

SAMARA CALÇADO DE AZEVEDO

**DETECCÃO E RESTAURAÇÃO DE ÁREAS SOMBREADAS EM
IMAGENS DIGITAIS DE ALTA RESOLUÇÃO ESPACIAL**



Presidente Prudente

2014

SAMARA CALÇADO DE AZEVEDO

**DETECCÃO E RESTAURAÇÃO DE ÁREAS SOMBREADAS EM
IMAGENS DIGITAIS DE ALTA RESOLUÇÃO ESPACIAL**

Dissertação apresentada ao Programa de Pós Graduação em Ciências Cartográficas da Universidade Estadual Paulista – Faculdade de Ciências e Tecnologia – Campus de Presidente Prudente, como parte dos requisitos para obtenção do título de Mestre em Ciências Cartográficas.

Orientador: Prof. Dr. Erivaldo Antônio da Silva

Presidente Prudente

2014

FICHA CATALOGRÁFICA

Azevedo, Samara Calçado.
S---- Detecção e restauração de áreas sombreadas em imagens digitais de alta
resolução espacial / Samara Calçado de Azevedo. - Presidente Prudente: [s.n],
2014
99 f.

Orientador: Erivaldo Antônio da Silva
Dissertação (mestrado) - Universidade Estadual Paulista, Faculdade de
Ciências e Tecnologia
Inclui bibliografia

1. Detecção de Sombras. 2. Melhoria Radiométrica. 3. Morfologia
Matemática. I. Silva, Erivaldo Antônio. II. Universidade Estadual Paulista.
Faculdade de Ciências e Tecnologia. III. Título.

BANCA EXAMINADORA

Erivaldo

Prof. Dr. ERIVALDO ANTONIO DA SILVA
(ORIENTADOR)

Aylton

Prof. Dr. AYLTON PAGAMISSE
(UNESP/FCT)

Rodrigo

Prof. Dr. RODRIGO AFFONSO DE ALBUQUERQUE NOBREGA
(UFMG)

Samara Calçado de Azevedo

SAMARA CALÇADO DE AZEVEDO

Presidente Prudente (SP), 27 de fevereiro de 2014.

Resultado: APROVADO

DEDICATÓRIA

Dedico a Deus em primeiro lugar, aos meus pais Maurílio e Solange, minha irmã Simone e todos que de alguma forma me apoiaram.

AGRADECIMENTO

Agradeço primeiramente a Deus pelo presente da vida, guiando meus caminhos e me concedendo coragem, serenidade, saúde e força para aceitar e compreender seus preceitos para mim.

À minha família, por todo o amor, incentivo e apoio em todas as etapas da minha vida, superando juntos e com paciência os obstáculos encontrados pelo caminho.

Ao professor, orientador e amigo Dr. Erivaldo Antônio da Silva pela confiança, paciência e contribuições no desenvolvimento deste trabalho.

A todos os professores do Departamento de Cartografia pelos ensinamentos durante a graduação e aos professores do PPGCC que contribuíram com a minha formação, em especial ao professor Dr. Maurício Galo pelos dados fornecidos e contribuições na qualificação. Aos membros da banca por aceitar participar e oferecer contribuições ao trabalho.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo auxílio financeiro durante o desenvolvimento do trabalho.

Aos amigos e professores do grupo de pesquisa em morfologia matemática, em especial ao Guilherme pelas várias ajudas e sugestões, ao Thiago pelas contribuições desde a iniciação científica e a Miriam, pelas valiosas contribuições, incentivo, amizade e conversas, sempre regadas a muitos risos. Ao Ignácio Bravo por me receber prontamente na UAH, dando todo o suporte e apoio na realização do estágio de pesquisa na Espanha.

Aos colegas e amigos da sala de permanência do PPGCC, pela troca de conhecimento, incentivo e bate-papos, regados de café e risadas. A todas paquionas, Fernanda, Raquel, Ana, Chaenne, Fernanda Puga, Tayná, em especial Ariane, Bruna, Hérica, Juliane e Maysa, pelo companheirismo, apoio e pelos muitos momentos especiais, desde a graduação.

Aos amigos prudentinos Elen, Marcela, Hellen, Raquel, Ryan e minha prima-amiga Dayane, por compreenderem minhas ausências e proporcionar muitos momentos de descontração e companheirismo nestes anos.

E a todos, que de alguma forma me ajudaram nesta caminhada, meus sinceros agradecimentos!!!

EPÍGRAFE

“O que quer que você faça na sua vida será insignificante, mas é muito importante que você faça, porque ninguém mais o fará.”

