sua vez, são utilizados como base para a geração dos índices (MATHER, 2004). Grande parte dos índices propostos utilizam da razão entre bandas, pela vantagem de reduzir efeitos das variações da topografia e iluminação sobre as imagens, tornando-se apropriados para comparações ao longo do tempo de uma mesma área (RICHARDS, 2012).

Dentre os índices mais conhecidos e utilizados no SR estão os índices de vegetação, que visam correlacionar o comportamento da reflectância da vegetação nas bandas do vermelho e infravermelho, com parâmetros biofísicos da cobertura vegetal, a fim de monitorar o vigor da vegetação, a fenologia da planta e mudanças dos ecossistemas (KE et al., 2015).

Os índices de vegetação exploram principalmente, os efeitos de absorção da reflectância na região do vermelho visível (centrado no comprimento de onda 650 nm) pelos pigmentos fotossintetizantes presentes na cobertura vegetal, e da alta reflectância pelo espalhamento múltiplo pelas folhas no infravermelho próximo, no intervalo entre os comprimentos de ondas 760 nm a 900 nm (JENSEN, 2009). Um dos índices mais tradicionais é o NDVI (do inglês *Normalized Difference Vegetation Index*). O NDVI expressa a normalização da diferença e soma entre as bandas do vermelho ( $R$ ) e infravermelho próximo ( $NIR$ ), conforme mostra a Equação 15, onde a vegetação apresenta seu comportamento dual, utilizado pelo SR para monitorar as mudanças sazonais e interanuais no desenvolvimento e na atividade da vegetação (MENESES e ALMEIDA, 2012).

$$NDVI = \frac{NIR - R}{NIR + R} \quad (15)$$

O resultado é uma imagem no intervalo entre -1 a 1, em que a vegetação representa os maiores valores e alvos terrestre, podem variar entre 0 e 0,8 (PONZONI et al., 2012). Com este padrão, pode-se assumir comportamento bimodal do histograma resultado do NDVI e a limiarização automática garante a separação da vegetação. No entanto, para evitar interpretações equivocadas dos valores dos índices, deve-se observar alguns fatores que afetam o pressuposto do comportamento de reflectância do alvo, como influência do sombreamento, resolução radiométrica do sensor e efeitos atmosféricos.


Os índices espectrais podem ser utilizados na segmentação automática de imagens multiespectrais, uma vez que permitem evidenciar alvos individuais com base nas suas propriedades. Em áreas urbanas esse efeito é benéfico devido à grande quantidade de objetos pertencentes à cena com variados comportamentos de reflectância. Embora existam objetos que se apresentam com similaridade espectral em algumas regiões do espectro, a combinação entre bandas pode favorecer muitas aplicações e diversos índices vêm sendo propostos e explorados na literatura para os mais variados fins. Polidoro (2007) investigou o comportamento dos principais elementos que compõem imagens da paisagem urbana, tais como a vegetação, rodovias, edificações, corpos d'água e sombras, com o objetivo de identificar as melhores combinações entre bandas e índices para separar esses elementos dos demais objetos da cena. Dentre os índices propostos pelo autor, dois índices mostraram resultados adequados para segmentar sombras em imagens multiespectrais e serão apresentados na sequência.

Espaços de cores invariantes às sombras têm sido amplamente utilizados na composição de índices espectrais (ADELINE et al., 2013). Polidoro et al. (2003), por exemplo, destacaram o comportamento das sombras no espaço HSI, onde apresentam altos valores de saturação, ao mesmo tempo que possuem as menores intensidades. O índice nSI (*Normalized Shadow Index*), mostrado na Equação 16, foi proposto pelos autores, conforme a diferença constatada para realçar as sombras e separá-las dos demais elementos da cena. Esse comportamento oposto é também apresentado no espaço HSV, conforme pode ser observado na Figura 9, devido a equivalência entre eles, e utilizado por Ma et al. (2008) na composição do índice NSDVI (*Normalized Saturation-Value Difference Index*) apresentado na Equação 17.

$$nSI = \frac{S - I}{S + I} \quad (16)$$

$$NSDVI = \frac{S - V}{S + V} \quad (17)$$

Figura 9 – Exemplo do comportamento das sombras no espaço HSV. (a) Imagem original WV-2; (b) Componente Saturação; (c) Componente Valor.



Existem, no entanto, diversos outros índices desenvolvidos neste sentido, como mostra Tsai (2006) e Chung et al. (2009), que utilizaram os canais Hue e Intensidade, mostrando uma melhor discriminação das sombras, quando comparado ao índice proposto por Polidoro et al. (2003). Entretanto, alvos que possuem o mesmo comportamento em ambos os canais de cores, devido à similaridade espectral das sombras, podem influenciar em falsas detecções. A vegetação também é um exemplo de erros na detecção, em virtude da densidade e arranjo do dossel que podem resultar em sombras e reduzir a resposta da vegetação. Estes efeitos refletem a importância da combinação de índices para a segmentação adequada dos objetos de interesse.

Embora esses índices permitam maior automatização na segmentação de sombras, apenas o efeito do espalhamento da atmosfera é considerado sobre regiões de sombras. As contribuições dos efeitos da absorção, reflectância vizinha, sensibilidade espectral dos sensores, irradiância solar, pode influenciar nos resultados obtidos, assim como influenciam na reflectância de superfície que se relaciona ao componente Hue tratado nos índices.

### 2.3 Restauração de Informações em Dados de Sensoriamento Remoto


Os dados de SR adquiridos por diferentes sensores do tipo passivo, contêm interferências no processo do registro dos dados, decorrentes em sua maioria, por falhas nos instrumentos detectores, por condições atmosféricas com a presença de nuvens, ou por condições do ambiente, como efeitos sazonais, da topografia, da presença de sombras, cobertura de neve, etc (VUOLO et al., 2017). Essas influências resultam na aquisição de imagens que não condizem com a superfície, pois as respostas que chegam no sensor são incompletas, corrompidas ou faltantes, que por sua vez restringem as aplicações de extração de informações e parâmetros da superfície terrestre.

Uma vez que é inevitável a obtenção de dados ópticos de sensores passivos sem falhas ou informações faltantes, o processo de reconstrução de imagens orbitais tornou-se um

tema recorrente nas últimas décadas. Um dos exemplos mais comuns visto entre a comunidade do SR, são as propostas para recuperar os dados do satélite Landsat 7, que apresentaram falha no sistema de compensação do movimento de avanço do sensor, realizado pelo instrumento SLC (*Scan Line Corrector*) (CHEN et al., 2011; JAIN et al., 2018). Após o desligamento do SLC, em 2003, as imagens do Landsat7 foram designadas como *SLC-off*, e possuem a ocorrência de um padrão de linhas paralelas pretas, ou seja, sem informações, que afetam grande parte da imagem, como pode ser visto no exemplo da Figura 10 (a), a qual mostra também exemplos de falta de informação provocadas por nuvens (Figura 10 (b)) e sombras (Figura 10 (c)) em imagens QuickBird e WorldView-2, respectivamente.

O processo de completar as informações faltantes ou de reconstruir dados corrompidos consiste em estimar valores a partir de dados válidos existentes ou de partes remanescentes da imagem. O uso de informações locais disponíveis nas partes remanescentes da imagem, e que não se encontram corrompidas, tem sido explorado por técnicas de transformação de intensidades visando a melhoria da informação na imagem. A seguir serão discutidas as técnicas mais usadas no contexto da restauração de sombras.

Figura 10 – Exemplos de imagens de SR com discontinuidades, informações faltantes e corrompidas. (a) Imagem do Landsat 7 ETM+ *SLC-off* ; (b) Porção da imagem contaminada por nuvens e (c) Sombras.



### 2.3.1 Transformações de Intensidades em Imagens

As limitações na aquisição de dados de SR por parte do sensor ou por condições adversas, resultam na distribuição incorreta dos valores de brilho, baixo contraste e até mesmo imagens com muitos ruídos radiométricos. As técnicas que envolvem transformações de intensidade têm como objetivo principal a melhoria da qualidade visual dessas imagens,

fazendo com que feições de interesse sejam reconhecidas e aumentando sua interpretação (GAO, 2009).

As técnicas de melhoria que realizam a manipulação direta dos pixels em uma imagem, são consideradas técnicas de transformação de espaço. Essa modificação dos valores dos pixels pode ser expressa como uma função de transformação de intensidade ou função de mapeamento na forma  $s = T(r)$ , em que  $T$  é uma transformação que mapeia o valor de pixel  $r$  em um valor de pixel  $s$  (GONZALES e WOODS, 2010). Apesar de serem consideradas técnicas simples, elas são essenciais para a manipulação de imagens e suas aplicações, sendo na maioria das vezes, o primeiro tipo de processamento que se deve realizar. Além disso, são consideradas computacionalmente mais eficientes, pois requerem menos recursos de processamento para serem realizadas (MENESES e ALMEIDA, 2012; GONZALES e WOODS, 2010).

No processo de transformação de intensidade, cada banda deve ser processada individualmente, sendo que nenhuma informação nova será criada, apenas a informação visual está representada com o máximo de contraste. Ao construir uma composição colorida da combinação de três bandas contrastadas, estas serão capazes de destacar as variações espectrais dos diferentes materiais da imagem. Não há uma regra de qual método deva ser aplicado e nem um padrão de qualidade da imagem contrastada, pois de maneira geral, estes requisitos estão condicionados ao objetivo específico do problema a ser resolvido, das características de cada imagem e da subjetiva capacidade de interpretação por parte do analista e usuários.

Na literatura existem várias técnicas para melhoria visual de imagens, dentre estas, existem as que são utilizadas para suprimir regiões escuras da imagem que por sua vez, podem ser aplicadas em regiões de sombras para evidenciar as feições sob seus efeitos, como a transformação de potência *gamma*, discutida na sequência.

#### a) Correção por Transformação de Potência *Gamma*


Transformações de potência, como a correção *gamma*, são transformações não-lineares que tem como objetivo alterar a faixa dinâmica das imagens para que elas tenham maior fidelidade no seu processo de captura ou exibição. Essa correção é necessária, pois a maioria dos dispositivos de aquisição, exibição e impressão de imagens apresentam uma relação não-linear entre a tensão e a luminosidade em que a resposta de intensidade de saída é uma função de potência da forma apresentada pela Equação 18 (GONZALES e WOODS, 2010).

$$s = cr^\gamma \quad (18)$$

sendo  $c$  e  $\gamma$  constantes positivas com  $c$  geralmente igual à 1;  $r$  e  $s$  os valores do pixel antes e depois da transformação. A não correção desse efeito resulta em imagens de saída mais escuras do que as imagens originais de entrada. A Figura 11 mostra o comportamento da transformação de potência dada pela Equação 18 para diferentes valores de  $\gamma$ . Em síntese, as curvas de potência para valores de  $\gamma < 1$ , mapeiam uma pequena faixa de valores de entrada escuros em um resultado com ampla faixa de valores de intensidade de saída. Este comportamento não linear em função da variação do expoente  $\gamma$ , tem sido utilizado na compensação dos baixos valores encontrados em regiões de sombras. A compensação desse efeito pode ser obtida a partir da transformação da lei de potência inversa (Equação 19), como um pré-processamento da imagem antes de sua exibição.

$$s = r^{1/\gamma} \quad (19)$$

Figura 11 – Plotagem da transformação de intensidade pela função de potência (Equação 18) para diferentes valores de  $\gamma$ .



Fonte: Adaptado de Gonzales e Woods (2010).


Nakajima et al. (2003) e Zhan et al. (2005), são exemplos de metodologias que utilizaram de uma função de potência da forma inversa para reduzir as diferenças de intensidade provocadas pelas sombras. Em ambas abordagens, as sombras são consideradas como uma fonte de ruído multiplicativo que corrompe o brilho da cena, e o parâmetro *gamma* é determinado em função dos valores de pixel da imagem sob condições normais de iluminação.

Nesses trabalhos, para aumentar a intensidade dos sinais registrados em áreas de sombras, o parâmetro *gamma* foi determinado pela formulação dada na Equação 20, considerando a resolução radiométrica da imagem de entrada e os valores médios de intensidade em regiões de sombras e não-sombras.

$$s = l \times (r/l)^{1/\gamma} \quad (20)$$

onde *r* e *s* representando os valores do pixel antes e depois da correção; *l* o range dinâmico de intensidades da imagem de entrada e  $\gamma$  o valor do parâmetro de correção *gamma*. A Figura 12 mostra o exemplo da correção *gamma* alcançado por Nakajima et al. (2003) em uma imagem de satélite. Em vistas gerais, a determinação do parâmetro geralmente considera a média de intensidade local das regiões de sombras e não-sombras, o que pode ser considerada uma vantagem para abordagens automáticas, pois se adaptam às diferentes características das imagens de entrada. Em contrapartida, sombras geralmente são extensas em imagens de áreas urbanas e ocupam uma grande parte da imagem, ocultando diversos tipos de materiais que se não considerados, podem comprometer o resultado da correção. Além disso, a identificação e determinação dos alvos que compõem cada região de sombra acarreta em uma demanda maior no tempo de execução, do que outros métodos abordados na literatura.

Figura 12 - Aplicação da correção *gamma* por Nakajima et al. (2003). (a) Imagem IKONOS original (banda PAN) com a presença de sombras e (b) Imagem corrigida.



#### b) Especificação de Histograma

A transformação de valores de intensidades da imagem por meio da especificação de histograma, conhecido também como casamento de histograma, permite determinar um formato específico para o histograma de saída de uma imagem. De forma geral, dada a imagem de entrada original e seu correspondente histograma, o processo envolve a transformação dos valores de intensidade da imagem original de tal forma, que a imagem de saída tenha um histograma de saída desejado (especificado à priori) (GAO, 2008).

Como na prática, a maioria das imagens não são adquiridas com histograma uniforme, deve-se lançar mão de técnicas de manipulação de histograma para realce e melhoria da informação visual. Embora a equalização de histograma seja um dos métodos mais conhecidos para obtenção de histograma uniforme, nem sempre o resultado desta transformação produz melhoria da informação e aumento de contraste (GONZALES e WOODS, 2010). Isto é visto para os casos em que a imagem possui extensa área homogênea de brilho, como corpos d'água e rodovias, por exemplo. Além disso, existem situações em que se torna desejável poder definir a forma específica para o histograma da imagem de saída, como é o caso do método de especificação de histograma.

Amplamente utilizada na criação de mosaicos para reduzir as diferenças radiométricas entre cenas adjacentes (RICHARDS, 2012), tomadas de duas órbitas ou de faixas do mesmo sensor, a especificação de histograma realiza um mapeamento dos valores da imagem de entrada para seus valores mais próximos no histograma especificado. Para isto, de posse da imagem de entrada e do histograma especificado, calcula-se a função de equalização da imagem de entrada primeiramente, cuja função para o caso discreto é dada pela Equação 21 (GONZALES e WOODS, 2010).

$$s_k = T(r_k) = \frac{(L-1)}{MN} \sum_{j=0}^k n_j \quad (21)$$

onde  $MN$  é o número total de pixels da imagem de entrada,  $n_j$  representa o número de pixels com intensidade  $r_j$  e  $L$  denota o número total de níveis de intensidade possíveis na imagem. Em seguida, calcula-se a função de transformação  $G(z_q)$  através da Equação 22, sendo  $p_z(z_i)$  os valores do histograma especificado.

$$G(z_q) = (L-1) \sum_{i=0}^q p_z(z_i) \quad (22)$$


Os valores calculados de  $G$  devem ser arredondados para números inteiros no intervalo  $[0, L-1]$ . Assim, o objetivo é encontrar os valores  $z_q$  (Equação 23) no histograma especificado, de modo que  $G(z_q)$  seja o mais próximo possível de  $s_k$ .

$$z_q = G^{-1}(s_k) \quad (23)$$

A Figura 13 ilustra o princípio da especificação de histograma. De uma maneira simples, o processo na prática consiste em construir uma tabela indexada (LUT, do inglês *look up table*), a qual armazena os valores inteiros de  $G(z_q)$  dentro do intervalo  $[0, L-1]$ . Busca-se então, para cada valor calculado de  $s_k$ , qual a posição da tabela que encontra-se sua melhor

correspondência (valor semelhante ou próximo), e o valor de intensidade encontrado  $z_q$  (proveniente do histograma especificado) é atribuído à imagem de entrada. Se, por exemplo, o valor de  $s_k$  for mais próximo da 150ª entrada da LUT, então tem-se  $q=149$  (pois descarta-se o valor inicial 0), e o valor de  $s_k$  é mapeado em  $z_q$ .

Figura 13 - Procedimento de transformação por especificação de histograma.



Fonte: Adaptado de Richards (2012).

A especificação de histograma, devido à sua tendência de mover as intensidades da imagem para extremidade superior da escala de intensidades do histograma, vem sendo amplamente empregada no contexto de remoção de sombras. Em Tsai (2006), o processo de restauração de sombras por meio da especificação de histogramas é realizado em duas etapas. Primeiramente, com as regiões de sombras já identificadas pelo processo de detecção, os autores determinam por meio de operadores morfológicos, as regiões de vizinhanças das sombras, as quais servirão de referência para o histograma especificado. Calcula-se então, para cada região de sombra e de vizinhança conectadas, seus histogramas acumulados e normalizados para a construção da LUT. Por fim, a segunda etapa envolve o ajuste dos valores de intensidade, a partir dos valores disponíveis na LUT. Embora seja considerado um método global de transformação de intensidades por Gonzales e Woods (2010), Tsai (2006) mostrou ser possível sua aplicação em escala local banda a banda, sendo a LUT gerada a cada região de sombras e de vizinhança conectadas. O método apresentou bons resultados (Figura 14), melhorando a visualização em pequenas regiões de sombras homogêneas, ou seja, que não apresentavam variabilidade de materiais envolvidos nessas áreas de sombras.

Figura 14 – Resultado da aplicação da especificação de histograma por Tsai et al. (2006). (a) Imagem aérea original com sombras e (b) Imagem corrigida.



Em aplicações com imagens, em que valores de intensidade são discretos, o histograma resultante não possui exatamente a mesma forma do especificado, sendo o resultado uma aproximação ao formato desejado (distribuição do brilho da imagem). Vale ressaltar que a equalização do histograma não é uma etapa necessária, sendo útil apenas para explicar o procedimento, e que na realidade, as etapas podem ser resumidas no relacionamento de  $r$  em  $s$  e de  $s$  em  $z$ , ou seja, o mapeamento pode ser realizado diretamente para mapear os pixels originais nos pixels da imagem do histograma especificados (GONZALES e WOODS, 2010). Além disso, o histograma especificado não necessariamente precisa ser extraído de uma imagem, podendo corresponder a uma função matemática especificada, com as propriedades corretas (SOLOMON e BRECKON, 2013).

### c) Correlação Linear

Para compensar as diferenças de iluminação provocadas por sombras, existem trabalhos que propõem o estabelecimento de uma correlação linear entre sombras e suas áreas de vizinhanças. A análise de correlação é usada para entender e avaliar o relacionamento linear entre duas ou mais variáveis existentes (TRIOLA, 1999). Sob a hipótese de que as áreas de sombras e não sombras em uma imagem compartilham das mesmas condições de iluminação, o modelo linear é estabelecido e se utiliza de informações locais retiradas de ambas as áreas (SHAHTAHMASSEBI et al., 2013). O objetivo é promover a melhoria da informação sob sombras, a partir do ajuste baseado em uma transformação linear (Equação 24), a qual relaciona as estatísticas, como a média e desvio-padrão de intensidades, de ambas regiões consideradas.

$$y = \frac{S_{ns}}{S_s}(x - x_s) + y_{ns} \quad (24)$$

onde  $x$  é o valor de intensidade do pixel de sombra;  $y$  representa o valor de intensidade corrigido;  $S_s$  e  $S_{ns}$  representam, respectivamente, o desvio padrão da área de sombra e não-sombra;  $x_s$  e  $y_{ns}$  são as médias das regiões de sombras e não-sombras, respectivamente.

Utilizando dessa abordagem, trabalhos como Nakajima et al. (2003), Sarabandi et al. (2004) e Chen et al. (2007) apresentaram discreta correção da influência de sombras sob imagens de áreas urbanas. Embora as amostras de imagens utilizadas pelos autores não proporcionam clara nitidez dos detalhes recuperados (Figura 15), o método mostra-se sensível e promissor na correção dos efeitos negativos de sombras, desde que adotados alguns procedimentos. A transformação por correlação linear quando aplicada de maneira global, por exemplo, em que a função de transformação é baseada na distribuição de intensidade de toda a imagem, apesar de ter um custo computacional menor, pode resultar em supressão de detalhes. Em imagens com alto detalhamento, como as de alta resolução espacial, abordagens locais, utilizando regiões de vizinhanças mais próximas das áreas de sombras analisadas, tendem a preservar detalhes, em troca de uma maior demanda de tempo para o processamento.

Figura 15 – Resultado da aplicação correlação linear Chen et al. (2007). (a) Imagem original do satélite QuickBird com sombras e (b) Imagem corrigida.



### 2.3.2 Restauração de Imagens por Inpainting Digital


A técnica de inpainting tem como premissa básica recuperar partes da imagem que foram danificadas ou remover artefatos indesejados presentes nas imagens (BERTALMÍO et al., 2000). O termo inpainting, também conhecido como retoque digital, tem como referência as práticas manuais de restauração exercidas por artistas da era medieval, cujo objetivo, era de recuperar falhas ou informações perdidas em pinturas antigas. Assim, o inpainting digital

propõe-se simular o processo de restauração manual no âmbito computacional, vistas as inúmeras funções que o retoque pode assumir no meio digital. O interesse no inpainting aumentou consideravelmente nas últimas décadas, principalmente pelo advento das imagens digitais, proporcionando a automatização da tarefa de restauração. Dentre as principais aplicações na literatura, encontram-se a restauração de fotografias e filmes, remoção de texto, desocclusão, remoção de objetos indesejados e retoques de fotos (QURESHI et al., 2017).

Assim como as técnicas de transformação de intensidades, o inpainting busca aumentar a qualidade da imagem, com o objetivo de produzir maior detalhamento das estruturas, que devido a falhas ou falta de informação, não eram visíveis antes da restauração pelo inpainting. Porém, os métodos de inpainting partem do pressuposto de que não existem informações disponíveis nas regiões danificadas da imagem, diferentemente das demais técnicas de melhoria. Ainda sim fazem parte dos métodos espaciais, que utilizam a hipótese de que as áreas desconhecidas a serem recuperadas e as demais regiões da imagem, compartilham das mesmas estruturas e propriedades estatísticas. Apesar do grande interesse nesta área de investigação com muitos trabalhos já publicados, trata-se de uma técnica recente de restauração de imagens no campo do SR, sendo o trabalho proposto por Bertalmio et al. (2000), o pioneiro no inpainting automático de imagens digitais na área clássica de Processamento de Imagens.

De maneira geral, dada uma imagem  $m \times n$  (Figura 16) com uma região interna à ela danificada/faltante  $\Omega$  (também chamada de domínio de inpainting), o processo de inpainting consiste em modificar os valores dos pixels em  $\Omega$ , baseando-se em informações de vizinhanças  $\partial\Omega$  contidas nas partes remanescentes da imagem ( $\Phi$ ), de tal forma que esta região recuperada não se destoe de sua vizinhança.

Figura 16 - Descrição geral do processo de inpainting.




O resultado do inpainting, portanto, leva à novas estruturas visíveis, que devem ser coerentes com as regiões de vizinhança, de modo que o retoque seja imperceptível na análise

visual. Em função da quantidade de problemas aos quais o inpainting é capaz de resolver, muitas têm sido as abordagens vistas na literatura, as quais diferenciam-se basicamente, na ordem adotada de preenchimento de  $\Omega$ , na forma como realizam o preenchimento (propagação da informação) e pela sensibilidade às regiões de textura. Ao considerar a modelagem matemática empregada nas abordagens, as técnicas de inpainting têm sido separadas em quatro principais frentes (CASACA et al., 2014; QURESHI et al., 2017): Métodos baseados em Equações Diferenciais Parciais (EDP), Métodos baseados em replicação de pixels, Métodos baseados em representação esparsa e Métodos híbridos.

### 2.3.2.1 Métodos de Inpainting

Nos métodos de inpainting via EDPs, as informações das vizinhanças são propagadas suavemente para o domínio de inpainting, de modo a dar continuidade as linhas isocrômicas, também chamadas de isófotos (do inglês, *isophotes*), ou seja, linhas de propagação de mesmo valor de intensidade na imagem (Figura 17). O modelo pioneiro proposto por Bertalmio et al. (2000), mencionado anteriormente, introduziu a ideia de utilizar uma difusão anisotrópica como forma de corrigir a evolução da direção de preenchimento para dentro de  $\Omega$ , buscando manter o padrão geométrico da informação local presente em  $\partial\Omega$ .

Figura 17 - Exemplo da direção de propagação por linhas isocrômicas da imagem.



Fonte: Adaptado de Shen et al. (2015).

No conjunto de técnicas de inpainting baseadas em EDPs, diversas variantes são observadas, as quais utilizam de diferentes modelos de difusão (lineares, não lineares, isotrópicos e anisotrópicos) de modo a favorecer direções particulares de propagação. Embora sejam computacionalmente mais rápidas e, na teoria, a continuação dos isófotos seja factível, na prática, os métodos via EDPs não são recomendados para reconstruir áreas extensas e com texturas. Quando não aplicado em imagens com domínio de inpainting limitado, o aparecimento

de borramentos e a excessiva suavização são observadas em áreas que contêm contornos e texturas (CASACA, 2010; SHEN et al., 2015; QURESHI et al., 2017)


Conforme vastamente reportado na literatura, os métodos via EDPs não são adequados para a restauração de imagens que envolvem texturas complexas e áreas extensas a serem recuperadas. A textura, no contexto de imagens de SR, constitui-se no arranjo e caracterização da repetição de intensidade e cor, sendo desta forma, um importante elemento na interpretação visual presente por toda a extensão da imagem (JENSEN, 2009). Assim, os métodos baseados em EDPs são limitados ao tratar de imagens com alta resolução espacial com grandes regiões de restauração, uma vez que elas são compostas pelos mais variados tipos de objetos e texturas. Neste caso, propostas que utilizam síntese de textura se mostram mais adequadas para recuperar áreas largas e texturizadas da imagem, pois utilizam a estratégia de reprodução de padrões de textura a partir de grupo de pixels presentes na própria imagem. Dessa forma, as técnicas de síntese de textura pixel a pixel têm como principal objetivo encontrar o melhor conjunto de pixels que se encaixe na área a ser preenchida, segundo uma medida de similaridade adotada.

No entanto, apesar de se mostrarem mais adequados para a realização de muitas tarefas como preenchimento de objetos, recuperação de imagens, compressão de vídeos etc., elas tendem a apresentar falhas quando a região a ser reconstruída é composta por diferentes tipos de texturas. Isso ocorre, na maioria dos casos, devido a adoção de toda a imagem como região de amostragem dos pixels, ao invés da busca local na vizinhança da região a ser reconstruída (CASACA et al., 2014). Além disso, o alto custo computacional das técnicas de síntese de textura pixel a pixel também pode ser visto como um ponto desfavorável de aplicação deste tipo de abordagem.

Os métodos baseados em exemplos podem ser considerados uma evolução das técnicas de síntese de textura. Nas abordagens envolvidas, além da síntese de textura ser realizada a partir de blocos de pixels ao invés de um único pixel, os métodos adotam uma ordem de prioridade durante o processo de reconstrução, que consideram tanto as informações geométricas, quanto as variações de intensidade locais da imagem. Um trabalho que merece destaque dentre os métodos baseados em exemplos é o proposto de Criminisi et al. (2004). Neste trabalho, os autores propõem o uso combinado da ideia do inpainting, de proporcionar a continuidade dos isófotos, e o emprego de uma prioridade de preenchimento no processo de síntese de textura, para a replicação de blocos de padrões selecionados a partir da região de amostragem. A Figura 18 ilustra o processo de reconstrução proposto por Criminisi et al. (2004), mostrando em (a) a imagem original que contém a região alvo a ser reconstruída ( $\Omega$ ),

seu contorno ( $\partial\Omega$ ), e a região de amostragem ( $\Phi$ ). O método visa sintetizar a região  $\Psi_p$  de vizinhança do pixel  $p$ , com  $p \in \partial\Omega$ , de modo a encontrar o bloco mais similar dentre os blocos candidatos  $\Psi_{q'}$  e  $\Psi_{q''}$  no espaço de amostragem (Figura 18 (b)). Como mostrado na Figura 18 (c), tem-se a substituição de  $\Psi_p$  pelo bloco ótimo, de forma a recompor uma parte faltante de  $\Omega$ . O processo se repete até que  $\Omega$  seja preenchido por completo. Vale a pena ressaltar que ambas as linhas (amarela e azul) foram propagadas com sucesso para a região a ser preenchida na imagem de ilustração, conforme pode ser visto ainda na Figura 18 (c), em referência à estrutura e a textura consideradas na modelagem de preenchimento do método.

Figura 18 – Ilustração da abordagem de reconstrução baseada em exemplos proposta por Criminisi et al. (2004).



A ordem de preenchimento no método de Criminisi ganha destaque no processo de síntese da informação, pois estabelece uma medida de prioridade  $P(p)$  (Equação 25), que balanceia tanto a continuidade das estruturas básicas da imagem, quanto a direção das intensidades dos isófotos na região analisada.

$$P(p) = C(p) \cdot D(p) \quad (25)$$

Na equação acima,  $C(p)$  e  $D(p)$  são os termos de confiabilidade e de dados, respectivamente, definidos por:

$$C(p) = \frac{\sum_{q \in \Psi_p \cap (T-\Omega)} C(q)}{|\Psi_p|}, \quad D(p) = \frac{|\nabla I_p^\perp \cdot n_p|}{\alpha} \quad (26)$$

onde  $|\Psi_p|$  é a área do bloco  $\Psi_p$ , centrado no ponto  $p$ , cuja dimensão é pré-fixada,  $I$  a imagem de entrada e  $T$  o seu domínio,  $\alpha$  é um fator de normalização ( $\alpha = L-1$ , com  $L$  igual ao valor

máximo de intensidade da imagem),  $\Omega$  a região de inpainting a ser reconstruída,  $n_p$  um vetor unitário ortogonal a região de vizinhança  $\partial\Omega$  no ponto  $p$  e  $\perp$  denota o operador ortogonal.

De acordo com os autores, o termo de confiabilidade  $C(p)$  determina uma medida de confiança para a região de vizinhança de  $p$ , de modo a priorizar na região de fronteira a continuidade de formas e estruturas, pois atribui os menores valores de confiabilidade aos pixels no centro da região de inpainting  $\Omega$ . Dessa forma, evita-se maiores influências dos blocos já inseridos e que não fazem parte da região de amostragem original. No caso do termo  $D(p)$ , ele garante o preenchimento na direção dos isófotos nas regiões de fronteira, considerando tanto a direção local da região como a informação de intensidade, de modo a priorizar a continuidade de estruturas lineares. Uma vez que todos os valores de prioridade são computados, o bloco com maior prioridade e que atende a medida de similaridade estabelecida (Equação 27) é considerado ótimo ( $\psi_{\hat{q}}$ ) e então utilizado no preenchimento da região alvo, até que esta seja completamente reconstruída. Em termos mais matemáticos, a medida de similaridade é calculada por:

$$\psi_{\hat{q}} = \arg \min_{\psi_q \in \Phi} d(\psi_{\hat{p}}, \psi_q) \quad (27)$$

onde  $d(\psi_{\hat{p}}, \psi_q)$  representa a distância definida pela soma das diferenças ao quadrado (SSD, do inglês *Sum of Squared Differences*) entre dois blocos, o bloco alvo  $\psi_{\hat{p}}$  e o candidato  $\psi_q$ . A cada preenchimento, os valores de prioridades são recalculados e atualizados, para uma nova região  $\psi_{\hat{p}}$  a fim de priorizar os pixels na região de fronteira, como comentado anteriormente.

Ao adotar esse modelo de síntese de textura baseado em exemplar por blocos, os autores produzem resultados apresentáveis no inpainting de áreas extensas e texturizadas, além da replicação por blocos reduzir efetivamente o tempo de processamento. No entanto, uma das ressalvas a serem feitas no método é a adoção de  $\Omega^c$  como região de amostragem, ou seja, o algoritmo busca os blocos candidatos em toda a extensão da imagem, excluindo a região alvo. No caso de imagens de SR, pode levar à replicação incorreta de pixels, produzindo áreas restauradas com baixa consistência e coerência visual. Além disso, a busca exaustiva em toda a imagem acarreta em maior esforço computacional, afetando o tempo de processamento,

A utilização de técnicas de transformação de domínios, tais como wavelets (MALLAT, 2008), transformada discreta do cosseno (DCT) e wave atoms (DEMANET e YING, 2007) tem sido comumente aplicada no contexto do inpainting de imagens, e compõem os métodos de representação esparsas. Estas técnicas baseiam-se na hipótese de que as regiões conhecidas e faltantes da imagem compartilham das mesmas propriedades e assim, ao serem

esparsamente representadas, os pixels faltantes possam ser recuperados pela atualização adaptativa da representação esparsa (GULERYUZ, 2006). Efeitos de borramentos podem ocorrer na recuperação de grandes regiões não regulares, em que a área restaurada apresenta-se suavizada em relação as demais.

Ao observar as vantagens e desvantagens de cada abordagem, tem-se a proposição de métodos híbridos. Os métodos híbridos combinam, por exemplo, a capacidade de preservação de textura que os métodos baseados em exemplos detêm, com a preservação da estrutura da imagem fornecida pelos métodos baseados em EDPs. No método proposto por Bertalmío et al. (2003) por exemplo, adota-se a decomposição da imagem em duas componentes: estrutura e textura, como forma de separar informações geométricas das texturas (ou detalhes com características oscilatórias e ruídos), de modo a realizar o processamento separado de cada componente. Dada uma imagem  $f$ , a decomposição deve satisfazer a seguinte relação:

$$f = u + v \quad (28)$$

A componente  $u$ , também chamada “cartoon” contém a estrutura e os objetos da imagem e,  $v$  representa os padrões texturais presentes na imagem. Com a decomposição é possível aplicar o método de inpainting via EDP (BERTALMIÓ et al., 2000) na imagem *cartoon* ( $u$ ), e o método de síntese de textura (EFROS e LEUNG, 1999) sobre a imagem  $v$ , cujo resultado final é obtido a partir da Equação 28. Nos casos em que a recuperação ocorre sobre grandes áreas, o custo computacional é elevado ao se adotar este tipo de abordagem de decomposição.

Com o objetivo de aliar as principais vantagens apresentadas pelos métodos de inpainting dispostos na literatura, conforme comentado, o método híbrido proposto em Casaca (2010) contribui com as ideias de inpainting automático de imagens. O método descrito em sua dissertação e posteriormente melhorado, sendo publicado em Casaca (2014), trata-se de uma abordagem híbrida inspiradas nas ideias de (BERTALMIÓ et al., 2000; BERTALMIÓ et al., 2003; CRIMINISI et al., 2004; CALVETTI et al., 2006). O método consiste na combinação de difusão anisotrópica, equação do transporte, amostragem dinâmica e síntese de textura para o inpainting de imagens com grandes áreas dotadas de texturas.

No capítulo seguinte, uma descrição da abordagem empregada será apresentada, juntamente com as devidas modificações propostas no desenvolvimento dessa pesquisa que visam a remoção das sombras em imagens orbitais com alta resolução espacial.

### 3. MATERIAIS E MÉTODO

Neste capítulo serão apresentados os materiais utilizados no desenvolvimento da pesquisa e a descrição geral da metodologia proposta para a remoção de sombras. A metodologia será detalhada na seção 3.2, a qual apresenta as etapas de detecção e restauração, bem como os procedimentos de avaliação de cada etapa.

#### 3.1 Materiais

Os recursos materiais utilizados para o desenvolvimento desta pesquisa são constituídos por imagens ópticas multiespectrais de alta resolução espacial, softwares para o processamento das imagens, desenvolvimento do algoritmo e análise dos dados, que serão apresentados a seguir.

##### 3.1.1 Recursos Computacionais e Softwares

- Computador Dell Vostro NBK 5470 com processador Intel Core i7, 8 GB de memória RAM e disco rígido de 500 MB (adquirido pelo projeto FAPESP 2013/25257-4);
- *Software* ENVI (*Environment for Visualizing Images*) desenvolvido pela empresa Exelis VIS (Visual Information Solutions);
- *Software* MATLAB R2017b, versão 9.3.0.713579;
- Caixa de ferramentas de Morfologia Matemática, SDC Morphology Toolbox for MATLAB, versão 1.6;
- *Image Processing Toolbox* for MATLAB;
- Sistema de Informação Geográfica *Quantum GIS (QGIS)*;
- Adobe Photoshop CS5.

Em relação aos recursos computacionais, o software ENVI foi empregado no pré-processamento das imagens que envolveu as etapas da calibração radiométrica, correção atmosférica e fusão. As imagens corrigidas são os dados de entrada para o algoritmo implementado no MATLAB, o qual faz uso de funções disponíveis nas *toolbox* de morfologia matemática e de processamento de imagem. A abordagem foi desenvolvida de tal forma que nenhuma interação com o usuário fosse necessária, visando à automatização total da tarefa. A parte manual e onerosa foi realizada no programa Photoshop para geração dos dados de

referência (*Ground Truth* - GT). Por fim, o MATLAB, o ENVI e o QGIS também foram utilizados, respectivamente, para a avaliação da fusão, na classificação não-supervisionada das imagens restauradas e na geração do NDVI.

### 3.1.2 Imagens Multiespectrais

Com o objetivo de avaliar a metodologia proposta foram utilizadas duas imagens orbitais, uma do satélite WorldView-2 (WV-2) e a outra do satélite Pléiades 1B (PL-1B). Por se tratarem de imagens multiespectrais de alta resolução espacial, as imagens foram adquiridas comercialmente, para atender à necessidade não somente deste projeto, mas também dos demais trabalhos desenvolvidos pelo grupo de pesquisa em Morfologia Matemática da FCT-UNESP.

As duas cenas cobrem aproximadamente 25 km<sup>2</sup> cada e abrangem uma parte da cidade de São Paulo, a qual concentra a maior população e densidade demográfica do Brasil. Em 2017, a população de São Paulo foi estimada em 12,1 milhões de habitantes (IBGE, 2017)<sup>4</sup>, ou 20 milhões, se considerada sua região metropolitana<sup>5</sup>. A área de estudo é mostrada na Figura 19, com destaque para a área de cobertura das duas imagens orbitais da região central da cidade de São Paulo. Além disso, nota-se também a extensão da região metropolitana, englobando cidades próximas, como Guarulhos, Osasco, entre outras.