Mahatma Gandhi

RESUMO

Novas possibilidades para o mapeamento urbano vêm sendo criadas com o aumento no detalhamento das imagens. A alta resolução espacial, espectral e radiométrica fornecem benefícios na identificação de elementos individuais em áreas urbanas, como casas, árvores, edifícios, entre outros. Contudo, as imagens acabam sofrendo com informações indesejadas ocasionadas por esses objetos elevados, como é o caso das regiões de sombras, responsáveis por influenciar na resposta espectral dos alvos e degradação visual das imagens. Como forma de reduzir as diferenças radiométricas ocasionadas pelas sombras, este trabalho tem como principal objetivo estabelecer uma metodologia capaz de detectar e restaurar sombras em imagens digitais de áreas urbanas de alta resolução espacial. O algoritmo proposto e implementado no *Matlab* utiliza propriedades de operadores morfológicos combinados para detectar as sombras, a partir do baixo padrão de respostas que elas apresentam nas imagens. O *top-hat* por fechamento de área permite realçar as sombras que são detectadas na sequência pela binarização automática. Na etapa de restauração, os objetos definidos pela rotulação da imagem binária são corrigidos pelo *matching* de histograma local, que combina parâmetros estatísticos extraídos de cada região com sua região vizinha de influência. Para análise da qualidade, a avaliação experimental foi realizada com imagens de alta resolução espacial e com alta e média densidade urbana. Os resultados mostraram que a metodologia conseguiu identificar a maioria das áreas de sombras, comprovado pelos índices de completeza e correção calculados, e homogeneizar as diferenças radiométrica ocasionadas por elas. A minimização desses efeitos é importante, pois contribuem com técnicas como a classificação, extração automática de malha viária e a correspondência de imagens.

Palavras Chaves: Detecção de Sombras, Melhoria Radiométrica, Morfologia Matemática, Imagens de Alta Resolução.

ABSTRACT

New possibilities for urban mapping have been created by improved level of detailing in images. High spatial, spectral and radiometric resolution provides advantages in identifying individual elements in urban areas, such as houses, trees, buildings, etc. However, these tall objects often throw up unwanted information as shadows, which influence visual image degradation and the spectral response of targets. This research aims to establish a methodology to detect and restore shadows in high spatial resolution digital images in urban areas in order to reduce radiometric differences caused by shadows.

The proposed algorithm was implemented in Matlab and applies morphological operators based on the low intensity property they present in the images. The black top-hat by area closing is used to highlight shadows detected in the following with automatic binarization. In the restoration step, objects defined by the labelling of binary images are corrected by local histogram matching, which combines statistical parameters extracted from each shadow area and their neighborhood non-shadow areas.

Both qualitative and quantitative analyses were carried out using high resolution images of medium and higher urban density. The results showed the method was able to identify most shadow areas, confirmed by the completeness and correctness index, and reduced radiometric differences caused by shadows. To mitigate these effects is important because they can affect techniques such as classification, change detection, automatic extraction of road networks, and image matching.

Keywords: Shadow Detection, Radiometric Enhance, Mathematical Morphology, High Resolution Images.

LISTA DE FIGURAS

Figura 1. Representação de uma Imagem Digital. (a) Imagem com uma área em destaque (b) seus níveis digitais correspondentes e (c) representação da resolução radiométrica.	21
Figura 2. Evolução da resolução espacial das imagens obtidas por diferentes sensores para uma mesma área	22
Figura 3. Influência do sombreamento na resposta do dossel em função da configuração da visada	24
Figura 4. Exemplo das classificações das sombras.	25
Figura 5. Diferentes contribuições na resposta das áreas de sombras.	26
Figura 6. Geometria fonte-alvo-sensor. (a) Vista perspectiva, (b) vista plana.	27
Figura 7. Exemplo de Elementos Estruturantes (a) com conectividade 4 e (c) com conectividade 8.	30
Figura 8. Exemplo de ínfimo e supremo de dois sinais unidimensionais. (a) Funções f e g unidimensionais (b) ínfimo e supremo das funções.	31
Figura 9. Resultado dos operadores elementares em uma imagem em níveis de cinza: (a) imagem original; (b) imagem erodida e (c) imagem dilatada.	33
Figura 10. Exemplo numérico do processo de erosão. (a) faixa retirada da imagem original; (b) elemento estruturante caixa e (c) resultado da erosão.	33
Figura 11. Decomposição em limiares da imagem f com 4 níveis de intensidade.	37
Figura 12. Exemplo de filtros morfológicos algébricos. (a) imagem original, (b) abertura por área e (c) fechamento por área de quinhentos pixels.	38
Figura 13. Exemplo teórico da transformação <i>top-hat</i> por abertura em um sinal unidimensional.	39
Figura 14. Exemplo teórico da transformação <i>Top-hat</i> por fechamento de um sinal unidimensional.	40
Figura 15. Gradientes Morfológicos da imagem f com um EE caixa 3x3. (a) Imagem binária f ; (b) Gradiente morfológico por erosão com bordas internas detectadas; (c) Gradiente morfológico por dilatação com as bordas externas detectadas; (d) Gradiente morfológico por dilatação e erosão.	42
Figura 16. Exemplo da Binarização de uma imagem. (a) Imagem de 8 bits de intensidade; (b) Histograma da imagem a ser segmentada pelo limiar 128 e (c) Imagem binária resultante. ...	45
Figura 17. Etapas da especificação de histograma.	48
Figura 18. Imagem WorldView-2 pancromática da área urbana de São Paulo e um exemplo do tamanho de um recorte utilizado elucidando os detalhes.	51
Figura 19. Exemplo de imagem aérea utilizada para verificar a metodologia. (a) Imagem RGB original; (b) Recorte 1000x1000 da faixa espectral do vermelho.	52
Figura 20. Fluxograma das etapas envolvidas no desenvolvimento da metodologia.	54

Figura 21. Exemplo da criação das regiões de referência. (a) Imagem original; (b) Detectada pela metodologia; (c) Rotulada em diferentes objetos da imagem; (d) Buffer em branco sobre os objetos em vermelho.	58
Figura 22. Procedimento para o <i>matching</i> entre os histogramas: (a) Referente a uma área de sombra e (b) de sua área vizinha correspondente.	59
Figura 23. Exemplo de metodologias que sofreram com a descontinuidade entre as regiões na restauração. (a) Resultado da metodologia proposta por Dare (2005); (b) Resultado para a metodologia proposta por Wan, King e Li (2012).	60
Figura 24. O efeito da suavização entre as bordas para restauração na imagem original. (a) Região de transição sem e (b) com suavização.	61
Figura 25. Exemplo de recortes da imagem de São Paulo.	62
Figura 26. Ajuste global da média aplicado para as imagens utilizadas. (a) Recorte original e (b) seu histograma; (c) Imagem contrastada e (d) o histograma resultante do ajuste da média.	63
Figura 27. Comportamento da metodologia de detecção em função do limiar de área (em pixels): (a) 5.000; (b) 10.000; (c) 20.000; (d) 25.000; (e) 30.000; (f) 35.0000.	64
Figura 28. Exemplo da etapa de detecção aplicada a um recorte com áreas de sombras. (a) Fechamento por área de 30.000 pixels; (b) <i>Top-hat</i> ; (c) Binarização automática por Otsu.	65
Figura 29. Resultado da abertura de área com limiar de 5 pixels. (a) Imagem Binarizada com ruídos destacados; (b) Imagem Binarizada com os ruídos removidos.	66
Figura 30. Análise qualitativa do resultado da detecção através da comparação visual entre: (a) Recortes originais e (b) Sobreposição das bordas das feições detectadas, nas imagens originais.	67
Figura 31. Exemplos do desempenho do algoritmo frente aos diversos alvos. (a) e (b) Detalhe do sucesso na identificação de pequenas sombras ocasionadas por veículos.	68
Figura 32. Exemplos de dados utilizados para avaliação quantitativa da primeira etapa da metodologia. (a) Imagem original; (b) <i>Ground Truth</i> gerado manualmente; (c) Resultado da detecção.	69
Figura 33. Comportamento dos índices de completeza e de correção para os recortes conforme a Tabela 1.	70
Figura 34. Análise do baixo índice de completeza para o recorte SP-PAN_36_39. (a) Recorte original; (b) Resultado da detecção; (c) <i>Ground Truth</i> e (d) Comparação entre a detectada e o <i>GT</i>	71
Figura 35. Análise do desempenho do método na presença de corpo d'água. (a) Recorte SP-PAN_11_40 original; (b) Resultado da detecção sobreposto ao <i>GT</i>	72
Figura 36. Exemplo da geração do buffer. (a) Imagem original; (b) Resultado da metodologia para a detecção das áreas de sombras e (c) <i>Buffer</i> gerado.	73
Figura 37. Procedimento para o <i>matching</i> local. (a) Objetos identificados individualmente; (b) Área de sombra rotulada e seu respectivo histograma equalizado acumulado e (c) Área de referência e seu histograma utilizado para o <i>matching</i>	74
Figura 38. Resultado da restauração. (a) Recorte original; (b) Resultado da restauração na imagem.	75

Figura 39. Resultado numérico do matching para uma região do recorte. (a) Região identificada em vermelho e seus respectivos valores originais com efeito de sombras dispostos na tabela; (b) Valores obtidos após o <i>matching</i> para a mesma região.....	76
Figura 40. Comparação entre os histogramas de um recorte: (a) antes e (b) depois do <i>matching</i>	76
Figura 41. Resultado do refinamento aplicado às imagens.....	78
Figura 42. Exemplos de recortes da imagem da região urbana de Presidente Prudente, utilizados para a validação da metodologia.....	79
Figura 43. Resultado da metodologia aplicado a um recorte. (a) Fechamento por área de 15.000 pixels; (b) <i>Top-hat</i> ; (c) Binarização automática por Otsu.....	79
Figura 44. Análise qualitativa do resultado da detecção através da comparação visual entre: (a) Recortes originais e (b) sobreposição dos vetores detectados nos recortes originais.	80
Figura 45. Exemplos de dados utilizados para avaliação quantitativa da primeira etapa da metodologia. (a) Imagem original; (b) Ground Truth gerado; (c) Resultado da detecção.	81
Figura 46. Comportamento dos índices de completeza e correção para os recortes conforme a Tabela 2.....	83
Figura 47. Análise do baixo índice de completeza para o recorte PP-PAN_44_24. (a) Recorte original; (b) Resultado da detecção; (c) <i>Ground Truth</i> e (d) Comparação entre a detectada e o GT.....	84
Figura 48. Análise do baixo índice de completeza para o recorte PP-PAN_12_21. (a) Recorte original; (b) Resultado da detecção; (c) Ground Truth e (d) Comparação entre a detectada e o GT.....	85
Figura 49. Análise das regiões de confusão na imagem <i>top-hat</i> antes da binarização.....	86
Figura 50. Obtenção da região de influência para um recorte. (a) Recorte original; (b) Sombras detectadas; (c) Áreas de influência geradas.....	86
Figura 51. Resultado da restauração para um conjunto de recortes.....	87
Figura 52. Comparação para um recorte de seus histogramas: (a) antes do matching e (b) depois.....	88
Figura 53. Resultado do refinamento para recortes de Presidente Prudente.....	89
Figura 54. Resultado da metodologia para imagens aéreas. (a) Recorte original; (b) Resultado do top-hat realçado; (c) Binarização com remoção das áreas menores que 5 pixels.....	90
Figura 55. Análise do resultado da detecção através sobreposição dos vetores detectados nos recortes originais: (a) Banda do Vermelho; (b) Banda do Verde e (c) Banda do Azul.....	91
Figura 56. Resultado da detecção para dois recortes referente à banda vermelha.....	91
Figura 57. Resultado da restauração para dois recortes. (a) Recorte da Figura 53(a); (b) Recorte da Figura 54 (b).....	92
Figura 58. Resultado da restauração pela técnica de correção <i>gamma</i> . (a) Imagem original; (b) Restaurada pela correção <i>gamma</i>	93
Figura 59. Resultado numérico da restauração por correção <i>gamma</i> para uma região do recorte identificada em vermelho e seus respectivos valores corrigidos.....	94