A escolha da área urbana de São Paulo se baseou pela grande concentração de feições antrópicas, como edificações residenciais, industriais e comerciais, que certamente contribuem para a ocorrência de grandes quantidades de sombras, em imagens com alta resolução espacial. Neste contexto, encontram-se sombras com variadas formas e tamanhos, formadas por todos os tipos de alvos presente no ambiente urbano (edifícios, árvores, viadutos e carros), conforme pode ser visto na Figura 20.

---

<sup>4</sup> Sítio da estimativa de população de São Paulo pelo IBGE - <https://cidades.ibge.gov.br/brasil/sp/sao-paulo/panorama>

<sup>5</sup> Uma **região metropolitana** é um aglomerado urbano composto por vários municípios administrativamente autônomos, mas integrados física e funcionalmente, formando uma mancha urbana praticamente contínua (...) (BRAGA e CARVALHO, 2004 apud FREITAS, 2009).

Figura 19: Localização das cenas utilizadas nos experimentos.



Projeções de sombras podem ser vistas sobre muitos outros alvos, incluindo vegetação e corpos d'água, ampliando as dificuldades na identificação das sombras tendo em vista o comportamento dinâmico da vegetação e a resposta similar do corpo d'água em algumas bandas. Com isso, o objetivo foi testar a robustez do método frente a grande diversidade espectral dos materiais presentes nas áreas urbanas, e sua eficácia devido à grande variabilidade de tipos de cobertura da terra.

Figura 20 - Exemplo de feições antrópicas e suas respectivas projeções de sombras presentes nas imagens WolrdView-2 e Pléiades-1B utilizadas.



As configurações das bandas adquiridas foram similares para cada cena, as quais contam com uma banda Pancromática de melhor resolução espacial (50 cm) e quatro bandas multiespectrais (azul, verde, vermelho e infravermelho próximo), com GSD de 2 m.

Originalmente, o sensor PL-1B coleta imagens com GSD de 0.7 m e 2.8 m no modo Pancromático e Multiespectral, respectivamente. No entanto, as imagens foram reamostradas antes de serem fornecidas, assim a quantização do sinal, que originalmente é coletado em 12 bits (4096 níveis de cinza), foi alterada para 16 bits (65536 níveis de cinza) no modo GeoTIFF. As imagens WV-2, também foram obtidas já reamostradas, em uma menor quantização, igual a 8 bits (256 níveis de cinza), quando originalmente são coletadas com 11 bits (2048 níveis de cinza). A vantagem em utilizar imagens com configurações diferentes é a possibilidade de avaliar a robustez do método em relação às mudanças de resoluções radiométricas.

Informações sobre a geometria de aquisição são encontradas junto aos metadados das imagens, cujas principais características estão especificadas na Tabela 1. As datas de aquisição das imagens são de épocas do ano relativamente próximas, sendo tomadas no final do outono (PL-1B) e começo do inverno (WV-2). As aquisições das imagens apresentaram valores semelhantes dos ângulos de iluminação e visada, o que resultam em sombras com orientação semelhantes. Ambas as cenas contam com um nível básico de correção radiométrica e estão georreferenciadas no datum WGS84 (*World Geodetic System 1984*) e sistema UTM (Universal Transversa Mercator) zona 23S.


Tabela 1 - Informações sobre a geometria de aquisição.

| <b>Informações</b>                  | <b>WorldView-2</b> | <b>Pléiades-1B</b> |
|-------------------------------------|--------------------|--------------------|
| <b>Data de aquisição</b>            | 06/07/2012         | 13/06/2015         |
| <b>Horário</b>                      | 13:41:16.547       | 13:20:40.3         |
| <b>Elevação solar</b>               | 39° 00' 00"        | 36°41'44.51"       |
| <b>Azimute solar</b>                | 27°06'00"          | 30°51'58.69"       |
| <b>Ângulo zenital solar</b>         | 51°00'00"          | 53°18'15.49"       |
| <b>Azimute do sensor</b>            | 170°12'00"         | 179°56'14"         |
| <b>Ângulo zenital do sensor</b>     | 09°42'00"          | 06°28'32.75"       |
| <b>Ângulo de visada (off-nadir)</b> | 2°54'00"           | 5°59'30.27"        |

### 3.2 Metodologia Proposta

O objetivo principal da pesquisa foi desenvolver uma abordagem automática para a detecção de sombras e a remoção dos efeitos em imagens de alta resolução espacial de áreas urbanas. Para isto, a metodologia proposta engloba quatro grandes etapas sequenciais: pré-processamento, detecção de sombras, remoção dos seus efeitos e a análise dos resultados, que serão descritas nas seções posteriores. A Figura 21 apresenta as principais etapas do método proposto.

Figura 21 – Fluxograma das principais etapas envolvidas no método de remoção de sombras.



### 3.2.1 Pré-processamento

A etapa de pré-processamento consiste nos processos envolvidos para a correção atmosférica das imagens e aumento da resolução espacial das imagens multiespectrais, por meio da fusão entre as bandas. A correção atmosférica dos dados foi necessária para a criação das máscaras espectrais, uma vez que as imagens foram obtidas com correção radiométrica básica, a qual inclui somente a correção de erros inerentes aos sensores durante o processo de imageamento, como a correção da corrente escura (do inglês *dark current*) e outros ruídos.

As imagens WV-2 e PL-1B foram então convertidas de NDs para valores de reflectância aparente, utilizando o módulo de calibração radiométrica disponível no programa ENVI. Para a conversão são utilizadas as informações presentes nos metadados da imagem,

como valores de ganho, *offset* e o comprimentos de onda central de cada banda, o horário de aquisição, o ângulo de elevação solar, irradiância solar e o valor de FWHM (largura da banda). As informações utilizadas na correção atmosférica do conjunto de bandas das imagens WV-2 e PL-1B estão especificadas nas Tabelas 2 e 3, respectivamente.

Embora sombras possuam contribuições da atmosfera em sua resposta, a correção dos dados para reflectância aparente não limita a tarefa de identificá-las, pelo contrário, ao considerar imagens com respostas físicas dos alvos, torna a abordagem mais robusta e acurada (ADELINE et al., 2013).

Tabela 2 - Metadados das bandas do sensor WorldView-2.

| <b>Bandas</b>                | <b>Comprimento de Onda (nm)</b> | <b>FWHM (nm)</b> | <b>Ganho (W/m<sup>2</sup>s r μm)</b> | <b>Offset (W/m<sup>2</sup>s r μm)</b> | <b>Irradiância Solar (W/m<sup>2</sup>μm)</b> |
|------------------------------|---------------------------------|------------------|--------------------------------------|---------------------------------------|----------------------------------------------|
| <b>Pancromática</b>          | 632,2                           | 336,9            | 0,9820                               | 0                                     | 1580,814                                     |
| <b>Azul</b>                  | 480,0                           | 54,3             | 0,0653                               | 0                                     | 1974,2416                                    |
| <b>Verde</b>                 | 545,0                           | 63,0             | 0,0572                               | 0                                     | 1856,4104                                    |
| <b>Vermelho</b>              | 660,0                           | 57,4             | 0,0848                               | 0                                     | 1559,4555                                    |
| <b>Infravermelho Próximo</b> | 835,0                           | 98,9             | 0,0937                               | 0                                     | 1069,7302                                    |


Tabela 3 - Metadados das bandas do sensor Pléiades-1B.

| <b>Bandas</b>                | <b>Comprimento de Onda (nm)</b> | <b>FWHM (nm)</b> | <b>Ganho (W/m<sup>2</sup>s r μm)</b> | <b>Offset (W/m<sup>2</sup> sr μm)</b> | <b>Irradiância a Solar (W/m<sup>2</sup>μm)</b> |
|------------------------------|---------------------------------|------------------|--------------------------------------|---------------------------------------|------------------------------------------------|
| <b>Pancromática</b>          | 640,0                           | 326,8            | 0,0834                               | 0,0                                   | 1548,0                                         |
| <b>Azul</b>                  | 495,0                           | 76,5             | 0,0987                               | 0,0                                   | 1915,0                                         |
| <b>Verde</b>                 | 558,5                           | 83,7             | 0,0982                               | 0,0                                   | 1830,0                                         |
| <b>Vermelho</b>              | 656,0                           | 78,8             | 0,0884                               | 0,0                                   | 1594,0                                         |
| <b>Infravermelho Próximo</b> | 842,5                           | 130,3            | 0,0575                               | 0,0                                   | 1060,0                                         |

Após a obtenção da imagem em reflectância aparente, a fusão entre a banda pancromática e as bandas multiespectrais de ambas as cenas foi realizada. O objetivo foi integrar as características fornecidas pelas 4 bandas multiespectrais de 2 m, a fim de aproveitar as características fornecidas pelas sombras em modelos de cores, com a alta resolução espacial da PAN de 50 cm. Assim, após a fusão foi possível obter bandas com alta resolução espacial e espectral. O *software* ENVI foi utilizado para a realização da fusão das imagens. O registro das bandas não foi necessário, uma vez que as bandas a serem fusionadas estão georreferenciadas e são oriundas do mesmo sensor. Dentre os métodos de fusão disponíveis no ENVI, foram

testados a transformação por Componentes Principais (CP) e Gram-Schmidt (GS), já que ambos os métodos não limitam a quantidade de bandas envolvidas no processo e, portanto, todas as quatro bandas foram utilizadas.

O método de fusão mais adequado foi selecionado a partir de uma avaliação quantitativa, baseada em métricas que comparam a similaridade espectral das imagens fusionadas com as bandas originais (seção 2.2.2.3). No processo de avaliação, como as bandas fusionadas não apresentam mais a mesma resolução espacial das bandas originais, um processo de reamostragem sobre as fusionadas é necessário, para compatibilizar e comparar a similaridade espectral entre elas. O processo de avaliação é ilustrado na Figura 22. O método de interpolação vizinho mais próximo foi selecionado, tanto para os métodos de fusão, quanto para o processo de reamostragem na avaliação, para evitar novos valores de brilho que não correspondem à cena original (SCHOWENGERDT, 2007).



As imagens fusionadas são a base para a construção dos índices espectrais, que por sua vez, têm a finalidade de fornecer informações espectrais que permitem evitar confusão entre alvos, motivo de se utilizar o NDVI, assim como evidenciar regiões de sombras no espaço HSV ao se utilizar o índice NSDVI. Maiores informações sobre o emprego dos índices no método de detecção são apresentadas na próxima seção.

### 3.2.2 Abordagem para Detecção Automática de Sombras

A primeira etapa propriamente dita do algoritmo implementado no software MATLAB é a detecção dos pixels que representam as áreas de sombras. As imagens já pré-processadas são os dados de entrada do algoritmo, cujo método baseia-se em duas propriedades básicas que as sombras detêm em imagens:

- Propriedade 1: Pixels pertencentes às áreas de sombras tendem a ter os menores valores de resposta registrado pelo sensor, ao longo de todo espectro eletromagnético (ADELINE et al., 2013);
- Propriedade 2: Sombras apresentam maior saturação (S) na banda do azul, devido à contribuição do espalhamento e baixo valor de intensidade (I) no modelo de cores HSI (POLIDORO et al., 2003).


O baixo padrão de resposta das sombras (propriedade 1) é explorado no método pelas ferramentas do PMI, mais especificamente pela transformação *top-hat* por fechamento, a qual realça regiões escuras da imagem.

Com o intuito de eliminar a determinação de um EE fixo necessário para o fechamento morfológico convencional, propõe-se nesta abordagem, a utilização da filtragem morfológica por área. Assim, os padrões escuros menores que o parâmetro de área são removidos da imagem e recuperados posteriormente, por meio da diferença entre a filtragem e a imagem original. O uso da filtragem morfológica por atributo favorece as aplicações em que os alvos de interesse não apresentam um padrão na imagem, como é o caso das sombras, que por possuírem formas e tamanhos variados, tornam inviável a determinação de um único EE para extraí-las. Além disso, como a análise do parâmetro de área é feita em cada seção transversal e obedecendo as regiões planas, têm-se uma redução na complexidade da cena e uma abordagem mais robusta na análise de imagens com alta resolução espacial.

A definição do parâmetro de área para a filtragem morfológica foi guiada pelo índice espectral NSDVI, conforme explicitado na Figura 23. Para a geração do NSDVI foi necessário, inicialmente, converter as bandas multiespectrais fusionadas (RGB123), para o espaço HSV de cores. Dispondo de cada canal separadamente, foi possível realizar a diferença normalizada entre os canais S e V, considerando as características que as sombras assumem em modelos de cores (propriedade 2). O resultado foi submetido ao método de Otsu (1979), o qual determinou o melhor limiar para segmentar os pixels identificados como sombras pelo NSDVI dos demais alvos. Ao final, tem-se uma imagem binária em que os pixels brancos representam as áreas identificadas como sombras pelo índice. O resultado binário do NSDVI é rotulado e de

cada classe formada, calcula-se a área com base na conectividade de 8 vizinhos. O maior valor de área é selecionado e então utilizado como dado de entrada no algoritmo de detecção morfológica. O refinamento do método foi realizado, com base na intersecção dos pixels contidos no NSDVI, excluindo os pixels de vegetação detectados pelo NDVI, e aplicando ao final o método de Otsu (1979), para a obtenção da máscara de sombras binária.

Figura 23 – Estimativa de área por meio do índice espectral de sombras.



Pode-se destacar que o método proposto apresenta vantagens com relação ao trabalho apresentado por Azevedo (2014), como a automatização do método, excluindo qualquer necessidade de intervenção externa e o emprego de imagens multiespectrais para extrair características de sombras em modelos de cores. Além disso, a combinação entre atributos espectrais e morfológicos representa um ganho na redução de falsas detecções.

### 3.2.2.1 Avaliação do Método de Detecção

A avaliação da metodologia de detecção será baseada em métricas tradicionais propostas por Congalton (1991) e adotadas nos principais trabalhos de detecção de sombras em imagens de SR, como Tsai (2006) e Adeline et al. (2013). Para o cálculo dessas métricas são utilizados três indicadores:  $P_s$  (taxa de acurácia do produtor),  $U_s$  (taxa de acurácia do usuário) e  $\tau$  (taxa de acurácia global).

$$P_s = \frac{TP}{TP + FN} \quad (29)$$

$$U_s = \frac{TP}{TP + FP} \quad (30)$$

$$\tau = \frac{TP + TN}{TP + TN + FP + FN} \quad (31)$$

onde, segundo Tsai (2006), TP (do inglês *True Positive* ou Verdadeiro Positivo) representa o número de sombras detectadas corretamente; FN (do inglês *False Negative* ou Falso Negativo) representa as áreas de sombras contidas na referência, mas que não foram identificadas pelo método; FP (do inglês *False Positive* ou Falso Positivo) representa as áreas identificadas pelo método, mas que não são sombras e por último, TN (do inglês *True Negative* ou Verdadeiro Negativo) indica o número de pixels considerados corretamente como não sendo sombras.

Os índices são baseados na comparação do resultado pixel a pixel da imagem resultante da detecção, com uma imagem tomada como de referência, chamada de *Ground Truth* (GT). A comparação leva em conta um *buffer* em ambas as imagens, o qual é considerado como um limite de aceitação. Essa tolerância é importante neste caso, pois as imagens tomadas como referência e consideradas como verdades são geradas por um operador humano, sendo um trabalho difícil e oneroso que limita a quantidade de imagens a serem avaliadas e, cujo resultado não é isento de erros.

A taxa de acurácia global reflete, portanto, a sensibilidade do algoritmo em detectar corretamente as sombras, o que contribui para procedimentos de extração/detecção ditos automáticos, como neste trabalho, de modo que os usuários possam verificar a qualidade dos dados obtidos, com base em valores estatísticos e em métricas que permitem validar o processo.


### 3.2.3 Abordagem para a Restauração dos Pixels de Sombras

A restauração da imagem consistiu na última etapa do algoritmo. Nesta etapa, motivados pela efetividade do inpainting na reconstrução de imagens, foi proposto o uso da abordagem híbrida de inpainting, descrita inicialmente por Casaca (2010), adaptando-o para o contexto de imagens multiespectrais, mais especificamente na restauração de sombras. Trata-se de uma abordagem híbrida, pois combina os efeitos benéficos da difusão anisotrópica, equação de transporte e alocação baseada em blocos de pixels para um inpainting automático de imagens danificadas por grandes áreas e com diferentes texturas. Essas características tornam o método adequado para lidar com abordagens complexas, como em restauração de

sombras em imagens com alta resolução espacial, desde que algumas modificações sejam conferidas ao método, conforme será explicado em cada etapa a seguir.

A abordagem realiza primeiramente, a decomposição da imagem original a ser restaurada, com o objetivo de separar as componentes estrutura (*cartoon*) e textura, como descrito anteriormente (Equação 28). No domínio dos dados de SR, principalmente no caso das imagens com alta resolução espacial, a decomposição é benéfica devido à complexidade dos dados, com heterogeneidade de informações e alto grau de detalhamento. Trata-se de uma decomposição não-simultânea, que primeiro obtém uma aproximação para  $u$ , e depois para  $v$ , sendo  $v = f - u$ , onde  $f$  é a imagem a ser restaurada. A aproximação para  $u$  (*cartoon*) é obtida a partir da resolução do modelo de difusão anisotrópico proposto por Barcelos et al. (2003), (para maiores detalhes, veja Barcelos et al. (2003), Barcelos et al. (2005), Casaca e Boaventura, (2008)). No nosso contexto multiespectral, optamos por utilizar todas as bandas, incluindo a pancromática, na decomposição, obtendo assim cinco componentes  $u$  que dispõem apenas das estruturas geométricas das bandas originais. A Figura 24 mostra um exemplo das características obtidas pela decomposição de uma imagem Pléiades. Como pode ser visto, há um ordenamento maior e com menos perturbações no campo de direções da imagem *cartoon* (Figura 24 (d)), do que o campo de direções Da imagem original  $f$  (Figura 24 (b)), e por conter tais característica, mostra-se mais apropriada para o cálculo da orientação dos isófotos e estabelecimento da ordem de preenchimento. Embora a utilização dos isófotos para definir a ordem do preenchimento seja uma abordagem comum na literatura (CRIMINISI et al., 2004; CHEN et al., 2007), estes são calculados a partir da imagem original e não da componente *cartoon*, que possui menos informações. Dessa forma, podem-se evitar efeitos adversos por parte de ruídos e regiões de texturas. O próximo passo consiste em estabelecer um ordenamento para o preenchimento das regiões de sombras, utilizando para isto, um critério de prioridade específico.

Figura 24 – Ilustração das características obtidas pela decomposição da imagem Pléiades 29\_9. (a) Imagem original; (b) campo das direções de uma amostra (em amarelo) de (a); (c) componente *cartoon* de (a) e (d) campo de direções da mesma amostra (em amarelo) de (c).