SUMÁRIO

1. INTRODUÇÃO	15
1.1 Considerações Iniciais	15
1.2 Objetivos.....	18
1.2.1 Objetivo Geral	18
1.2.2 Objetivos Específicos	18
1.3 Justificativa	18
2. FUNDAMENTAÇÃO TEÓRICA.....	20
2.1 Conceitos de Imagens Digitais de Sensoriamento Remoto	20
2.2 Fontes de Distorções Radiométrica nas Imagens	23
2.2.1 Características Gerais das Sombras	24
2.3 Processamento Digital de Imagens	28
2.3.1 Processamento Morfológico de Imagens.....	29
2.3.1.1 <i>Conceitos Básicos</i>	30
2.3.1.2 <i>Operadores Elementares</i>	31
2.3.1.3 <i>Filtros Morfológicos</i>	34
2.3.1.4 <i>Transformação Top-hat</i>	38
2.3.1.5 <i>Gradiente Morfológico</i>	41
2.3.2 Limiarização de Imagens	42
2.3.2.1 <i>Método automático de Otsu</i>	43
2.4 Correção Radiométrica de Imagens	45
2.4.1 Especificação de Histogramas	47
2.5 Métricas para Avaliação da Qualidade	48
3. MATERIAIS E METODOLOGIA PROPOSTA.....	51
3.1 Materiais	51
3.2 Metodologia Proposta.....	53
3.2.1 Etapa de Detecção.....	54

3.2.1.1 <i>Formas de avaliação dos resultados da detecção</i>	56
3.2.2 Etapa de Restauração	56
3.2.2.1 <i>Determinação das áreas de referências</i>	57
3.2.2.2 <i>Procedimento para o matching</i>	58
3.2.2.3 <i>Refinamento do método</i>	59
3.3 Comparação com outras técnicas.....	61
4. APRESENTAÇÃO E ANÁLISE DOS RESULTADOS	62
4.1 Experimentos para área urbana de São Paulo	62
4.2 Experimentos para área urbana de Presidente Prudente	78
4.3 Experimentos com imagens aéreas	90
4.4 Comparação da restauração com a correção gamma.....	92
5. CONCLUSÕES E RECOMENDAÇÕES	95
REFERÊNCIAS	98

1 INTRODUÇÃO

1.1 Considerações Iniciais

A demanda crescente de informações sobre a superfície terrestre nos dias atuais, proporcionada principalmente pela facilidade e disseminação dos mapas digitais, tem reflexo direto no desenvolvimento de sensores remotos capazes cada vez mais, de proporcionar imagens com um alto nível de detalhes. Embora as imagens aéreas tenham sido pioneiras, as inovações tecnológicas incorporadas ao Sensoriamento Remoto (SR) orbital permitiram aliar o alto poder de resolução espacial com a periodicidade dos dados. Dessa forma, da mesma maneira que esses dados ampliam as possibilidades de aplicação para os estudos urbanos, novos desafios foram criados tanto para o processamento, quanto para a extração de informação e análises dessas imagens (CARVALHO, 2011; MENESES e ALMEIDA, 2012).

Um dos principais desafios do aumento no detalhamento proporcionado pelas imagens de alta resolução espacial na área urbana é a presença constante de áreas de sombras, ocasionadas pela obstrução da iluminação por objetos elevados sobre a superfície, tendo maiores proporções em cenas urbanas. A literatura aponta muitos efeitos negativos que as sombras podem causar nas imagens. O principal deles, segundo Dare (2005), é a redução ou total omissão de informação da superfície imageada. Consequentemente, elas degradam a qualidade visual das imagens e englobam alvos que na cena estão espacialmente separados. Além disso, podem inviabilizar aplicações como o reconhecimento de objetos, a obtenção de índices espectrais, a classificação e a segmentação de imagens (ADELINE et al., 2013).

Embora, as sombras sejam importantes na interpretação das imagens, fornecendo informações sobre a topografia do terreno, forma e alturas dos objetos, como observado em Irvin e Mckeown (1989). Ao realizar um levantamento dos trabalhos apresentados na última década, é notável o aumento dos desafios proporcionados por elas nas imagens. Os efeitos das sombras não estão restritos somente a imagens de SR. Sanin, Sanderson e Lovell (2011) mostram métodos que necessitam da remoção de sombras em imagens de vídeo. Segundo eles, a principal motivação para esta tarefa tem sido observada para aplicações de vigilância e monitoramento, na qual sombras diminuem o desempenho do reconhecimento e rastreamento automático dos objetos na cena, por classificar incorretamente sombras como objetos. Dessa forma, reduzem a confiabilidade do modelo de reconhecimento e aumentam a probabilidade de perda do controle do sistema. As sombras são inevitáveis mesmo no caso das imagens obtidas por sensores passivos aerotransportados e terrestres, em que se tem um controle maior na

geometria fonte-sensor-alvo e influenciam nos processos posteriores, como a correspondência entre imagens.

Para a remoção dos efeitos ocasionados pelas sombras, duas etapas são necessárias. A primeira trata-se de identificar sua localização na imagem através da detecção. Enquanto a segunda etapa constitui-se da correção dessas áreas de forma a restaurar a textura, com o objetivo de recuperar a informação que foi obstruída devido ao efeito da sombra (ŞEREF, 2010; SHAHTAHMASSEBI et al., 2013).

Os métodos de detecção de sombras em geral, são separados em métodos baseados em modelos e métodos baseados em propriedades. Nos métodos baseados em modelos, a exata localização das sombras na imagem é matematicamente resolvida através de modelos geométricos, que necessitam de informações a priori sobre a fonte de iluminação no instante de aquisição da imagem e conhecimento tridimensional da cena e dos objetos.

A grande vantagem desses métodos, de acordo com o levantamento feito por Adeline et al. (2013) é de proporcionar uma boa acurácia na predição dessas áreas de sombras e também serem independentes das propriedades de reflectância dos alvos. Contudo, o principal problema enfrentado por eles é a dependência direta do resultado em função da qualidade dos dados empregados. Dependendo do modo como informações tridimensionais da cena são obtidas e a utilização de parâmetros de orientação da imagem incorretos, todos os processos subsequentes serão afetados. Alguns exemplos de metodologias que empregam os dados da imagem, combinados com outras fontes de informação podem ser encontrados em Rau, Chen e Hen (2002), Salvador et al. (2004) e Zhan, Shi e Xia (2005).

Existem metodologias, no entanto, que não enfrentam esses problemas, pois fazem somente o uso de informações disponíveis na própria imagem. Os métodos baseados em propriedades possuem hipóteses levantadas de acordo com as características de cor, brilho e baixa luminância que as áreas sombreadas apresentam. O menor valor de radiância em relação as demais áreas da imagem é a principal propriedade que as sombras apresentam (ADELINE et al., 2013). Alguns métodos propostos que exploram essa característica utilizam técnicas simples como a limiarização, características dos modelos de cores e métodos de segmentação. Entretanto, a facilidade na execução desses métodos é limitada, pois estes falham quando existem outros elementos com baixa intensidade de brilho, ou seja, há confusões entre as sombras e feições que possuem respostas radiométricas similares. Referências adicionais sobre o assunto podem ser encontradas em Dare (2005), Tsai (2006), Liu e Yamazaki (2012), Li e Zhang (2014), entre outros.

A detecção de sombras por si só não resolve e nem ameniza os seus efeitos nas imagens. A degradação causada por elas tem sido tratada na literatura por técnicas que promovem uma melhoria radiométrica nessas áreas. Muitos trabalhos utilizam um parâmetro *gamma* para promover o aumento do sinal registrado nas áreas de sombras. Entretanto, ao utilizar o mesmo parâmetro para todas as áreas da imagem ignora-se a existência de diferentes objetos presentes nessa região (Shahtahmassebi et al., 2013).

Uma técnica que proporciona bons resultados para minimizar diferenças radiométricas na mosaicagem e geração de ortofotos é a especificação de histograma, ou em inglês *Histogram Matching*. Esta técnica necessita de dados de referências para aplicação, os quais são facilmente obtidos de faixas adjacentes quando se trata de imagens aéreas. No caso da correção de sombras em imagens orbitais, o *histogram matchig* vem se destacando como mostrado por Dare (2005) e Tsai (2006) como uma solução para minimizar as diferenças radiométricas ocasionadas por elas. Entretanto, uma desvantagem deste método, quando aplicado em imagens orbitais, é a necessidade da utilização de dados de referência, principalmente quando se trata de imagens de alta resolução, pois pelo fato de geralmente serem comerciais e de alto custo, se torna inviável a aquisição de outras imagens para serem utilizadas como referência. Além disso, dificilmente uma nova imagem da mesma região e tomada com o mesmo sensor, não sofrerá com os efeitos das sombras. Outro problema enfrentado é o efeito da penumbra, que por ser uma região de transição entre sombra e iluminação, possuem valores radiométricos um pouco diferente e quando corrigidos, provocam um esbranquiçado nas bordas da região restaurada.