### 3.2.3.1 Determinação da Prioridade de Preenchimento

Nesta etapa, busca-se estabelecer uma ordem de preenchimento para os pixels que se encontram nas regiões de fronteiras das áreas de sombras a serem reconstruídas. Para isto, utiliza-se a máscara de sombras obtida na etapa de detecção como guia para identificação dos pixels vizinhos. Com base então, nos isófotos determinados por meio da imagem *cartoon* e nos pixels de vizinhanças contidos no contorno  $\partial\Omega$  da região de inpainting  $\Omega$ , a ordem de preenchimento é calculada por (CASACA et al., 2014):

$$P(p) = R(p) \cdot C(p), \quad p \in \partial\Omega \quad (32)$$

onde a medida de relevância  $R(p)$  e termo de confiança  $C(p)$  são dados, respectivamente, por:

$$R(p) = |\nabla(\Delta u_p) \cdot \vec{d}_p|, \quad \vec{d}_p = \frac{\nabla^\perp u_p}{|\nabla^\perp u_p|} \quad (33)$$

$$C(p) = \left( \frac{\sum_{q \in H_m(p) \cap (D - \Omega)} C(q)^{\frac{1}{k}}}{|H_m(p)|} \right)^k \quad (34)$$

onde  $p$  representa o pixel analisado;  $\vec{d}_p$  é dado pelo vetor gradiente ortogonal normalizado de  $u$  em  $p$ ;  $\Delta u_p$  representa o operador laplaciano do campo de direções de  $u$ ;  $\nabla^\perp u_p$  representa o campo de direção normalizado de  $u$ ;  $|H_m(p)|$  é o tamanho do bloco quadrado ( $m \times m$ ) centrado no pixel  $p$ ;  $C(q)$  é inicializado como sendo 1 e  $k$ , o parâmetro regulador. Dessa forma, enquanto que o termo de relevância  $R$  projeta os isófotos presentes na região de contorno  $\partial\Omega$ , preservando assim a evolução de estruturas lineares, o termo de confiança mantém a coerência do preenchimento de  $\Omega$ , ponderando que blocos sintetizados contribuam de forma sistemática no preenchimento.

Vale a pena destacar a importância da acurácia na determinação da máscara de sombras na etapa de detecção, uma vez que ela é usada como guia na determinação da região de contorno e no estabelecimento da ordem de preenchimento. Assim, a presença de falsos positivos na máscara de sombras poderá acarretar em artefatos indesejados na imagem restaurada, pois será entendido pelo algoritmo de inpainting como um dado genuíno da imagem. Além disso, utilizou-se no algoritmo de inpainting, a máscara de sombras dilatada, de forma a expandir o domínio de restauração e garantir que a atribuição da prioridade seja dada aos pixels de vizinhança, evitando qualquer tipo de incoerência por parte da detecção prévia da máscara (regiões de sombras).

### 3.2.3.2 Amostragem Dinâmica Local e Alocação de Blocos

Com a identificação dos pixels com máxima prioridade, o próximo passo consiste em identificar o bloco adequado para o preenchimento. Neste sentido, foi adotado um procedimento de amostragem local, denominado de amostragem dinâmica (CASACA et al., 2014), com o objetivo de manter a coerência de preenchimento, evitando assim que blocos distantes sejam considerados no preenchimento. O método diferencia-se, portanto, da maioria

dos métodos clássicos de inpainting vistos na literatura, os quais adotam como a região de amostragem  $\Phi$ , o complementar do domínio de reconstrução  $\Omega$ , dado por  $\Omega^c$ , isto é, equivalente a toda imagem remanescente, excluindo a região a ser reconstruída. A região de amostragem ( $\Lambda\Omega_p$ ) então, passa a ser determinada localmente, de acordo com cada pixel  $p \in \partial\Omega$  selecionado a partir do critério de prioridade (Equação 29).

A Figura 25 apresenta uma ilustração do esquema de preenchimento pela amostragem dinâmica. A partir da região dinâmica de amostragem (Figura 25 (a))  $H_L(p)$  centrada no pixel de maior prioridade é feita a busca do bloco mais adequado, ou seja, ótimo  $H_m(\hat{q})$  a ser preenchido na região alvo  $\Omega$ , mais especificamente na vizinhança de  $p$ . Para isto, uma medida de similaridade é empregada, a qual denomina-se distância da raiz quadrada dos quadrados médios normalizada (NRMSD, do inglês *Normalized Root Mean-Square Deviation*) dada pela Equação 35.


$$d(p, q) = \frac{\|p - q\|_{\Delta U}}{\sqrt{\|p\|_{\Delta U}^2 + \|q\|_{\Delta U}^2}} \quad (35)$$

onde,

$$\|p - q\|_{\Delta U} = \sqrt{(p - q)^T \Delta U (p - q)}, \quad \|p\|_{\Delta U} = \sqrt{p^T \Delta U p}, \quad \|q\|_{\Delta U} = \sqrt{q^T \Delta U q} \quad (36)$$

com  $\Delta U$  sendo a matriz diagonal definida pelo Laplaciano de  $u: \Delta U_{ii} = \Delta U_{p_i}, p_i \in H_n(p) \cap \Lambda\Omega_p$ . A medida NRMSD compara o bloco fixo  $H_n(p)$ , com todos os blocos candidatos  $H_n(q)$  dentro da região de amostragem  $\Lambda\Omega_p$  (Figura 27 (b)). O bloco ótimo  $H_n(\hat{q})$ , será aquele que minimizar a distância NRMSD entre  $H_n(p)$  e  $H_n(q)$ , para todo  $H_n(q) \in \Lambda\Omega_p$ . A partir do bloco ótimo encontrado, uma pequena região  $H_m(\hat{q})$  é então selecionada como válida para preencher a vizinhança  $H(p)$  de  $p$  (Figura 25 (c)).

Figura 25 - Ilustração do esquema de preenchimento por blocos através da amostragem dinâmica.



Dentre as vantagens de adotar a amostragem dinâmica, destaca-se a eficiência computacional, uma vez que o algoritmo busca apenas os blocos contidos em  $\Lambda\Omega_p$ , ao invés de percorrer a imagem inteira, como as demais abordagens da literatura. Além disso, o fato da janela ser definida em relação ao pixel  $p$ , de maior prioridade, que são atualizados a cada iteração, tem-se uma maior coerência de preenchimento, evitando que pixels distantes da região a ser reconstruída sejam considerados candidatos. Embora até o momento a abordagem tenha sido aplicada em imagens sintéticas e fotográficas, as características de preenchimento local do método o torna apropriado em aplicações de restauração de imagens de SR devido ao custo computacional reduzido, bem como a alta presença de texturas e outras feições de natureza complexa encontradas em imagens urbanas.

#### 4. EXPERIMENTOS, RESULTADOS E AVALIAÇÃO

Este capítulo apresenta os experimentos e os resultados obtidos nas principais etapas descritas do método proposto (Figura 21) que são: o pré-processamento, a detecção e a remoção dos efeitos de sombras. Os resultados e avaliações foram realizadas em duas imagens orbitais, e alguns experimentos foram realizados com diferentes níveis de complexidades para verificar os potenciais de aplicação do método. A comparação com outros métodos propostos na literatura também é apresentada (4.2.1) na etapa de detecção, juntamente com a avaliação quantitativa.

##### 4.1 Pré-processamento

Inicialmente, a conversão das imagens para reflectância aparente foi realizada com o intuito de atenuar variações e interferências referentes ao processo de aquisição das imagens. Ao avaliar visualmente o resultado da conversão, verifica-se uma melhoria em termos de brilho e contraste geral da cena, facilitando a distinção entre os alvos, o que pode ser visto para WV-2 na Figura 26 e PL-1B na Figura 27.

Figura 26 - Resultado da conversão dos NDs para valores físicos. (a) Imagem WV-2 PAN original; (b) Imagem WV-2 PAN corrigida; (c) Composição colorida normal original e (d) Composição colorida normal corrigida.





Figura 27 - Resultado da conversão dos NDs para valores físicos. (a) PL-1B PAN original; (b) PL-1B PAN corrigida; (c) Composição colorida normal original e (d) Composição colorida normal corrigida.



Foi realizada a análise da escala radiométrica em que se encontram os valores das bandas transformados, a fim de avaliar se possíveis artefatos ou inconsistências nos metadados possam ter gerado valores discrepantes no resultado. As estatísticas de todas as bandas em valores de reflectância foram verificadas e estão sumarizados na Tabela 4.

Tabela 4 - Estatísticas das 5 bandas após a conversão para reflectância.

| Bandas                  | WorldView-2 |        |        |              | Pléiades-1B |        |        |              |
|-------------------------|-------------|--------|--------|--------------|-------------|--------|--------|--------------|
|                         | Min         | Max    | Media  | Desv. Padrão | Min         | Max    | Media  | Desv. Padrão |
| <i>Pan</i>              | 0.0000      | 0.8174 | 0.1037 | 0.0658       | 0.0000      | 1.1973 | 0.1173 | 0.0656       |
| <i>B1_azul</i>          | 0.0000      | 0.0435 | 0.0064 | 0.0027       | 0.0000      | 1.1446 | 0.1238 | 0.0447       |
| <i>B2_verde</i>         | 0.0000      | 0.0406 | 0.0063 | 0.0037       | 0.0000      | 1.1919 | 0.1143 | 0.0508       |
| <i>B3_vermelho</i>      | 0.0000      | 0.0716 | 0.0053 | 0.0045       | 0.0000      | 1.2316 | 0.1105 | 0.0608       |
| <i>B4_infravermelho</i> | 0.0000      | 0.1153 | 0.0118 | 0.0097       | 0.0000      | 1.2053 | 0.1336 | 0.0709       |

É possível observar que os valores de reflectância média para as imagens PL-1B são maiores que os valores médios das imagens WV-2, isto ocorre devido ao maior poder de quantização do sensor PL-1B, o que pode explicar também os altos valores máximos


---

Azevedo S. C.

encontrados. De posse das imagens corrigidas e em valores de reflectância, mesmo que aparente, é possível realizar operações aritméticas entre bandas do mesmo sensor ou de sensores diferentes, uma vez que os dados representam valores físicos em uma mesma escala. Com as bandas compatíveis, o próximo passo consistiu na fusão dos dados, necessária para produzir bandas com alta detalhamento e informações espectrais agregadas.

As imagens originais em reflectância foram os dados de entrada para a fusão e os resultados obtidos dos dois métodos testados sobre as imagens WV-2 e PL-1B são apresentados na Figura 28. A Figura 28 (a) corresponde a uma amostra da imagem original WV-2 na composição colorida falsa cor RGB432, sendo (b) e (c) o resultado do método CP e do método GS aplicados sobre ela, respectivamente. Ainda na Figura 28, (d) representa uma amostra da imagem original PL-1B na composição colorida falsa cor RGB432, sendo (e) e (f) o resultado do método CP e do método GS, respectivamente. A representação dos resultados em composição colorida falsa cor evidencia a vegetação, sendo possível também distinguir melhor os alvos urbanos.

Figura 28 - Resultado da fusão aplicados ao conjunto de imagens WV-2 (a-c) e PL-1B (d-f).



Da análise visual nota-se que os métodos de fusão GS e CP forneceram a inserção de detalhes com maior nitidez e semelhança espectral com a imagem original. No entanto, ainda visualmente, é possível notar distorções no resultado do método CP sobre as imagens WV-2, em que as áreas vegetadas aparecem com tons saturados de vermelhos (Figura 28 (b)). No caso dos dados PL-1B, os resultados ficaram visualmente semelhantes e com preservação das cores, se comparadas à imagem original. Isso mostra o maior desempenho e qualidade espectral dos dados proveniente da imagem de maior resolução radiométrica. As métricas que avaliam a qualidade dos resultados de fusão foram calculadas (Seção 2.2.2.3), com base na comparação entre as imagens originais reamostradas e os resultados da fusão, sendo os resultados obtidos apresentados na Tabela 5.

Tabela 5 – Métricas de qualidade para avaliar as distorções dos métodos de fusão CP e GS aplicados sobre as imagens WV-2 e Pléiades-1B.

| Métricas     | WV-2   |        | PL-1B  |        |
|--------------|--------|--------|--------|--------|
|              | PCA    | GS     | PCA    | GS     |
| <b>CC</b>    | 0.8614 | 0.8643 | 0.8874 | 0.8859 |
| <b>RMSE</b>  | 0.0025 | 0.0025 | 0.0269 | 0.0270 |
| <b>ERGAS</b> | 0.0920 | 0.0901 | 0.0567 | 0.0569 |
| <b>UIQI</b>  | 0.8608 | 0.8642 | 0.8874 | 0.8858 |

Considerando os índices calculados, nota-se um comportamento semelhante dos valores obtidos para ambos conjuntos de imagens. Para as imagens WV-2, o método GS mostrou menor discrepância nos índices ERGAS e RMS, seguida de alta correlação (CC) e similaridade (UIQI) entre as imagens fusionadas e originais WV-2 (Tabela 5), o que confirma o resultado da análise visual. No caso da fusão das imagens PL-1B, as métricas demonstraram comportamento bem similar, mostrando que ambos os resultados provenientes dos métodos testados são adequados para a abordagem. Dessa forma, o método de fusão GS foi o selecionado, pois além de apresentar bons índices de qualidade, também evidenciou detalhes na imagem com maior nitidez, preservando características espectrais de ambos os dados.

De posse das imagens pré-processadas, o próximo passo consistiu na aplicação do algoritmo, sendo os resultados apresentados e avaliados para as duas etapas do método proposto: a etapa de detecção e na sequência, a etapa de restauração da imagem original.

## 4.2 Desempenho do Método de Detecção

A fim de avaliar o método proposto e validar a abordagem, um conjunto de 215 imagens foram selecionadas, sendo 118 provenientes da cena WV-2, e 97 da cena PL-1B. Optou-se por trabalhar com recortes de mesma dimensão (300 x 300 pixels), os quais facilitam a avaliação visual dos resultados, além de diminuir o tempo de processamento, especialmente por conta do tamanho das bandas utilizadas, que variam antes e após a fusão de 80 a 138 *megabytes*, no caso das bandas multiespectrais, e de 318 a 619 *megabytes*, no caso da banda pancromática. Além disso, a construção dos GTs sobre os recortes levou menos tempo do que se fosse sobre toda a cena, sendo a única etapa manual do trabalho e a mais onerosa, a qual limitou a quantidade de imagens de entrada. Cada recorte tem um número identificador (ID) associado, o qual é utilizado tanto para leitura dos dados de entrada, quanto na avaliação quantitativa da detecção, em que compara-se o resultado com o GT de mesmo ID, contribuindo para a automatização do algoritmo. O ID é obtido a partir da quantidade de linhas e colunas da imagem e do tamanho de cada recorte. Dessa forma, o ID representa a posição (linha e número da imagem) do recorte na cena. Como após a fusão todas as bandas do mesmo sensor possuem a mesma resolução espacial, tem-se quantidades iguais de recortes para as 5 bandas e os ID's representam recortes de áreas equivalentes.

A avaliação quantitativa do método foi realizada a partir dos índices numéricos discutidos na Seção 3.2.2.1, com o objetivo de entender o comportamento do algoritmo perante o conjunto de dados. O desempenho global médio do algoritmo para ambos os conjuntos de imagens é apresentado na Tabela 6.


Tabela 6 - Valores médios dos índices de acurácia calculados na avaliação quantitativa da detecção.

| Cena                 | Número de Imagens | $P_s$ (%)        | $U_s$ (%)        | $\tau$ (%)       |
|----------------------|-------------------|------------------|------------------|------------------|
| <b>WorldView-2</b>   | 118               | 91,64 $\pm$ 6,83 | 92,48 $\pm$ 4,72 | 94,20 $\pm$ 2,32 |
| <b>Pléiades – 1B</b> | 97                | 86,96 $\pm$ 5,12 | 92,82 $\pm$ 5,39 | 90,84 $\pm$ 2,98 |

Analisando os índices obtidos, verifica-se boa acurácia na discriminação de áreas de sombras por parte do algoritmo, alcançando acurácia global maior que 90% para os dois conjuntos de imagens avaliados. Os índices mostram melhor acurácia da detecção de sombras sobre as imagens WV-2, do que sobre as imagens PL-1B.


Embora nenhum índice tenha apresentado resultados insatisfatórios, menores valores são encontrados para o índice de acurácia do produtor, o qual considera os FN, que são os pixels pertencentes ao GT, mas que não constam no resultado da detecção. Dessa forma,

verifica-se que o método deixou de detectar pixels de sombras, rotulados nos dados de referência. Em contrapartida, a elevada acurácia do usuário mostra a baixa presença de FP, destacando que o método foi capaz de detectar com boa acurácia somente as sombras, com um número reduzido de confusões com outros tipos de alvos. O fato de FN ser maior que FP garante que os pixels extraídos são em sua maioria pertencentes às áreas afetadas por sombras, assegurando que na próxima etapa, apenas as sombras serão restauradas. Com o objetivo de analisar de maneira individualizada e extrair informações do desempenho do algoritmo sobre cada conjunto de dados, a Figura 29 apresenta os índices calculados para o conjunto de imagens da cena WV-2.



O melhor desempenho na detecção sobre as imagens WV-2 foi visto para as imagens 12\_29 e 20\_51, as quais estão apresentadas em destaque na Figura 30. Para estas imagens, o algoritmo alcançou uma acurácia global similar igual a 97,43%. Como pode ser visto na Figura 30 (c) e (f), grandes áreas de sombras projetadas pelos edifícios que constam na imagem foram corretamente identificadas, assim como sombras menores provenientes de residências, pontes e da diferença de nível da rodovia. Alguns alvos com alta reflectância sob sombras não foram detectados, mas como também não foram considerados como sombras na rotulação do GT, contribuíram para a boa performance do método.

Figura 30 - Melhores desempenhos apresentados pelo método sobre as imagens WV-2. (a) Imagem original 12\_29, (b) Resultado da detecção e (c) Resultado sobreposto na composição falsa cor; (d) Imagem original 20\_51, (e) Resultado da detecção e (f) Sobreposição do resultado na composição falsa cor.



O resultado com menor desempenho foi visto para a imagem 44\_31, na qual o algoritmo apresentou acurácia global de 86,02%. Com o intuito de avaliar os motivos da baixa acurácia e apontar as possíveis falhas do algoritmo, uma verificação desse resultado é apresentada na Figura 31, em que mostra-se a composição falsa cor da imagem original no item (a); o GT da imagem em (b); o resultado da detecção em (c) e o resultado sobreposto na composição falsa cor em (d). Embora tenha havido uma correta identificação das maiores sombras projetadas por edifícios, o método deixou de detectar sombras menores, conforme pode ser observado no resultado sobreposto na composição falsa cor original (Figura 31 (d)). Além disso, observa-se resultados fragmentados e falhos, o que acarretou no aumento dos FN e redução da acurácia do produtor, a qual alcançou 72,57%.

A Figura 32 mostra o comportamento dos índices calculados para o conjunto de imagens PL-1B. Pode-se notar que a acurácia global das imagens PL-1B é alta, variando de 82% a 96%. O melhor percentual de acurácia global 96,26% foi encontrado para a imagem 14\_44 (Figura 33) e o pior de 82,47% para a imagem 54\_23 (Figura 34).

Figura 31 - Resultado com menor desempenho do conjunto de imagens WV-2. (a) Composição falsa cor da imagem original 44\_31; (b) GT da imagem; (c) Resultado da detecção e (d) Sobreposição do resultado na composição falsa cor.




Figura 32 - Desempenho da detecção para o conjunto de dados PL-1B.




Figura 33 - Melhor desempenho apresentado pelo método sobre o conjunto de imagens PL-1B. (a) Composição falsa cor da imagem original 14\_44; (b) Resultado da detecção e (c) Resultado sobreposto na composição falsa cor





Figura 34 - Resultado com menor desempenho do conjunto de imagens PL-1B. (a) Composição falsa cor da imagem original 54\_23; (b) GT da imagem; (c) Resultado da detecção e (d) Sobreposição do resultado na composição falsa cor.