Com base nos principais problemas identificados pela revisão da literatura, este trabalho propõe uma metodologia para detectar e restaurar as sombras em imagens digitais de alta resolução espacial de áreas urbanas. Para tanto, será utilizado o processamento morfológico de imagens (PMI) e o *matching* de histograma. O PMI se destaca, dentre os demais métodos, pois possui ferramentas e propriedades de aplicação, as quais são capazes de detectar padrões escuros (também chamados de vales) nas imagens sem alterar forma ou suas localizações. Assim, operadores morfológicos por subtração, chamados de *top-hats* são utilizados para detectar as sombras, com base na sua principal característica de baixo padrão de resposta em relação às outras áreas da imagem. Com as sombras devidamente identificadas, o *matching* de histograma é implementado com a finalidade de recuperar as informações ofuscadas pela presença de sombras, utilizando para isto, informações locais como dados de referência. Neste caso, as áreas que contem sombras serão corrigidas a partir de fatores radiométricos de uma área vizinha (região de influência). Por fim, o refinamento do método possibilitou a

minimização do efeito da penumbra através da suavização dessas regiões, que poderão ser restauradas na imagem original sem maiores efeitos, servindo de subsídio para posteriores aplicações.

1.2 Objetivos

1.2.1 Objetivo Geral

Com base nos principais problemas encontrados na revisão da literatura, o objetivo geral deste trabalho é propor uma metodologia para detectar sombras e restaurar feições presentes em imagens digitais de alta resolução espacial de áreas urbanas, a partir de um algoritmo abrangente e que possa ser aplicado sem a necessidade de informações extra-imagem.

1.2.2 Objetivos Específicos

- Investigar e testar as propriedades dos operadores morfológicos, bem como a influência de seus parâmetros na identificação de sombras;
- Implementar a metodologia proposta para detecção das sombras e corrigir as diferenças radiométricas causadas por elas através do *matching* de histograma local;
- Avaliar os resultados da detecção qualitativamente por uma análise visual e quantitativamente através de índices de qualidade;
- Verificar o comportamento da metodologia e os resultados para imagens aéreas e orbitais;
- Comparar a restauração por meio de outras técnicas de correção radiométrica.

1.3 Justificativa

A utilização das imagens de SR nos estudos urbanos não é recente e sua importância vem se consolidando, principalmente com o aumento da resolução espacial, que permite a identificação detalhada dos objetos e fenômenos ocorridos na superfície apoiando aplicações de monitoramento e planejamento das cidades. Entretanto, o alto poder de resolução espacial em áreas com densidade urbana elevada, acabou tendo um efeito contrário, resultando numa quantidade acentuada de regiões de sombras que omitem informações e inviabilizam a extração de informação das imagens.

A necessidade em resolver este problema é confirmada pela quantidade de trabalhos que se propõem a identificar e remover os efeitos das sombras nas imagens. Contudo, em todos são observados algum tipo de ressalvas, tanto em relação aos dados empregados, quanto aos efeitos decorrentes da própria característica e hipótese utilizadas. Fato confirmado pelo levantamento feito por Sanin, Sanderson e Lovell (2011) o qual apontaram a falta de uma metodologia robusta nessa tarefa. Além disso, não são observados critérios na determinação de índice que apontam a eficiência e qualidade da detecção.

Estudos sobre os principais problemas envolvidos em remover os efeitos das sombras nas imagens devem ser incentivados, principalmente para o desenvolvimento de metodologias que sejam simplificadas e possíveis de se aplicar em um contexto geral. A morfologia matemática (MM) se destaca neste sentido, pois é considerada uma técnica de processamento e análise de imagem poderosa, sendo capaz de proporcionar soluções para vários problemas, desde que observadas suas propriedades, assim como proposto neste trabalho, que investiga e testa as propriedades dos operadores morfológicos, bem como a influência de seus parâmetros para a identificação das sombras. Além disso, a MM também proporciona ferramentas para delimitar os objetos sem alterar sua forma e posição na imagem, importantes na etapa de restauração da metodologia proposta.

Dessa forma, o trabalho visa contribuir com outras metodologias que são influenciadas de alguma forma, pelos efeitos negativos das sombras em suas aplicações, como por exemplo, a classificação de imagens, a correspondência entre imagens e a obtenção de índices espectrais. Esses fatores acompanhados do avanço tecnológico incorporados aos sistemas computacionais permitem vislumbrar novas técnicas de análises de imagens e contribuir para a automação de seus processos.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Conceitos de Imagens Digitais de Sensoriamento Remoto

O termo Sensoriamento Remoto (SR), segundo Novo (2010) representa o sistema de aquisição da informação de um objeto, a partir de medidas feitas por um sensor, sem que haja contato físico direto com o mesmo. Os sistemas sensores são então os responsáveis por registrar e transformar o sinal das interações entre a radiação eletromagnética e as substâncias que compõem o objeto, na maioria das vezes representado pela superfície do planeta Terra, em informações sobre o meio ambiente. A importância dessas informações impulsionou o desenvolvimento de equipamentos, capazes cada vez mais de recobrir a superfície terrestre e de armazenar ou transmitir para a Terra os dados coletados (MENESES e ALMEIDA, 2012). Atualmente, uma característica das imagens adquiridas por sensores em plataformas aéreas ou orbitais é que eles estão prontamente disponíveis em formato digital, o que torna o conhecimento das propriedades da imagem digital importante, tanto para o seu processamento, quanto para análise desses dados (RICHARDS, 2012).