Mais uma vez é possível notar menores valores de acurácia do produtor, indicando que o método deixou de detectar pixels de sombras. Objetos com alta reflectância sob sombras são os principais problemas encontrados, pois o método não foi sensível a valores de brilhos

altos, detectando apenas regiões com baixo valor de brilho em uma vizinhança. Outra dificuldade encontrada foi em relação às sombras próprias de edifícios, pois o método não conseguiu identificar em sua totalidade.

Por outro lado, o método apresentou bom desempenho, com um número reduzido de falsos positivos, pois conseguiu distinguir corretamente as sombras verdadeiras dos muitos outros objetos que se confundem com elas na maioria dos métodos baseados em propriedades encontrados na literatura. Dentre os casos mais comuns de confusões, de acordo com Adeline et al. (2013), estão os telhados com baixa reflectância, carros, tipos de asfaltos com baixa resposta, corpo d'água e piscinas. A Figura 35 destaca alguns dos bons resultados obtidos pelo método proposto, evidenciando o acerto do método frente aos erros e pontos críticos de falsas detecções citados. Além disso, dentre as vantagens apresentadas pelo método proposto, está a autonomia da detecção em relação ao usuário e à imagem, uma vez que não há a intervenção externa para definição de parâmetros ou limiares, assim como também não são necessárias quaisquer outras informações além das disponíveis pelas bandas multiespectrais. Dessa forma, os resultados numéricos indicam a viabilidade do método proposto em áreas urbanas densas.

Figura 35 - Exemplo do bom desempenho do método de detecção frente à alvos que se confundem com sombras como (a) carros, (b) piscinas e (c) corpo d'água.



A critério de exemplo dos resultados de detecção, foram selecionados alguns outros recortes mostrando o desempenho do algoritmo, os quais representam os diversos tipos de alvos de área urbana densa, de modo a conterem tipos de sombras com tamanhos e formas diversificadas, como pode ser visto nas Figuras 36 e Figura 37 referentes às cenas do WV-2 e do PL-1B, respectivamente.

Figura 36 - Dois exemplos de resultados da detecção de sombras obtidos sobre imagens WV-2. Primeira linha: (a) Imagem original WV-2 11\_24; (b) Resultado da detecção e (c) GT da imagem. Segunda linha: (d) Imagem original WV-2 29\_27; (e) Resultado da detecção e (f) GT da imagem.





Figura 37 - Dois exemplos de resultados da detecção de sombras obtidos sobre imagens PL-1B. Primeira linha: (a) Imagem original PL-1B 10\_41; (b) Resultado da detecção e (c) GT da imagem. Segunda linha: (d) Imagem original PL-1B 48\_40; (e) Resultado da detecção e (f) GT da imagem.



Com base na análise visual é possível perceber que o algoritmo foi capaz de detectar a maioria dos pixels de sombras, conforme pode ser observado pela comparação entre as imagens originais (Figuras 36 e 37 (a) e (d)) e o resultado binário da detecção (Figuras 36 e 37 (b) e (e)), em que os pixels identificados como sombras representam as áreas brancas e os demais pixels que não são de interesse foram rotulados como fundo (áreas em preto). Nota-se que o método produziu resultados satisfatórios, comprovado pela semelhança visual com os seus respectivos GTs (Figuras 36 e 37 (c) e (f)), principalmente em áreas com alta concentração de objetos antrópicos, identificando desde sombras projetadas por edifícios de pequeno e grande portes, assim como foi capaz de detectar as sombras ocasionadas pela variação de altura da vegetação. Além disso, o bom desempenho do algoritmo para as imagens dispostas na Figura 36 e 37 é confirmado pelos índices calculados e que são apresentados na Tabela 7.

Tabela 7 - Acurácia da detecção nas imagens mostradas na Figura 36 e Figura 37.

| <b>Cena / ID</b>     | <b><math>P_s</math> (%)</b> | <b><math>U_s</math> (%)</b> | <b><math>\tau</math> (%)</b> |
|----------------------|-----------------------------|-----------------------------|------------------------------|
| <b>WV-2 / 11_24</b>  | 96,16                       | 96,72                       | 96,41                        |
| <b>WV-2 / 29_27</b>  | 95,18                       | 94,99                       | 95,93                        |
| <b>PL-1B / 10_41</b> | 95,76                       | 90,70                       | 90,88                        |
| <b>PL-1B / 48_40</b> | 87,54                       | 97,04                       | 89,09                        |

#### 4.2.1 Análise Comparativa da Detecção

As taxas da avaliação quantitativa obtidas para o método proposto foram comparadas com as calculadas para dois métodos de detecção de sombras apresentados na literatura, a detecção por meio do índice espectral de sombras NSDVI e pelo método proposto por Movia et al. (2016). Ambos os métodos avaliados foram escolhidos por serem baseados em propriedades e, portanto, os parâmetros e premissas utilizadas por eles consideram as informações provenientes das imagens multiespectrais, assim como o método proposto. No método de Movia et al. (2016), a banda do infravermelho não é utilizada e a detecção é feita primeiramente com a geração de candidatos pelo índice de corpo d'água (WBI, do inglês *Water Body Index*), sendo refinada posteriormente com o cálculo de componetes principais (CP) e do canal C3 proveniente do modelo de cores C1C2C3.

A Tabela 8 apresenta a comparação das taxas de acurácia média calculadas para os dois métodos de detecção de sombras avaliados, dispostas juntamente com as taxas do método proposto sobre os dois conjuntos de dados.


Tabela 8 - Análise comparativa das taxas de acurácia da detecção para o índice NSDVI, o método de Movia et al. (2016) e o método proposto.

|                 | WorldView2              |                         |                         | Pléiades                |                         |                         |
|-----------------|-------------------------|-------------------------|-------------------------|-------------------------|-------------------------|-------------------------|
| Métodos         | $P_s$ (%)               | $U_s$ (%)               | $\tau$ (%)              | $P_s$ (%)               | $U_s$ (%)               | $\tau$ (%)              |
| <b>NSDVI</b>    | <b>96,51</b> $\pm 6,52$ | 89,53 $\pm 5,78$        | <b>94,86</b> $\pm 3,38$ | 80,19 $\pm 4,92$        | 94,02 $\pm 5,82$        | 88,13 $\pm 2,86$        |
| <b>Movia</b>    | 86,67 $\pm 6,68$        | 81,02 $\pm 12,23$       | 87,53 $\pm 4,44$        | 82,81 $\pm 3,31$        | <b>95,78</b> $\pm 4,44$ | 89,80 $\pm 3,05$        |
| <b>Proposto</b> | 91,64 $\pm 6,83$        | <b>92,48</b> $\pm 4,72$ | 94,20 $\pm 2,32$        | <b>86,96</b> $\pm 5,12$ | 92,82 $\pm 5,39$        | <b>90,84</b> $\pm 2,98$ |

A comparação quantitativa das taxas indica a superioridade na detecção de sombras pelo método proposto. Embora o índice NSDVI tenha apresentado a melhor acurácia global para o conjunto de imagens WV-2, a presença de falsos positivos, apontada pela baixa acurácia do usuário, mostra-se como uma desvantagem em usar somente esse índice para identificar sombras. Já o método de Movia et al. (2016) demonstrou boa acurácia em detectar somente pixels de sombras sobre as imagens PL-1B. No entanto, deixou de detectar áreas de sombras, conforme pode ser visto pelo baixo desempenho em relação ao método proposto, da taxa de acurácia do produtor.


A Figura 38 mostra a comparação dos valores de acurácia global proveniente dos três métodos avaliados para todo o conjunto de imagens WV-2 (Figura 38 (a)) e PL-1B (Figura 38 (b)). Conforme pode ser visto, o método proposto tem bom desempenho sobre os dois conjuntos de imagens, enquanto que os outros dois métodos apresentam-se inconstantes. O NSDVI apresentou bom desempenho para os dados WV-2 e piora para os dados PL-1B, enquanto que o método de Movia et al. (2016) teve comportamento oposto.

Figura 38 – Comparação da Acurácia Global da detecção pelo método proposto com dois métodos existentes na literatura sobre o conjunto de imagens: (a) WW-2 e (b) PL-1B.



Considerando este índice, duas áreas pertencentes a cada conjunto de dados foram avaliadas. A Figura 39 mostra dois casos de desempenho insatisfatórios por parte dos métodos sobre as imagens WV-2, para um melhor entendimento dos principais motivos das falhas ocorridas. O método de Movia et al. (2016) apresentou o pior desempenho para as imagens WV-2, com 68,58% e 74,93% para as imagens 43\_41 e 8\_40, respectivamente. Para as mesmas imagens, o método proposto foi o que apresentou os melhores resultados com 93,51% e 87,04% de acurácia global, enquanto que o NSDVI alcançou 93,13% e 77,80%. Isso pode ser constatado pela sobreposição de todos os resultados (Figura 39 (b) e (d)), em que áreas em amarelo se sobressaem em relação as demais, representadas pela grande quantidade de falsos positivos detectados erroneamente pelo método de Movia. Embora o NSDVI também tenha apresentado falsas detecções, sobretudo em áreas de vegetações arbórea e rasteira da segunda imagem, poucas áreas em azul são vistas, apenas sobressaindo as áreas que não eram comuns aos erros de todos os métodos.

Figura 39 – Análise comparativa de desempenho apresentado pelos métodos. (a) Composição colorida falsa cor da imagem WV-2 43\_41 e (b) Sobreposição dos resultados; (c) Composição colorida falsa cor da imagem WV-2 8\_40 e (d) Sobreposição dos resultados.




A análise comparativa dos resultados sobre a imagem PL-1B 7\_46, mostrado pela Figura 40, mostra maior ocorrência de falsos positivos azuis e amarelos (Figura 40 (b)), referente aos erros apresentados pelos métodos NSDVI e Movia, respectivamente. O método proposto destaca-se novamente pela alta acurácia na detecção, com acurácia global de 95,73%, enquanto que o NSDVI apresentou o menor valor entre os três métodos, igual a 73,74% e o método de Movia et al. (2016) obteve acurácia global de 79,23%.

Novamente, as maiores falhas são vistas sobre áreas de vegetação, em que somente o método proposto apresenta sensibilidade na identificação de sombras nestas regiões. Mesmo que possa haver falhas na construção do GT sobre a vegetação, por ser uma operação manual em áreas críticas e agravadas pela diferença de altura do dossel em que ocorrem múltiplas reflexões e sombras, a comparação visual com a imagem original deixa claro a confusão por parte dos métodos NSDVI e Movia que refletiu na redução dos índices de acurácia.

Dessa forma, destaca-se o bom desempenho do método, que apresentou alta acurácia global e baixas taxas de falsas detecções, sendo sensível às áreas de sombras sobre vegetação, onde os outros métodos falharam. Deve-se ressaltar a vantagem do método proposto em combinar aspectos contextuais dos operadores morfológicos, do que somente as informações espectrais como os outros métodos avaliados, resultando em uma maior sensibilidade e robustez do método.

Figura 40 - Análise comparativa de desempenho apresentado pelos métodos. (a) Composição colorida falsa cor da imagem PL-1B 7\_46 E (b) Sobreposição dos resultados.




### 4.3 Experimentos do Método de Restauração Proposto

Conforme descrito na metodologia (Seção 3.2.3), o próximo passo consiste na reconstrução por meio do inpainting automático. O bom desempenho do método de detecção garante que nesta etapa de reconstrução, que quase todos os pixels a serem reconstruídos pertencerão às regiões de sombras, devido as baixas taxas de falsos positivos obtidos. A principal preocupação neste caso, é com a coerência na reconstrução dos alvos da superfície, com a replicação de padrões de maneira adequada, de modo que o resultado não prejudique posteriores aplicações. Nos testes realizados, procurou-se verificar o desempenho do algoritmo considerando o processo (automático ou não), tamanho da área a ser reconstruída, o tipo de alvo, os parâmetros envolvidos (janela de inpainting e da amostragem) e o tempo de processamento. No caso dos parâmetros empregados no processo de difusão, não houve a necessidade de variação, pois são estabelecidos por formulações matemáticas de modo a maximizar o desempenho do método, sendo mantidos fixos apenas o desvio padrão do ruído  $\sigma = 15$ ; o número de iterações  $Ni_{BBS} = 20$ ; e o passo temporal  $\Delta_t = 0.1$  para todas as bandas, após seleção por meio de critério visual. Além disso, foi adotado a máscara dilatada para todos os experimentos, para garantir que efeitos de penumbra e de pixels de bordas não interferissem no processo de reconstrução.

#### 4.3.1 Experimento 1 – Reconstrução Semi-automática Guiada por Máscara Manual

No primeiro experimento, foram simuladas áreas faltantes em duas imagens para verificar o comportamento da abordagem de inpainting sobre imagens de SR, considerando alvos reais. A Figura 41 apresenta o resultado do primeiro experimento com área simulada. Na primeira imagem (Figura 41 (a)) foram retirados 417 pixels representados por retângulos pretos (Figura 41 (b)), enquanto que na segunda imagem (Figura 41 (d)) foram removidos 968 pixels (Figura 41 (e)), em ambos os casos foram consideradas áreas com padrões geométricos e com textura, de modo a avaliar a consistência da reconstrução.


Figura 41 – Avaliação do desempenho da abordagem sobre feições de textura de SR. (a) e (d) Imagens originais; (b) e (e) Áreas simuladas a serem recuperadas; (c) e (f) Imagens restauradas.



Com base nos resultados obtidos, é possível perceber que a abordagem conseguiu reconstruir as áreas danificadas de maneira satisfatória. Apesar de não serem áreas extensas, o grau de dificuldade foi adicionado pelas próprias feições, com a presença de detalhes como quinas, diferenças de nível e entrelaçamentos. O método conseguiu recuperar, no primeiro caso (Figura 41 (f)), a faixa de passagem amarela seguindo os padrões lineares, com algumas áreas contendo desarmonia quase imperceptível. A restauração da segunda imagem (Figura 41 (f)) se mostrou adequada tanto na reconstrução dos padrões lineares maiores e menores do telhado, quanto em relação à quina da edificação, que apesar de ter uma pequena desconexão, por se tratar de um alvo, o resultado ainda é relevante. Ambas as imagens levaram em torno de 0.5 minuto para atingir o resultado final.


Ainda no enfoque de avaliar a abordagem com uma máscara simulada, a Figura 42 mostra o resultado do inpainting aplicado para duas imagens WV-2 com presença de sombras (Figura 42 (a) e (d)), com o intuito de verificar o comportamento do método sobre feições de SR, considerando uma área reduzida da imagem com duas áreas de sombras cada. Neste experimento, utilizou-se como domínio de inpainting uma máscara gerada manualmente para ambas imagens, contendo 11680 e 9197 pixels de sombras a serem restaurados na primeira e segunda imagem, respectivamente.

Figura 42 – Resultado da reconstrução pelo inpainting guiado por máscara. (a) e (d) Imagens originais; (b) e (e) Domínio de inpainting por máscaras manuais; (c) e (f) Imagens reconstruídas.



Da análise visual dos resultados obtidos pelo inpainting semi-automático (Figura 42 (c) e (f)), é possível perceber que a abordagem conseguiu reconstruir com boa coerência áreas da imagem que estavam sob a presença de sombras. Padrões retilíneos foram mantidos pelo processo de síntese de textura por blocos adotado, como pode ser observado pela replicação de padrões da rodovia, que ocorreu de maneira satisfatória em grande parte de ambas as imagens. A Figura 43 evidencia melhor os detalhes dos resultados da restauração de ambas as imagens, sendo que em (a) e (b) tem-se o detalhamento do antes e depois do resultado destacado pelo retângulo vermelho da Figura 42 (c); em (c) e (d) um zoom da comparação entre a imagem original e a restauração da segunda imagem destacado pelo retângulo amarelo da Figura 42 (f).

Figura 43 – Detalhes da reconstrução apresentada na Figura 42.



Como pode ser visto na Figura 43 (b), o método conseguiu recuperar de forma satisfatória os detalhes da rodovia, como os desníveis de rampas de acesso, vegetações rasteiras e faixas da rodovia. Padrões de textura também foram recuperados de maneira satisfatória, como pode ser visto na Figura 43 (d), como o topo de edifícios e telhados de construções. No entanto, algumas inconsistências podem ser vistas, pela omissão de feições como carros, destacados pelo retângulo amarelo na primeira imagem restaurada (Figura 42(c)) quando comparada com a original (Figura 42 (a)); também houve a replicação errônea de carros, como pode ser notado pelo destaque em vermelho do resultado da restauração da segunda imagem (Figura 42 (f)) que não existiam na imagem original (Figura 43 (d)). Em relação ao tempo de processamento, a primeira imagem com duas grandes áreas de sombras e maior quantidade de pixels levou cerca de 4,5 minutos para ter todos os pixels da máscara restaurados, enquanto que o tempo da segunda foi de 3,9 minutos.

#### 4.3.2 Experimento 2 – Reconstrução Automática das Imagens WV-2 e PL-1B

Este experimento que foi denominado de automático, pelo fato de que a máscara de sombras gerada pelo método de detecção é utilizada como entrada para o algoritmo. O algoritmo realiza a reconstrução de toda a imagem, sem a necessidade de intervenção alguma do operador. Deve-se apenas inserir no início da sua execução, o tamanho do bloco para a síntese de textura e a janela de amostragem para a busca dos blocos similares.

O método foi testado para as duas imagens e as Figuras 44, 45 e 46 apresentam exemplos de resultados obtidos na restauração de imagens WV-2, com áreas em destaques para melhor visualização da restauração (vermelho, verde e amarelo). Vale a pena ressaltar que o método conseguiu reconstruir tanto cada banda individualmente, quanto qualquer composição colorida RGB formada por três bandas. Adotou-se a composição colorida normal para representar todos os resultados obtidos por facilitar a interpretação visual, pois é a composição de como naturalmente os alvos na natureza são vistos.

Figura 44 – Inpainting automático e restauração de imagens WV-2 2\_32. (a) Imagem Original; (b) Imagem restaurada; (c-e) Detalhes da reconstrução.




Figura 45 - Inpainting automático e restauração de imagens WV-2 19\_49. (a) Imagem Original; (b) Imagem restaurada; (c-e) Detalhes da reconstrução.





Figura 46 - Inpainting automático e restauração de imagens WV-2 49\_30. (a) Imagem Original; (b) Imagem restaurada; (c-e) Detalhes da reconstrução.



Ao aplicar o método automático sobre a imagem por completo e analisando os resultados obtidos, verifica-se que muitas das regiões de sombras foram reconstruídas de maneira satisfatória, mantendo os valores de intensidade coerentes. O interesse maior é em recuperar os alvos sob sombras, de forma que o resultado corresponda com a realidade e que a coerência visual da imagem não seja prejudicada. Isso ocorreu em muitas das regiões mostradas, como na recuperação de carros e estacionamento (Figura 44 (c) e Figura 45 (c)), telhados de residências e galpões (Figuras 44 (d) e (e)), ruas e calçadas (Figuras 45 (d), (e) e (e); Figuras 46 (d) e (e)). Em contrapartida, foram observadas incoerências na replicação de informações, como a introdução equivocada de blocos com telhados de edificações sobre o arruamento (Figura 46 (c)). Esse fato ocorreu devido à uma soma de fatores que envolvem o tamanho da área a ser reconstruída, o tipo do padrão envolvido e sua posição no canto da imagem, que inviabiliza a busca de padrões vizinhos e resulta em poucas amostras a serem verificadas pelo algoritmo. Algumas bordas indesejadas também foram introduzidas e visualmente percebidas após a reconstrução (Figura 46 (d)). Ademais, considerando a dificuldade da tarefa, o algoritmo mostrou resultados adequados em muitos dos casos das imagens WV-2. Nas Figuras 47, 48 e 49 são apresentados exemplos dos resultados obtidos para imagens PL-1B, juntamente com seus detalhes da reconstrução.