Uma imagem digital é definida, de acordo com Gonzales e Woods (2010), como uma função bidimensional na forma $f(x, y)$ cujo valor ou amplitude de f nas coordenadas espaciais (x, y) é representado por um número digital (ND), que assume somente valores inteiros positivos. No caso das imagens cujo processo de formação depende da energia eletromagnética refletida pelos alvos, a função $f(x, y)$ é caracterizada por duas componentes: a quantidade de energia eletromagnética incidente sobre a cena e a quantidade que é refletida por esta. Estas componentes são chamadas de *iluminação* e *reflectância* e são denotadas, respectivamente, por $i(x, y)$ e $r(x, y)$, sendo possível representar $f(x, y)$ de acordo com a Equação 1. A natureza de $i(x, y)$ é determinada pela fonte de iluminação, e a de $r(x, y)$ pelas características dos objetos da cena, o que mostra na Equação 3, que a reflectância está entre a absorção total (0) e a reflectância total (1).

$$f(x, y) = i(x, y) * r(x, y) \quad (1)$$

onde

$$0 < i(x, y) < \infty \quad (2)$$

e

$$0 < r(x, y) < 1 \quad (3)$$

As imagens digitais são representadas na forma de um arranjo matricial, composta por um conjunto de elementos de imagem denominado *pixel* (acrônimo do inglês *picture element*), cuja posição é dada por coluna (x) e linha (y). A cada *pixel* é associado um valor de intensidade medido para aquela área. Na Figura 1(a) está apresentada uma imagem digital com uma pequena área selecionada com seus respectivos níveis digitais (ND's) mostrados em (b) dentro da resolução radiométrica (c).

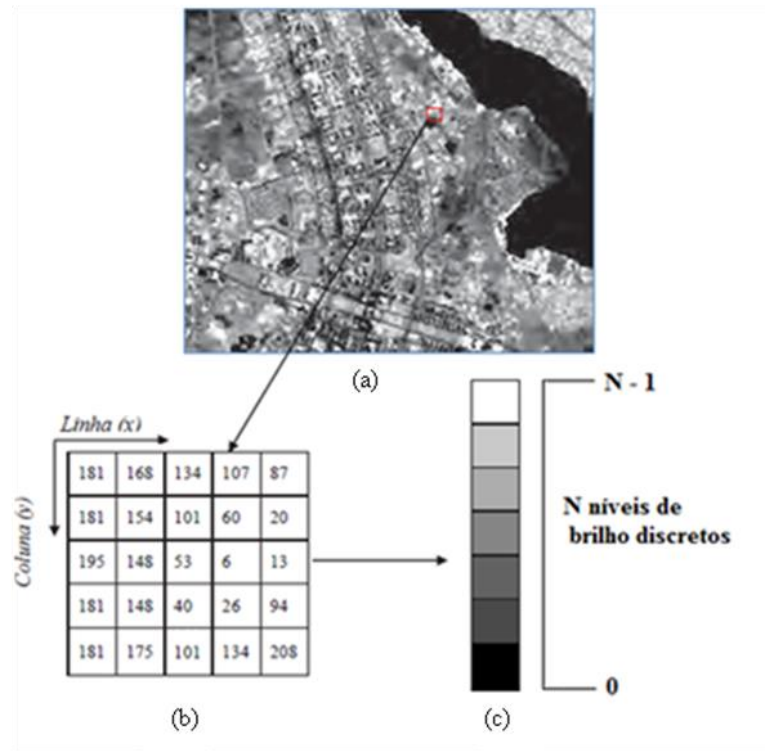


Figura 1. Representação de uma Imagem Digital. (a) Imagem com uma área em destaque (b) seus níveis digitais correspondentes e (c) representação da resolução radiométrica.

Fonte: Adaptada de MENESES e ALMEIDA (2012).

Para que uma imagem seja passível de ser analisada por meio do processamento computacional, de acordo com Pedrini e Schwartz (2008) é necessário que a função $f(x, y)$ passe do espaço contínuo para o discreto. Esse processo é chamado de Digitalização e envolve dois passos: a amostragem e a quantização. A amostragem consiste em discretizar o domínio de definição da imagem em termos espaciais, ou de coordenadas (x, y) , e a quantização consiste na escolha de um número inteiro L de nível de cinza, permitido para cada ponto da imagem. Esse processo de amostragem discreta de uma imagem possui duas características fundamentais para o sensoriamento remoto: a resolução espacial e a resolução radiométrica.