Figura 47 - Restauração da imagem PL-1B 8\_8 pelo inpainting automático. (a) Imagem Original; (b) Imagem restaurada; (c-e) Detalhes da reconstrução.




Figura 48 - Restauração da imagem PL-1B 16\_57 pelo inpainting automático. (a) Imagem Original; (b) Imagem restaurada; (c-e) Detalhes da reconstrução.





Figura 49 - Restauração da imagem PL-1B 2\_23 pelo inpainting automático. (a) Imagem Original; (b) Imagem restaurada; (c-e) Detalhes da reconstrução.



Os resultados da reconstrução automática das imagens PL-1B também se mostraram adequados para muitas feições presentes nas imagens, recuperando tanto áreas homogêneas como terrenos (Figuras 47 (e) e 48 (c)) e vias (Figura 49 (c) e (e)), quanto em áreas com diferentes alvos de padrões variados (Figura 47 (c) e (d)). Podem ser percebidas inserções de padrões indevidos, como telhados junto ao nível da via (Figura 49 (c)), que não condizem com a realidade e devem ser evitados em qualquer tipo de aplicação futura.

Em geral, baseado na análise visual, as interferências das sombras reduziram na maioria dos casos analisados, com pouca ocorrência de inconsistências e quase nenhuma de borramentos ou suavizações. Destaca-se a predominância de restaurações adequadas para padrões retilíneos, como vias e telhados homogêneos, em virtude principalmente do método adotar a restauração sobre o componente *cartoon* ( $u$ ), o qual destaca melhor as linhas isocrônicas da imagem. Contudo, resultados satisfatórios também foram encontrados na restauração de grandes áreas de sombras, o que deve ser destacado, pois a maioria dos métodos da literatura tendem a falhar neste quesito.

Os principais parâmetros envolvidos na reconstrução das respectivas imagens mostradas anteriormente estão dispostos na Tabela 9, juntamente com o desempenho do algoritmo em função da área a ser preenchida e o tempo de processamento. Nos seis casos apresentados, as imagens PL-1B foram as que necessitaram de um tempo maior para a reconstrução, não somente pela quantidade de pixels a serem reconstruídos, mas principalmente em função da janela de alocação ser menor, com blocos pequenos sendo preenchidos a cada iteração.

Tabela 9 – Informações dos resultados e parâmetros adotados na reconstrução.


| Satélite/ ID Imagem | Número de pixels reconstruídos | Janela de alocação | Janela de amostragem | Tempo de processamento (min)* |
|---------------------|--------------------------------|--------------------|----------------------|-------------------------------|
| WV-2/ 19_49         | 28594                          | 11                 | 95                   | 3,60                          |
| WV-2/ 49_30         | 38151                          | 11                 | 75                   | 4,18                          |
| WV-2/ 2_32          | 25933                          | 11                 | 95                   | 2,97                          |
| PL-1B/ 8_8          | 28620                          | 7                  | 85                   | 7,09                          |
| PL-1B/ 16_57        | 22845                          | 5                  | 95                   | 13,9                          |
| PL-1B/ 2_23         | 18673                          | 7                  | 85                   | 4,79                          |

\*Incluindo o tempo da detecção

Em relação ao tempo de processamento, o algoritmo apresentou bom desempenho, visto que a maioria das imagens detém uma quantidade elevada de pixels de sombras, chegando em alguns casos, a quase 1/3 da imagem coberta por sombras. Porém, a coerência da restauração varia conforme a quantidade de informações úteis e não contaminadas disponíveis na área de amostragem. Nos casos em que as áreas de sombras passam a ocupar a maior parte da área da imagem, isto é, mais de 2/3 da imagem, o inpainting pode não ser a melhor alternativa. Isto porque deve haver a disponibilidade de informações de vizinhanças não contaminadas para que o processo de reconstrução obtenha êxito, o que é uma limitação enfrentada pelos métodos de inpainting na literatura. Quando minimamente esta condição não é satisfeita, o método torna-se limitado a construir áreas coerentes e com fidelidade à imagem original, conforme mostra a Figura 50, a qual ilustra os casos em que as sombras representam 2/3 da imagem. Portanto, as aplicações subsequentes deverão levar em consideração essa relação entre o tamanho da área a ser reconstruída e a qualidade da reconstrução.

A próxima etapa visa comparar o uso de técnicas de transformação de intensidades, clássicas na literatura de SR, aos resultados obtidos pelo inpainting automático.

Figura 50 – Limitação do método automático de inpainting na reconstrução de imagens com sombras presentes em grande parte da imagem. (a) Imagem original WV-2 36\_31; (b) Imagem original PL-1B 48\_40; (c) e (d) Imagens reconstruídas inadequadamente.



#### 4.3.2.1 Comparação com as Técnicas de Transformação de Intensidades

Diferentemente da abordagem de inpainting, os métodos de transformações de intensidade, como a GC, LC e HM (Seção 2.3.1), consideram os valores de intensidade das regiões de sombras no processo de restauração, mesmo apresentando baixo padrão de respostas. Um relacionamento linear é assumido entre as áreas com diferenças radiométricas, como as regiões de sombras e não sombras, pois estavam sob a mesma condição de iluminação no momento da aquisição da imagem. Com o intuito de verificar as diferenças entre a abordagem de inpainting com as técnicas convencionais de transformação de intensidades utilizadas na remoção de sombras, os três métodos foram implementados, levando em consideração características radiométricas locais no caso do HM e LC, e globais no caso da GC. Nas Figuras 51 e 52 apresenta-se a comparação visual entre as técnicas, com ambas figuras mostrando em (a) a imagem original com sombras e, de (b) até (e) apresentam-se os resultados obtidos pelas seguintes técnicas: CG, LC, HM e do inpainting automático proposto.

Figura 51 – Comparação com técnicas de melhoria de intensidade. (a) Imagem original WV-2 19\_49; (b) Imagem restaurada pela CG, (c) pela LC, (e) pelo HM e (e) pelo inpainting





Figura 52 - Comparação com técnicas de melhoria de intensidade. (a) Imagem original PL-1B 8\_8; (b) Imagem restaurada pela GC, (c) pela LC, (d) pelo HM e (e) pelo inpainting.



Na análise comparativa dos resultados apresentados, nota-se visualmente, que as técnicas de transformação de intensidades não promoveram a visibilidade das informações sob sombras de maneira plena e satisfatória. A partir dos detalhes apresentados na Figura 53, pôde-se observar que embora alguns alvos possam ser percebidos, principalmente pelo método de HM, o discernimento das feições sob sombras ficou restrito, mesmo após a restauração. Por outro lado, os métodos de transformação de intensidade não adicionaram nenhum artefato à cena durante o processo de melhoria, mostrando fidelidade dos objetos restaurados em relação à imagem original. Nota-se, por exemplo, a incoerência na replicação de padrões azuis (Figura 53 (e) em vermelho) por parte do inpainting, que não fazem parte da cena original, como pode ser observado na comparação com o resultado do HM (Figura 53 (d) em vermelho).

Um outro ponto a ser destacado é que embora a melhoria da visualização não seja efetiva por parte das técnicas de transformação de intensidades, essas não possuem limitação em relação a reconstrução de imagens tomadas em quase sua totalidade por sombras de grandes extensões. A Figura 54 mostra os diferentes resultados alcançados na reconstrução da imagem WV-2 36\_31 pelas técnicas de transformação de intensidades.

Figura 53 – Detalhes da comparação entre os resultados das técnicas de restauração extraídos da Figura 50 (a-e) em amarelo e de 51 (a-e) em vermelho.





Figura 54 - Reconstrução de áreas extensas de sombras pelos métodos de transformação de intensidades. (a) Imagem original WV-2 36\_31; resultado da restauração por: (b) GC, (c) LC e (d) HM.




Apesar de não alcançarem uma restauração completa da imagem, é possível notar principalmente pelo método de HM (Figura 54 (d)) detalhes como arruamentos, telhados e carros, que antes não eram perceptíveis na presença de sombras e que o inpainting não foi capaz de resolver, como pode ser visto na Figura 50 (c), apresentada anteriormente. Contudo, o resultado bastante ruidoso dos métodos de transformação de intensidades, pode causar interferências e prejudicar subsequentes aplicações automáticas que necessitem das informações sem sombras.

#### 4.3.2.2 Avaliação dos Resultados da Restauração

Após a remoção dos efeitos das sombras, a avaliação dos resultados obtidos foi realizada de forma qualitativa e quantitativa. Na análise qualitativa, uma inspeção visual sobre alvos que são comuns em imagens de SR foi feita, a qual também considerou os valores de intensidade desses alvos antes e após a restauração. Neste processo, outra imagem Pléiades-1A (PL-1A) adquirida em outra época (Setembro de 2013) foi utilizada. Esta imagem, que abrange uma parte de São Paulo, possui uma região de sobreposição à imagem PL-1B (Figura 55) e foi empregada com o intuito de comparar a veracidade dos valores de intensidade restaurados. Os

dois satélites Pléiades (1A e 1B), chamados de satélites gêmeos, encontram-se na mesma órbita, separados em 180 graus um do outro e possuem configurações idênticas, as quais favorecem a análise e comparação entre eles. Contudo, existe uma grande dificuldade em obter imagens sobre áreas urbanas complexas sem que haja a ocorrência de sombras nas mesmas posições, pois estas são causadas pelos mesmos alvos. Assim, para que a comparação fosse possível, houve a seleção de uma imagem em outra época e também sob condições de iluminação e geometria diferentes.

Figura 55 – Área de sobreposição entre a imagem de referência (PL-1A 2013) e a imagem utilizada nos experimentos (PL-1B 2015).



Na Tabela 10 estão especificadas as principais informações sobre a geometria de aquisição da imagem de referência PL-1A. Dentre as informações, destaca-se o ângulo de elevação solar, que por ser maior que o da PL-1B, resultou em sombras menores. Além disso, a diferença de época do ano da imagem PL-1A, fez com que as direções das sombras ocorressem de maneira distinta. Dessa forma, realizou-se a busca de alvos sob sombras em 2015 (PL-1B), mas que em 2013 (PL-1A) estavam devidamente iluminados. Regiões identificadas com mudança de cobertura durante este período foram desconsideradas da análise.


A Figura 56 apresenta a comparação dos valores de intensidade referente à três alvos comuns em imagens de SR (Vegetação, via asfaltada e telhado de edificação). Para cada alvo selecionado, apresentam-se os valores RGB do mesmo ponto obtido sob o efeito de sombra (Figura 56 (a), primeira coluna), após a sua restauração (Figura 56 (b), segunda coluna) e na imagem de referência sem sombra (Figura 56 (c), terceira coluna). Também, a critério de comparação, apresenta-se na última coluna (Figura 56 (d)) um ponto adicional do mesmo tipo

de alvo sob condições de iluminações normais na imagem de estudo de PL-1B 2015. De forma análoga, a Figura 57 também apresenta a comparação entre os valores de RGB para outros pontos do mesmo tipo de alvos selecionados.

Tabela 10 - Informações sobre a geometria de aquisição da imagem de referência.

| Informações                  | Pléiades-1A   |
|------------------------------|---------------|
| Data de aquisição            | 14/09/2013    |
| Horário                      | 13:21:07.9    |
| Elevação solar               | 53°45'34.95"  |
| Azimute solar                | 46°01'41.31"  |
| Ângulo zenital solar         | 53°18'15.49"  |
| Azimute do sensor            | 180°00'43.60" |
| Ângulo zenital do sensor     | 04°23'16.05"  |
| Ângulo de visada (off-nadir) | 03°58'40.04"  |


Figura 56 – Comparação dos valores de intensidade RGB referente a amostras de pixels de três alvos de SR. (a) Valores RGB em condições de sombras; (b) Valores RGB após a restauração; (c) Valores RGB na imagem de referência sem sombras; (d) Valores RGB para alvos do mesmo tipo sob condições de iluminações normais na imagem 2015.



Os resultados comparativos mostram que após a etapa de restauração, houve um aumento no padrão de intensidade para os três alvos em ambas as figuras comparativas (Figura 56 e 57). Esse aumento não foi aleatório e se assemelhou aos valores RGB da imagem de referência, como também se manteve bem próximo ao padrão de resposta do mesmo tipo de alvo sem sombras, no ponto adicional selecionado na imagem de estudo (última coluna de

ambas as Figuras 56 e 57). O tipo de alvo telhado foi o que apresentou uma maior variação na resposta após a restauração, quando comparado com os valores originais sob sombra. Apesar de ter mostrado um aumento expressivo nos valores RGB, este não foi totalmente compatível com os valores comparativos de referência e nem com o ponto adicional. Essas discrepâncias foram maiores para a primeira figura (Figura 56 (d)), mas também é vista no segundo caso (Figura 57 (d)), e podem estar ligados à variabilidade de resposta desse tipo de alvo em função das condições da superfície, altitude, variações dos ângulos de incidência da radiação, que contribuem com as diferenças da informação espectral captada. No entanto, o padrão característico da assinatura espectral do telhado que para composições de concreto e metal, por exemplo, é de alta reflectância nas bandas do visível (HEROLD et al., 2002) foi mantido. De uma forma geral, verifica-se que os alvos em análise recuperaram o padrão RGB de intensidade após a restauração. Os efeitos das sombras na redução da resposta foram minimizados, e os pixels avaliados demonstraram estar compensados desses efeitos, como base na comparação realizada.

Figura 57 - Comparação análoga à Figura 56 para outros pontos dos mesmos tipos de alvos de SR analisados. (a) Valores RGB em condições de sombras; (b) Valores RGB após a restauração; (c) Valores RGB na imagem de referência sem sombras; (d) Valores RGB para alvos do mesmo tipo da imagem 2015.




O resultado obtido após a restauração demonstrou ter reduzido os efeitos das sombras. Dessa forma, fica comprovado que a imagem restaurada pode ser utilizada em uma série de aplicações. Como forma de avaliar o comportamento de processos subsequentes, alguns

exemplos de aplicações foram gerados e avaliados visualmente, como a classificação (Figura 58) e a geração do índice espectral NDVI (Figura 59).

No caso da classificação, o algoritmo utilizado foi o K-médias, que consiste de um processo iterativo não-supervisionado por pixel. Para isto, é necessária a definição a priori da quantidade de clusters (grupos) a serem formados e o agrupamento de pixels é realizado com base na proximidade espectral com o vetor média dos clusters pré-definidos. Os centros dos clusters são recalculados a cada iteração, a partir dos elementos alocados e o processo repete-se quantas vezes forem necessárias, até que não haja uma mudança significativa nos pixels alocados. Com a análise de agrupamento, procurou-se observar a remoção do sombreamento na classificação não-supervisionada da imagem antes e depois da restauração.

Neste estudo, foram adotadas 50 repetições para o processo iterativo e foram considerados 4 grupos para serem representados no resultado da classificação. Apesar das imagens terem alta variabilidade espectral por parte dos alvos presentes no ambiente urbano, os 4 grupos foram selecionados com o propósito de representar apenas áreas de sombras, área construída, vegetação e telhado. A Figura 58 apresenta o resultado da classificação não supervisionada para duas imagens RGB normal antes (Figura 58 (a) e (e)) e após a restauração de regiões com sombras (Figura 58 (c) e (g)).


Figura 58 – Resultado da classificação não-supervisionada pelo k-médias. (a) Imagem original WV-2 13\_49 e (b) sua classificação; (c) Imagem (a) restaurada e (d) sua classificação; (e) Imagem original WV-2 19\_49 e (f) sua classificação; (g) Imagem (e) restaurada e (f) sua classificação.



Pode-se notar no resultado da classificação das imagens originais (Figura 58 (b) e (f)), que o classificador identificou as sombras presentes na imagem como parte do cluster Tema 1 (vermelho), com uma quantidade elevada de pixels rotulados nesse tema. No entanto, após a correção das imagens, há uma mudança significativa no resultado da classificação (Figura 58 (d) e (h)), principalmente ao que concerne ao tema 1, em que removeu-se padrão de sombras projetadas por edificações e passando a inclusive diferenciar padrões das classes via e construções. Ao observar a classificação da imagem restaurada, é possível notar que o tema 1 manteve-se rotulando pixels com baixo padrão de respostas, mas neste caso, como o sombreamento foi reduzido, passou a considerar pixels escuros de telhado e do arruamento como pertencentes ao tema 1. Vale destacar que nenhum tipo de pós-classificação foi realizado, com o objetivo de avaliar o comportamento do algoritmo em identificar os temas, baseado apenas nos valores de intensidade. A classificação gerou confusões entre asfalto, construções de concreto e telhas pelo classificador, porém, isto é comum na classificação não-supervisionada de área urbanas, em virtude das características semelhantes que os alvos possuem, que dificultam uma boa discriminação, devendo lançar mão de outro tipo de atributo além do espectral. Assim, apenas para efeito de comparação, a classificação demonstrou que os padrões espectrais foram reconstituídos após a restauração da imagem, isto é, houve uma melhoria da informação comprovada através da análise visual da classificação não-supervisionada dos resultados e da imagem original.

A Figura 59 mostra o resultado da geração do índice espectral NDVI antes e após a correção das sombras. É possível notar uma maior ocorrência de valores negativos no NDVI (Figura 59 (c)) calculados a partir das bandas da imagem original, que podem ser imediatamente associados às áreas de sombras, quando essas áreas são comparadas visualmente com a imagem original (Figura 59 (a)). Este comportamento não se observa no NDVI (Figura 59 (d)) calculado a partir das bandas da imagem restaurada, onde fica evidente que há um aumento dos valores de NDVI positivos relacionados às áreas vegetadas da imagem, que foram recuperadas após a restauração, tanto em áreas de vegetação rasteira como arbórea, conforme pode ser visto na área central de vegetação da imagem restaurada (Figura 59 (b)). Além disso, alguns pontos isolados de alto valor de NDVI são observados, sendo que estes são resultantes da restauração de árvores isoladas do ambiente urbano. Já a remoção do sombreamento provocou a minimização das áreas negativas da imagem, as quais passaram a assumir novos valores de NDVI compatíveis a da região em que se encontram, como valores referentes às vias e telhados no NDVI da imagem restaurada. Com isto, é possível concluir que a restauração resultou em valores adequados para os alvos de SR, configurando uma etapa viável para aplicações posteriores.

Figura 59 – Resultado do índice NDVI após a restauração da imagem. (a) Imagem original PL-1B 55\_34; (b) Imagem (a) restaurada; (c) NDVI aplicado às bandas de (a) e (d) NDVI aplicado às bandas de (b).



## 5. CONCLUSÕES E RECOMENDAÇÕES

As sombras representam uma séria interferência na extração de informações a partir de imagens orbitais, sobretudo em áreas urbanas complexas, pois chegam a cobrir mais de 30-35% de toda a imagem. Este trabalho teve como objetivo principal contribuir com uma estratégia automática para a remoção dos efeitos de sombras em imagens orbitais multiespectrais de alta resolução espacial, adquiridas sobre áreas urbanas. O método de detecção foi desenvolvido juntamente com uma abordagem de restauração, ambos de maneira automática e em um único algoritmo, utilizando as informações disponíveis nas imagens de entrada com sombras sem necessidade de dados adicionais.

A primeira etapa dentro do método automático, consiste na identificação das regiões de sombras através da sua detecção. A detecção das sombras foi realizada pelo operador *top-hat* por fechamento de área, em que foram combinadas as características espectrais de sombras fornecidas pelo índice espectral NSDVI, com as características morfológicas da filtragem por atributo, a qual explora relações espaciais de vizinhança (contexto) entre os pixels de sombras e os pixels sob condições normais de iluminação. Para que a combinação de informações espectrais e de contexto fosse possível, foi necessária a conversão da imagem em reflectância aparente e compatibilização da resolução entre as bandas de entrada, por meio da fusão entre elas. Tais processos consolidaram a etapa de pré-processamento das imagens. O método de fusão por transformação GS foi o que proporcionou melhor nitidez no detalhamento dos objetos em ambos conjuntos de dados avaliados. Além disso, assim como o método de CP, mostrou alta similaridade espectral representada pelos índices de correlação, com baixa discrepância entre o resultado da fusão e as bandas originais, mostrado pelo baixo valor calculado para os índices ERGAS e RMSE.

Para a detecção das sombras de maneira automática, o algoritmo de Otsu (1979) foi empregado sobre o resultado da filtragem morfológica. Os pixels candidatos às áreas de sombras foram refinados na intersecção com as máscaras espectrais, de modo a gerar a máscara de sombras de cada imagem. Os experimentos realizados sobre um conjunto de 215 recortes de imagens dos satélites WV-2 e PL-1B, mostrou que o método de detecção obteve boa performance, representada pelos índices de acurácia calculados com base nos dados GT gerados. A acurácia global média para o conjunto de dados ficou acima dos 90%, sendo que para as imagens WV-2 e PL-1B o algoritmo alcançou uma média de 94,20% e de 90,84%, respectivamente. Destaca-se ainda a boa acurácia demonstrada pelo método em detectar somente pixels de sombras, evidenciada pela alta acurácia do usuário média de aproximadamente 92% para ambos dados e baixa presença de FP, dentre o conjunto de imagens avaliadas.

Trata-se de um resultado expressivo no estado da arte da detecção de sombras, pois a maioria dos métodos possuem ressalvas em relação a confusões com alvos de baixo padrão de resposta. A utilização das informações espectrais proporcionou um ganho em relação à abordagem proposta anteriormente, visto que aumentou a discriminação de sombras em relação aos demais alvos e contribuiu para a automatização do método. Em contrapartida, o método deixou de detectar alguns pixels de sombras, principalmente das imagens PL-1B, as quais apresentaram uma taxa de acurácia do produtor média de aproximadamente 87%. Esse resultado não se consolida em uma desvantagem do método, de um lado porque a taxa ainda assim é satisfatória, de outro porque o fato de FN ser maior que FP garante dentre os pixels detectados pelo método, que a maioria pertença às regiões de sombras e que serão restaurados.

A comparação com outras abordagens, também mostrou a robustez do método na detecção de sombras. A superioridade foi constatada pelas altas taxas de acurácia global média obtidas pelo método para ambos os conjuntos de imagens. O NSDVI mostrou boa sensibilidade a grande parte dos pixels de sombras, ao custo de um número maior de confusões. Já o método de Movia et al. (2016), apesar de demonstrar melhor acurácia do usuário sobre as imagens PL-1B, não apresentou taxas expressivas de acurácia global, quando comparado à regularidade das taxas do método proposto. A análise comparativa dos resultados mostrou também a capacidade do método proposto em separar as sombras sobre vegetação, diferentemente das outras abordagens avaliadas, que apresentaram confusões nessas áreas.

A qualidade com que as sombras foram detectadas pelo método automático proposto garantiu que as máscaras de sombras geradas, pudessem ser utilizadas sem problemas como guia no processo de inpainting. Nos testes não automáticos, com o intuito de verificar o comportamento do inpainting sobre feições de SR, a abordagem reconstruiu de maneira satisfatória áreas com texturas como telhados, assim como manteve a coerência na recuperação de quinas de edificações e em padrões lineares como as vias. Ainda de maneira não automática, duas grandes áreas de sombras também foram reconstruídas com boa coerência, apesar de algumas inconsistências terem ocorrido, como a omissão de veículos constantes na via.

Visto a viabilidade do método na restauração de sombras demonstrada pelos testes não automáticos, a sua aplicação de maneira automática foi vislumbrada para a recuperação de todos os pixels detectados como sombras no conjunto de imagens utilizadas. Os experimentos demonstraram que a combinação de difusão anisotrópica, síntese de textura e amostragem dinâmica conseguiram recuperar muitas das regiões de sombras de maneira satisfatória, mantendo coerente os valores de intensidade. Feições que encontravam-se sob sombras foram reconstruídas, incluindo telhados, áreas de vegetação, vias, carros e calçadas. Com base na

análise visual, as interferências das sombras reduziram na maioria das imagens apresentadas, com pouca ocorrência de inconsistências e quase nenhuma de borramentos ou suavizações. Além disso, a adoção das bandas multiespectrais na decomposição da imagem e para o estabelecimento da ordem de preenchimento se mostrou adequada, mantendo a coerência dos isófotos da imagem, visto pela reconstrução adequada de padrões lineares. Deve-se ressaltar que os valores de intensidade se mostraram adequados, visto as comparações estabelecidas entre os valores de RGBs com a imagem de referência obtida. Além disso, não encontra-se na literatura este tipo de comparação e análise realizadas aqui, visto a dificuldade em se obter imagens sem sombras para serem utilizadas como referência. A viabilidade do método também foi verificada em aplicações subsequentes como a classificação da imagem e a obtenção do índice espectral NDVI. Quando comparou-se visualmente as aplicação antes e após a restauração, os resultados mostraram que valores de intensidade obtidos após a restauração foram compatíveis com alvos da imagem sem os efeitos de sombras, demonstrando a remoção dos efeitos das sombras pelo método.

Embora tenha apresentado bons resultados na restauração de sombras alongadas e projetadas por alvos heterogêneos, o método possui algumas limitações. Devido o processo de inpainting realizar a replicação por blocos com base nas informações de vizinhança, o método mostra-se inadequado para os casos mais drásticos em que as sombras representam a maior parte da imagem, pois acabam replicando padrões de maneira incorreta pela falta de informações disponíveis.

A avaliação comparativa com as três técnicas de transformação de intensidades implementadas, mostrou que a restauração pelo inpainting proporcionou maior detalhamento e discernimento de feições. O método de HM, dentre os outros avaliados (GC e LC), foi o que apresentou os melhores resultados, tornando perceptíveis alguns detalhes que antes estavam sob sombras, mas ainda aquém do inpainting. Para os casos em que o inpainting não conseguiu realizar a restauração de forma plena, como em imagens com grandes áreas de sombras, o HM se mostrou mais adequado. Nestes casos, o HM conseguiu promover a visualização de feições como arruamentos, telhados e carros, mostrando fidelidade dos objetos restaurados em relação à imagem original. No entanto, a restauração apresenta-se mais ruidosa e pode prejudicar seu uso, dependendo da aplicação, pois a qualidade de reconstrução fica comprometida.

A principal vantagem observada no método proposto para remoção de sombras é a automaticidade em realizar a tarefa, além de utilizar apenas como dados de entrada, as informações provenientes de bandas multiespectrais, o que a estende para outras aplicações que necessitem da remoção de sombras. A automatização deve ser destacada, principalmente ao que

concerne os métodos de inpainting, que na maioria dos casos são guiados por abordagens manuais ou semi-automáticas. Vale a pena ressaltar, que o estudo demonstrou a viabilidade do inpainting na reconstrução de áreas largas de sombras, dentro da limitação comentada e que envolvem diversos tipos de feições com texturas. Embora existam na literatura outras abordagens de inpainting para sombras, devido a dificuldade da tarefa de restauração, essas técnicas geralmente consideram para restauração apenas regiões homogêneas da imagem, o que minimiza a complexidade do problema.

Para trabalhos futuros, recomenda-se a expansão e avaliação do método para outros tipos de imagens, como por exemplo, as imagens aéreas obtidas por VANT. Deve constar também em próximos estudos, a automatização dos parâmetros envolvidos no método de inpainting, como o tamanho das janelas de amostragem e alocação, de forma a obter a melhor configuração para imagens orbitais. A integração das técnicas de intensidade e o inpainting também poderão ser objeto de estudo, de modo que as imagens restauradas pelo HM, por exemplo, sejam utilizadas como informação no cálculo e determinação das prioridades, fazendo que o inpainting passe a considerar como existente as informações ofuscadas pela presença de sombras, ao invés de descartá-las.

## REFERÊNCIAS

- ADELINE, K. R. M.; CHEN, M.; BRIOTTET, X.; PANG, S. K.; PAPARODITIS, N. Shadow detection in very high spatial resolution aerial images: A comparative study. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 80, p. 21-38, 2013.
- AIAZZI, B.; ALPARONE, L.; BARONTI, S.; GARZELLI, A. Quality assessment of pansharpening methods and products. **IEEE Geoscience Remote Sensing Society Newsletter**, v. 161, p. 10–18, 2011.
- AL-NAJDAWI, N.; BEZ, H. E.; SINGHAI, J.; EDIRISINGHE, E. A. A survey of cast shadow detection algorithms. **Pattern Recognition Letters**, v. 33, n. 6, p. 752-764, 2011.
- ALPARONE, L.; LUCIEN W.; CHANUSSOT, J.; THOMAS, C.; GAMBA, P.; BRUCE, L. M. Comparison of pansharpening algorithms: Outcome of the 2006 GRS-S data fusion contest. **IEEE Transactions on Geoscience and Remote Sensing**, v. 45, n. 10, p. 3012-3021, 2007.
- ARÉVALO, V.; GONZÁLEZ, J.; AMBROSIO, G. Detecting Shadow QuickBird satellite images. **Proceedings...** ISPRS Commission VII Mid-term Symposium Remote Sensing: From Pixels to Processes. Enschede, Netherlands, 2005.
- ASAI, H.; AARAB B, A.; BELLOUKI, M. Shadow elimination and vehicles classification approaches in traffic video surveillance context. **Journal of Visual Languages and Computing**, v. 25, p. 333–345, 2014.
- AZEVEDO, S. C. **Detecção e restauração de áreas sombreadas em imagens digitais de alta resolução espacial**. Dissertação (Mestrado em Ciências Cartográficas) – Presidente Prudente. 2014. 99 f.
- BARCELOS, C.A.Z.; BOAVENTURA, M.; SILVA, E.C. A well-balanced flow equation for noise removal and edge detection. **IEEE Transactions on image processing**, v. 12, n. 7, p. 751-763, 2003.
- BARCELOS, C.A.Z.; BOAVENTURA, M.; SILVA J.R.; SILVA, E.C. Edge detection and noise removal by use of a partial differential equation with automatic selection of parameters. **Computational & Applied Mathematics**, v. 24, n. 1, p. 131-150, 2005.
- BELWARD, A. S.; SKØIEN, J. O. Who launched what, when and why; trends in global land-cover observation capacity from civilian earth observation satellites. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 103, p. 115-128, 2015.
- BENEDIKTSSON, J.A.; PESARESI, M.; AMASON, K. Classification and feature extraction for remote sensing images from urban areas based on morphological transformations. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, n. 9, p. 1940-1949, 2003.
- BENEDIKTSSON, J. A.; BRUZZONE, L.; CHANUSSOT, J.; MURA, M. D.; SALEMBIER, P.; VALERO, S. Hierarchical analysis of remote sensing data: Morphological attributes profiles and binary partition trees, **Proceedings..** of 10th Int. Symp. on Mathematical Morphology (ISMM 2011), P. Soille, G. K. Ouzounis, and M. Pesaresi, Eds., Intra, Lake Maggiore, Italy, 2011,

- BERTALMIO, M.; SAPIRO, G.; CASELLES, V.; BALLESTER, C. Image Inpainting. **Proceedings...** Computer Graphics, SIGGRAPH, p. 417-424, 2000.
- BERTALMÍO, M.; VESE, L.A.; SAPIRO, G.; OSHER, S. Simultaneous structure and texture image inpainting. **IEEE Transactions in Image Processing**, v. 12, p. 882–889, 2003.
- BLASCHKE, T.; HAY, G.J; KELLY, M.; LANG, S.; HOFMANN, P.; ADDINK, E.; FEITOSA, R. Q.; MEER, F. M.; WERFF, H.; COILLIE, F.; TIEDE, D. Geographic Object-Based Image Analysis – Towards a new paradigm. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 87, p. 180–191, 2014.
- BORNEMANN, F.; MÄRZ, T. Fast image inpainting based on coherence transport. **Journal of Mathematical Imaging and Vision**, v. 28, p. 259–278, 2007.
- BRAGA, R.; CARVALHO, P. F. **Cidade: espaço da cidadania**. Pedagogia cidadã: cadernos de formação: ensino de Geografia. São Paulo: UNESP-PROPP, p. 105-120, 2004.
- BREEN, E.J.; JONES, R. Attribute openings, thinnings, and granulometries. **Computer Vision and Image Understanding**, v. 64, n. 3, p. 377–389, 1996.
- CALVETTI, D.; SGALLARI, F.; SOMERSALO, E. Image inpainting with structural bootstrap priors. **Image and Vision Computing**, v. 24, 782–793, 2006.
- CASACA, W. C. O. **Restauração de Imagens Digitais com Texturas utilizando Técnicas de Decomposição e Equações Diferenciais Parciais**. Dissertação (Mestrado - IBILCE) – São José do Rio Preto, SP, Brasil. 2010. 192 f.
- CASACA, W. C. O.; BOAVENTURA, M. Decomposição de imagens digitais em cartoon e textura através de uma equação de difusão não linear. **Anais... IV Workshop de Visão Computacional**, v. 4, p. 35-40, 2008.
- CASACA, W. C. O.; BOAVENTURA, M.; ALMEIDA, M. P.; NONATO, L. G. Combining anisotropic diffusion, transport equation and texture synthesis for inpainting textured images. **Pattern Recognition Letters**, v. 36, p. 36-45, 2014.
- CHAVEZ, P.S. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. **Remote Sensing of Environment**, v.24, n.3, p.459- 79, 1988.
- CHEN, J.; ZHU, X.; VOGELMANN, J. E.; GAO, F. JIN, S. A simple and effective method for filling gaps in Landsat ETM+ SLC-off images. **Remote sensing of environment**, v. 115, n. 4, p. 1053-1064, 2011.
- CHEN, Y.; WEN, D.; JING, L.; SHI, P. Shadow information recovery in urban areas from very high resolution satellite imagery. **International Journal of Remote Sensing**, v. 28, n. 15, p. 3249–3254, 2007.
- CHENG, Q.; SHEN, H.; ZHANG, L.; YUAN, Q.; ZENG, C. Cloud removal for remotely sensed images by similar pixel replacement guided with a spatio-temporal MRF model. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 92, p. 54–68, 2014.

- CHUNG, K.L.; LIN, Y.R.; HUANG, Y.H. Efficient shadow detection of color aerial images based on successive thresholding scheme. **IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 2, p. 671–682, 2009.
- CONGALTON, R.G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v. 37, n. 1, p. 35–46, 1991.
- CORRÊA, R. L. **O espaço urbano**. São Paulo, ed. Ática, 4º edição, 2002.
- CRIMINISI, A.; PEREZ, P.; TOYAMA, K. Region filling and object removal by exemplar-based image inpainting. **IEEE Transactions on Image Processing**, v. 13, n. 9, p. 1200-1212, 2004.
- ĆURIĆ, V.; LANDSTRÖM, A.; THURLEY, M. J.; HENDRIKS, C. L. L. Adaptive mathematical morphology – A survey of the field. **Pattern Recognition Letters**, v. 47, p.18–28, 2014.
- DARE, P. M. Shadow Analysis in High-Resolution Satellite Imagery of Urban Areas. **Photogrammetric Engineering & Remote Sensing**, v. 71, n. 2, p. 169–177, 2005.
- DEMANET, L.; YING, L. Wave atoms and sparsity of oscillatory patterns. **Applied and Computational Harmonic Analysis**, v. 23, n. 3, p. 368-387, 2007.
- DOUGHERTY, E. R.; LOTUFO, R. A. **Hands-on morphological image processing**. Bellingham, Washington – EUA: SPIE – The International Society for Optical Engineering, 2003.
- DU, P.; LIU, P.; XIA, J.; FENG, L.; LIU, S.; TAN, K.; CHENG, L. Remote Sensing Image Interpretation for Urban Environment Analysis: Methods, System and Examples. **Remote Sensing**, v. 6, p. 9458-9474, 2014.
- DUAN, G.; GONG, H.; ZHAO, W.; TANG, X.; CHEN, B. An index based approach on high resolution images. **Proceedings...** International Symposium on Satellite Mapping Technology and Application (ISSMTA2013), p. 6-8, 2013.
- EFROS, A.A.; LEUNG, T.K. Texture synthesis by non-parametric sampling. **Proceedings...**In: IEEE Int. Conf. Computer Vision, p. 1033–1038, 1999.
- FACON, J. **Morfologia Matemática: teoria e exemplos**. Curitiba: PUC, 1996. 295p.
- FAZAN, A. J.; POZ, A. P. D. Predição de Sombras de Edifícios sobre Vias Urbanas com se em Modelos Digitais de Elevações e Dados de Imagens Aéreas de Alta Resolução. **Boletim de Ciências Geodésicas**, Curitiba, v. 14, n. 3, p.350-369, 2008.
- FONSECA, L. M. G.; NAMIKAWA, L. M.; CASTEJON, E. F.; CARVALHO, L. A. S.; PINHO, C. M. D.; PAGAMISSE, A. Image Fusion for Remote Sensing Applications. **Image Fusion and Its Applications: InTech**, p. 153-178, 2011.
- FREITAS, R. Regiões Metropolitanas: uma abordagem conceitual. **Humanae**, v.1, n.3, p. 44-53, 2009.

- FUNKA-LEA, G. D.; STEEDMAN, M. **The Visual Recognition of Shadows by an ActiveObserver**. Dissertation - University of Pennsylvani, Computer and Information Science, 1994. 200 f.
- GAO, J. **Digital analysis of remotely sensed imagery**. New York, NY, USA: McGraw-Hill Professional Publishing, 2008. 439 p.
- GEVERS, T; SMEULDERS, A.W.M. Colour-based object recognition. **Pattern Recognition**, v. 32, pp. 453–464, 1999.
- GONZALEZ, R.C.; WOODS, R.E. **Processamento de Imagens Digitais**. Tradução: Cristina Yamagami e Leonardo Piamonte. São Paulo. 3ª Ed. Peason Prentice Hall, 2010. 624p.
- GONZALEZ-AUDÍCAN, M.; SALETA, J. L.; CATALAN, R. G.; GARCIA, R. Fusion of multispectral and Panchromatic Images Using Improved IHS and PCA Mergers Based on Wavelet Decomposition. **IEEE Transactions on Geoscience and Remote Sensing**. v.42, p. 1291-1299, 2004.
- GULERYUZ, O.G. Nonlinear approximation based image recovery using adaptive sparse reconstructions and iterated denoising-part ii: adaptive algorithms. **IEEE Transaction on Image Processing**, v. 15, n. 3, p. 555–571, 2006.
- HEROLD, M.; GARDNER, M.; HADLEY, B.; ROBERTS, D. The spectral dimension in urban land cover mapping from high-resolution optical remote sensing data. **Proceedings...** In: Symposium on Remote Sensing of Urban Areas, 3, Istanbul, Turkey, 2002.
- HEROLD, M.; GARDNER, M.; ROBERTS, D. A. Spectral Resolution Requirements for Mapping Urban Areas. **IEEE Transactions on Geoscience and Remote Sensing**, v.41, n. 9, p. 1907-1919, 2003a.
- HEROLD, M.; LIU X.; CLARKE, K. C. Spatial metrics and image texture for mapping urban land use. **Photogrammetric Engineering and Remote Sensing**, v. 69, n. 9, p.991-1001. 2003b.
- HEROLD, M.; MENZ, G.; CLARKE, K.C. Remote sensing and urban growth models—demands and perspectives. **Proceedings...** In: Symposium on remote sensing of urban areas, Regensburg, Germany, Regensburger Geographische Schriften, v. 35, 2001.
- HEROLD, M.; ROBERTS, D.; GARDNER, M.; P. Dennison. Spectrometry for urban area remote sensing - Development and analysis of a spectral library from 350 to 2400 nm. **Remote Sensing of Environment**, v. 91, n. 3-4, p. 304-319, 2004.
- HONKAVAARA, E.; MARKELIN, L.; ROSNELL, T.; NURMINEN, K. Influence of solar elevation in radiometric and geometric performance of multispectral photogrammetry. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 67, p. 13-26, 2012.
- HUANG, J.; XIE, W.; TANG, L. Detection of and compensation for shadows in colored urban aerial images. **Proceedings...** In: Intelligent Control and Automation, p. 3098-3100, 2004.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Cidades e Estados do Brasil**. Disponível em: <<https://cidades.ibge.gov.br/brasil/sp/sao-paulo/panorama>>. Acesso em: Novembro 2017.

IRVIN, B.; MCKEOWN, D. Methods for Exploiting the Relationship between Buildings and their Shadows in Aerial Imagery. **Proceedings...** In: Image Understanding and the Man-Machine Interface II, p.1564–1575. 1989.

JACOBSEN, K. High Resolution Satellite Images Systems – Overview. **Proceedings...** In: ISPRS Hannover Workshop High Resolution Earth Imaging for Geospatial Information, v. XXXVI, p. 487-496, 2005.

JAIN, M.; DIMRI, A. P. Efficacy of Filtering Techniques in Improving Landsat SLC-Off Thermal Infrared Data. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 11, n. 1, p. 271-284, 2018.

JENSEN, J. R. **Sensoriamento Remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos – SP: Parêntese, 2009. 598 p.

JENSEN, J. R.; COWEN, D. C. Remote sensing of urban/suburban infrastructure and socioeconomic attributes. **Photogrammetric Engineering & Remote Sensing**, v. 65, n. 5, p. 611-622, 1999.

JIANG, J.; TIAN, Y.; WANG, M.; ZHENG, Y.; YU, T. A Shadow Detection Algorithm for Remote Sensing Images. **Journal of Computational Information Systems**, v. 9, n. 10, p. 3783–3790, 2013.

KE, Y.; IM, J.; LEE, J.; GOING, H.; RYU, Y. Characteristics of Landsat 8 OLI-derived NDVI by comparison with multiple satellite sensors and in-situ observations. **Remote Sensing of Environment**, v. 164, p. 298–313, 2015.

LABEN, C.A.; BROWER, B.V. **Process for Enhancing the Spatial Resolution of Multispectral Imagery using Pan-sharpening**. United States Eastman Kodak Company, Rochester, NY. USPatent 6,011,875. <http://www.freepatentsonline.com/6011875.html>.

LEVINE, M.D.; BHATTACHARYYA, J. Removing shadows. **Pattern Recognition Letters**, v. 26, n. 3, p. 251–265, 2005.

LI, M.; STEIN, A.; BIJKER, W.; ZHAN, Q. Region-based urban road extraction from VHR satellite images using Binary Partition Tree. **International Journal of Applied Earth Observation and Geoinformation**, v. 44, p. 217–225, 2016.

LI, X.; SHEN, H.; ZHANG, L.; LI, H. Sparse-based reconstruction of missing information in remote sensing images from spectral/temporal complementary information. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 106, p. 1-15, 2015.

LI, Y.; SASAGAWA, T.; GONG, P. A system of the shadow detection and shadow removal for high resolution city aerial photo. **Proceedings...** ISPRS Congr, Comm, v. 35, p. 802-807, 2004.

- LI, Y.; YONG, B.; WU, H.; NA, R.; XU, H. An improved top-hat filter with sloped brim for extracting ground points from airborne lidar point clouds. **Remote Sensing**, v. 6, p. 12885-12908, 2014.
- LI, X.; SHEN, H.; ZHANG, L.; ZHANG, H.; YUAN, Q. Dead pixel completion of aqua MODIS band 6 using a robust M-estimator multiregression. **IEEE Geoscience and Remote Sensing Letters**, v.11, n. 4, p. 768–772, 2014.
- LIESENBERG, V. **Análise multi-angular de fitofisionomias do bioma cerrado com dados MISR/Terra**. Dissertação (Mestrado em Sensoriamento Remoto) - INPE, São José dos Campos. 2005. 120 f.
- LILLESAND, T. M.; KIEFER, R. W. **Remote Sensing and image interpretation**. John Wiley & Sons, 6 ed., 2007. 804 p.
- LIN, C. H.; LAI, K. H.; CHEN, J. Y. Patch-based information reconstruction of cloud-contaminated multitemporal images. **IEEE transactions on geoscience and remote sensing**, v. 52, n. 1, p. 163-174, 2014.
- LIU, W.; YAMAZAKI, F. Object-Based Shadow Extraction and Correction of High-Resolution Optical Satellite Images. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 5, n. 4, p. 1296 – 1302, 2012.
- LORENZI, L.; MELGANI, F.; MERCIER, G. Inpainting strategies for reconstruction of missing data in VHR images. **IEEE Geoscience and remote sensing letters**, v. 8, n. 5, p. 914-918, 2011.
- LORENZI, L.; MELGANI, F.; MERCIER, G. A Complete Processing Chain for Shadow Detection and Reconstruction in VHR Images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 50, n. 9, p. 3440-3452, 2012.
- LORENZZETTI, J. A. **Princípios físicos de Sensoriamento Remoto**. Blucher, 1 ed., 2015, 292p.
- MA, H., QIN, Q. AND X. SHEN. Shadow segmentation and compensation in high resolution satellite images. **Proceedings... IEEE IGARSS**, v. 2, p. 1036–1039, 2008.
- MAALOUF, A.; CARRE, P.; AUGEREAU, B.; FERNANDEZ-MALOIGNE, C. A bandelet-based inpainting technique for clouds removal from remotely sensed images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 7, p. 2363–2371, 2009.
- MALLAT, S. **A wavelet tour of signal processing: the sparse way**. Academic press, 2008.
- MATHER, P. M. **Computer processing of remotely-sensed images: an introduction**. 3rd edition, Chichester, England: John Wiley & Sons, 2004, 442 p.
- MATLAB. **MATLAB and Statistics Toolbox**. [S.l.], 2012.

- MAURER, T. How to pan-sharpen images using the gram-schmidt pan-sharpen method – a recipe. **Proceedings...** International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, ISPRS Hannover Workshop, Germany, 2013.
- MENESES, P.R.; ALMEIDA, T. **Introdução ao Processamento de Imagens de Sensoriamento Remoto**. 1 ed. Brasília: UnB/CNPq, v.1, 2012.
- MILTON, E.J. Principles of Field Spectroscopy. **International Journal of Remote Sensing**, 187, 1807-1827. 1987.
- MOURA, Y. M. **Influência da geometria de aquisição de dados sobre o EVI na estação seca em floresta tropical usando dados MISR/TERRA**. Dissertação (Mestrado em Sensoriamento Remoto) - INPE, São José dos Campos, 2012. 116 f.
- MOVIA, A.; BEINAT, A.; CROSILLA, F. Shadow detection and removal in RGB VHR images for land use unsupervised classification. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 119, p. 485-495, 2016.
- MURA, M. D.; BENEDIKTSSON, J. A.; BOVOLO, F.; BRUZZONE, L. An unsupervised technique based on morphological filters for change detection in very high resolution images. **IEEE Geoscience Remote Sensing Letters**, v. 5, n. 3, p. 433–437, 2008.
- MURA, M. D.; BENEDIKTSSON, J. A.; BRUZZONE, L. Modeling structural information for building extraction with morphological attribute filters, **Proceedings..** Image and Signal Processing for Remote Sensing XV - SPIE, v., p. 7477. Berlin, Germany, 2009.
- MURA, M. D.; BENEDIKTSSON, J. A.; BRUZZONE, L. A general approach to the spatial simplification of remote sensing images based on morphological connected filters, **Proceedings...** IEEE International Geoscience and Remote Sensing Symposium, 2011.
- MURA, M. D.; BENEDIKTSSON, J. A.; WASKE, B.; BOVOLO, F.; BRUZZONE, L. Morphological attribute profiles for the analysis of very high resolution images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 48, n. 10, p. 3747 – 3762, 2010.
- NAKAJIMA, T.; TAO, G.; YASUOKA, Y. Simulated Recovery of Information in Shadow Areas on IKONOS Image by Combing ALS Data. **Proceedings...** Asian Conference on Remote Sensing, Kathmandu, November, p. 25–29, 2002.
- NOVO, E. M. L. M. **Sensoriamento Remoto: Princípios e Aplicações**. São Paulo, ed. Edgar Blucher, 4ª edição, 2010. 387p.
- OK, A. O. Automated detection of buildings from single VHR multispectral images using shadow information and graph cuts. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 86, p. 21–40, 2013.
- OTSU, N. A threshold Selection Method from Gray-Level Histograms. **IEEE Transactions on Systems, Man and Cybernetics**, v. 9, n. 1, p. 62-69, 1979.
- PERSELLO, C. **Advanced Techniques for the Classification of very high resolution and hyperspectral remote sensing images**. PhD Dissertation – University of Trento. 2010, 158p.

- PESARESI, M.; BENEDIKTSSON, J. A. A new approach for the morphological segmentation of high-resolution satellite imagery, **IEEE Transaction on Geoscience and Remote Sensing**, v. 39, n. 2, p. 309–320, 2001.
- PINHO, CMD. **Análise orientada a objetos de imagens de satélites de alta resolução espacial aplicada à classificação de cobertura do solo no espaço intra-urbano: o caso de São José dos Campos**. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2005. 180 f.
- POHL, C.; GENDEREN, J. L. V. Multisensor image fusion in remote sensing: concepts methods and applications. **International Journal of Remote Sensing**, v. 19, p. 823–854, 1998.
- POLI, D.; REMONDINO, F.; ANGIULI C, E.; AGUGIARO, G. Radiometric and geometric evaluation of GeoEye-1, WorldView-2 and Pléiades-1A stereo images for 3D information extraction. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 100, p. 35–47, 2015.
- POLIDORO, A. M.; **Detecção de Elementos da Paisagem Urbana em Imagens Aéreas Multiespectrais**. Tese - (Doutorado em Ciências Cartográficas) - Universidade Estadual Paulista, Faculdade de Ciências e Tecnologia de Presidente Prudente, 2007. 177 f.
- POLIDORO, A. M.; FLORES, F. C.; IMAI, N. N.; TOMMASELLI, A. M. G.; FRANCO, C. Automatic Shadow Segmentation in Aerial Color Images. **Proceedings... XVI Brazilian Symposium on Computer Graphics and Image Processing (SIBGRAPI '03)**, 2003.
- PONZONI, F.J.; PINTO, C. T.; LAMPARELLI, R. A. C.; JUNIOR, J. Z.; ANTUNES, M. A. H. **Calibração de Sensores Orbitais**. São Paulo, Oficina de Textos, 2015.
- PONZONI, F.J.; SHIMABUKURO, Y.E.; KUPLICH, T. M. **Sensoriamento Remoto da Vegetação**. São Paulo, 2 ed., Oficina de Textos, 2012.
- QURESHI, M. A.; DERICHE, M.; BEGHDADI, A.; AMIN, A. critical survey of state-of-the-art image inpainting quality assessment metrics. **Journal of Visual Communication and Image Representation**, v. 49, p. 177-191, 2017.
- RICHARDS, A. J. **Remote Sensing Digital Image Analysis: An Introduction**. 5 ed. Canberra, Austrália: Springer-Verlag, 2012, 494 p.
- SALVADOR, E.; CAVALLARO, A.; EBRAHIMI, T. Cast Shadow Segmentation Using Invariant Color Features. **Computer Vision and Image Understand**, v.95, p.238-259, 2004.
- SANIN, A.; SANDERSON, C.; LOVELL, B. C. Shadow Detection: A Survey and Comparative Evaluation of Recent Methods. **Pattern Recognition**, v. 45, n. 4, p. 1684–1695, 2012.
- SARABANDI, P.; YAMAZAKI, F.; MATSUOKA, M.; KIREMIDJIAN, A. Shadow detection and radiometric restoration in satellite high resolution images. **Proceedings... Geoscience and Remote Sensing Symposium (IGARSS'04)**, p. 3744-3747, 2004.

SATELLITE IMAGING CORPORATION. **Apresenta informações sobre grande parte dos satélites de observação terrestres e amostras de imagens.** Disponível em: <<http://www.satimagingcorp.com/>>. Acesso em: 10 maio 2015.

SCHOWENGERDT, R. A. **Remote Sensing: Models and Methods for Image Processing.** Academic Press, 3. ed., 2007, 560p.

SDC Morphology Toolbox for MATLAB v.1.6. **Tutorial.** Naperville, USA. Disponível em <<http://www.mmorph.com/>>. Acesso em: Maio 2015.

SHAHTAHMASSEBI, A. R.; SONG, J.; ZHENG, Q.; BLACKBURN, G. A.; WANG, K.; HUANG, L. Y.; PAN, Y.; MOORE, N.; SHAHTAHMASSEBI, G.; HAGHIGHI, R. S.; DENG, J. S. Remote sensing of impervious surface growth: A framework for quantifying urban expansion and re-densification mechanisms. **International Journal of Applied Earth Observation and Geoinformation**, v. 46, p. 94–112, 2016.

SHAHTAHMASSEBI, A. R.; YANG, N.; WANG, K.; MOORE, N.; SHEN, Z. Review of Shadow Detection and De-Shadowing Methods in Remote Sensing. **Chinese Geographical Science**, v. 23, n. 4, p. 403-420, 2013.

SHEN, H.; LI, X.; CHENG, Q.; ZENG, C.; YANG, G.; LI, H.; ZHANG, L. Missing information reconstruction of remote sensing data: A technical review. **IEEE Geoscience and Remote Sensing Magazine**, v. 3, n. 3, p. 61-85, 2015.

SILVA, A. G. **Uso de árvore de componentes para filtragem, segmentação e detecção de padrões em imagens digitais.** Tese (Doutorado em Engenharia Elétrica), Campinas, SP, 2009. 123 f.

SILVA, G. F.; CARNEIRO, G. B.; DOTH, R.; AMARAL, L. A.; DE AZEVEDO, D. F. Near real-time shadow detection and removal in aerial motion imagery application. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 140, p. 104-121, 2018.

SOILLE, P. **Morphological Image Analysis.** Berlin. Springer-Verlag, 2004. 391p.

SOLOMON, Chris; BRECKON, Toby. **Fundamentos de processamento digital de imagens: uma abordagem prática com exemplos em Matlab.** Tradução: José Rodolfo Souza Rio de Janeiro. 1ª Ed. LTC, 2013. 289p.

SONG, W.; UM, X.; YAN, G.; HUANG, S. Extracting the green fractional vegetation cover from digital images using a shadow-resistant algorithm (SHAR-LABFVC). **Remote Sensing**, v.7, p. 10425-10443, 2015.

TIAN, J.; QI, X.; QU, L.; TANG, Y. New spectrum ratio properties and features for shadow detection. **Pattern Recognition**, v. 51, p. 85-96, 2016.

TOTH, C.; JÓZKÓW, G. Remote sensing platforms and sensors: A survey. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 115, p. 22-36, 2016.

TRIOLA, M. F. **Introdução À Estatística.** Edit. LTC-Livros Técnicos e Cient. Ltda. Rio de Janeiro–Brasil, 1999. 410p.

- TSAI, V. J. D. Automated Shadow Compensation in Color Aerial Images. **Proceedings...** Annual Conference of American Society for Photogrammetry and Remote Sensing, Reno, Nevada, 2006.
- UPDIKE, T.; COMP, C. Radiometric use of WorldView-2 imagery. **Technical Note**, p. 1-17, 2010.
- VINCENT, L. Morphological Area Opening and Closings for Grayscale Images. **Proceedings...** In: Shape in Picture 92, Workshop, Holanda, 1992.
- VUOLO, F.; WAI-TIM, N. B.; ATZBERGER, C. Smoothing and gap-filling of high resolution multi-spectral time series: Example of Landsat data. **International journal of applied earth observation and geoinformation**, v. 57, p. 202-213, 2017.
- WALD, L. Quality of high resolution synthesised images: Is there a simple criterion? Thierry Ranchin and Lucien Wald. **Proceedings...** In: 3<sup>rd</sup> Conference "Fusion of Earth data: merging point measurements, raster maps and remotely sensed images", Sophia Antipolis, France. SEE/URISCA, p. 99-103, 2000.
- WANG, X.; LIU, S.; DU, P.; LIANG, H.; XIA, J.; LI, Y. Object-Based Change Detection in Urban Areas from High Spatial Resolution Images Based on Multiple Features and Ensemble Learning. **Remote Sensing**, v. 10, n. 2, p. 276, 2018.
- WANG, Z.; BOVIK, A. C. A universal image quality index, **IEEE Signal Processing Letters**, v. 9, n. 3, p. 81-84, 2002.
- WANG, Z.; ZIOU, D.; ARMENAKIS, C.; LI, D.; LI, Q. A comparative analysis of image fusion methods. **IEEE Transactions Geoscience Remote Sensing**, v. 43, p. 1391-1402, 2005.
- WENG, Q. Remote sensing of impervious surfaces in the urban areas: Requirements, methods, and trends. **Remote Sensing of Environment**, v. 117, p. 34-49, 2012.
- WOLF, P. R.; DEWITT, B. A. **Elements of Photogrammetry**. 3. ed. Boston: McGraw-Hill, 2000. 608 p.
- WU, J.; BAUER, M. E. Evaluating the effects of shadow detection on Quickbird image classification and spectro radiometric restoration. **Remote Sensing**, v. 5, n. 9, p. 4450-4469, 2013.
- XU, L.; QI, F.; JIANG, R.; HAO, Y.; WU, G. Shadow Detection and Removal in Real Images: A Survey. **Technical Report**. Shangai JiaoTong University, PR China, 2006.
- YAMAZAKI, F.; LIU, W.; TAKASAKI, M. Characteristics of shadow and removal of its effects for remote sensing imagery. **Proceedings...** International Geoscience and Remote Sensing Symposium, IGARSS, Cape Town, South, Africa, 12-17 July, 4, p. 426-429, 2009.
- YUHENDRA; ALIMUDDIN, I.; SUMANTYO, J. T. S.; KUZE, H. Assessment of pan-sharpening methods applied to image fusion of remotely sensed multi-band data.

**International Journal of Applied Earth Observation and Geoinformation**, v. 18, p. 165–175, 2012.

ZHAN, Q.; SHI, W.; XIAO, Y. Quantitative analysis of shadow effects in high-resolution images of urban areas. **International Archives of Photogrammetry and Remote Sensing**, v. 36, n. 8/W27, 2005.

ZHOU, W.; HUANG, G.; TROY, A.; CADENASSO, M. L. Object-based land cover classification of shaded areas in high spatial resolution imagery of urban areas: A comparison study. **Remote Sensing of Environment**, v.113, p. 1769–17, 2009.