A resolução espacial refere-se a menor área imageada por um sensor, ou seja, trata-se da projeção geométrica do detector na superfície terrestre, determinando o tamanho do menor

objeto que pode ser identificado em uma imagem (MOREIRA, 2011). Pode ser entendida então, como uma medida geométrica em que muitas vezes é erroneamente associada como sinônimo de *pixel*. A Figura 2 exemplifica o aumento da resolução espacial das imagens orbitais obtidas por diferentes sensores. Nota-se que conforme o poder de resolução é aumentado de 30 metros para 60 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. Em geral, a escolha da resolução espacial implica em atender o grau de detalhamento requerido para determinada aplicação. A resolução radiométrica está associada com a capacidade do sistema sensor em detectar as variações da radiância espectral. Quanto maior for o número de níveis de radiância que o detector pode discriminar, maior sua resolução radiométrica. 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. Duas outras resoluções não menos importantes que caracterizam os sistemas sensores são a resolução




Figura 2. Evolução da resolução espacial das imagens obtidas por diferentes sensores para uma mesma área
Fonte: Adaptada de SOUZA (2012).

A resolução temporal se refere ao intervalo de tempo entre a aquisição de duas imagens de uma mesma área, ou seja, com que frequência o sensor revisita e coleta dados de um mesmo alvo. Esse processo de adquirir dados com certa frequência é sem dúvidas fundamentais para acompanhar a evolução ou mudanças que ocorrem na Terra. A resolução espectral por sua vez está ligada ao número e dimensão de intervalos de comprimentos de onda específicos (chamados de banda ou canais) aos quais um instrumento de SR é sensível (JENSEN, 2009). Sensores com grande número de bandas estreitas, situadas em diferentes regiões espectrais tem a capacidade de discriminar melhor as interações entre a energia eletromagnética e os materiais que compõem a superfície terrestre.

A atual evolução dos sistemas sensores, favorecidos pela demanda crescente de usuários e pela competitividade de empresas interessadas em oferecer as melhores tecnologias, trouxe novas possibilidades de mapeamento e análise de imagens. Contudo, a qualidade das imagens não depende somente da qualidade do sensor. Existem muitas fontes de erros que podem degradar as imagens, reduzindo ou até mesmo inviabilizando suas aplicações.

2.2 Fontes de Distorções Radiométrica nas Imagens

Os dados espectrais adquiridos por sensores aéreos ou orbitais podem conter distorções tanto na geometria, quanto na medida dos valores de brilho da imagem, estes chamados de distorções radiométricas. As distorções radiométricas podem ser causadas por uma série de fatores, dos quais os principais são devido às variações na iluminação da cena, características do sistema sensor, geometria de visada, dependência do comprimento de onda e pelos efeitos atmosféricos (RICHARDS, 2012).

As distorções relacionadas a atmosfera são devido ao processo de absorção e espalhamento da energia pelos constituintes atmosféricos (oxigênio, gás carbônico, vapor d'água, ozônio, aerossóis, entre outros), que podem atenuar a trajetória do sinal registrado pelo sensor. Como os sensores são projetados para operar fora das regiões de absorção, o espalhamento torna-se o efeito dominante sobre o sinal, reduzindo a eficiência na identificação dos objetos terrestres. 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. Existem aplicações em que a correção atmosférica não é um fator primordial para melhoria dos dados, sendo preponderante na comparação entre bandas e em análises de imagens da mesma região datadas de períodos diferentes (RICHARDS, 2012).

A maneira como os dados são adquiridos também influencia em diferenças radiométricas nas imagens. Variações na geometria de aquisição da fonte de iluminação e de visada interferem na quantidade de energia captada pelo sensor. Efeitos como o hot spot e vinhete são exemplos da vulnerabilidade das imagens digitais às imperfeições da tomada aérea. O hot spot está relacionado ao efeito de reflexão especular de feições na superfície terrestre, que altera significativamente valores de brilho em certas regiões da imagem aparecendo extraordinariamente claras. No caso do efeito chamado vinhete, as regiões periféricas da imagem aparecem mais escuras em relação ao centro devido ao bloqueio parcial dos raios de luz pelo sistema de lentes (NÓBREGA, 2002). Dessa forma, a reflectância da superfície ser função

então, segundo Liesenberg (2005), não somente das propriedades espectrais e espaciais dos alvos, como também da 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. Assim, de acordo com o exemplo dado pelo autor e disposto na Figura 3, quando maiores proporções de sombras de dossel e solos são vistas pelo sensor (situação 3), há uma diminuição nos valores de reflectância que acabam influenciando numa estimativa equivocada das propriedades dos objetos e interpretação dos dados.

O problema da interferência nas respostas dos objetos por parte das sombras torna-se ainda maior quando imagens de alta resolução espacial de áreas urbanas são adquiridas. O detalhamento da cena aliado a grande quantidade presente de objetos elevados, resulta em uma porção significativa de áreas de sombras na imagem coletada, e com grande parte das respostas dos alvos influenciadas por este efeito. As principais características sobre as sombras e suas influências nas imagens devem ser entendidas, para que soluções de tratamento e atenuação dos seus efeitos possam ser propostas, contribuindo para a interpretação correta dos dados.

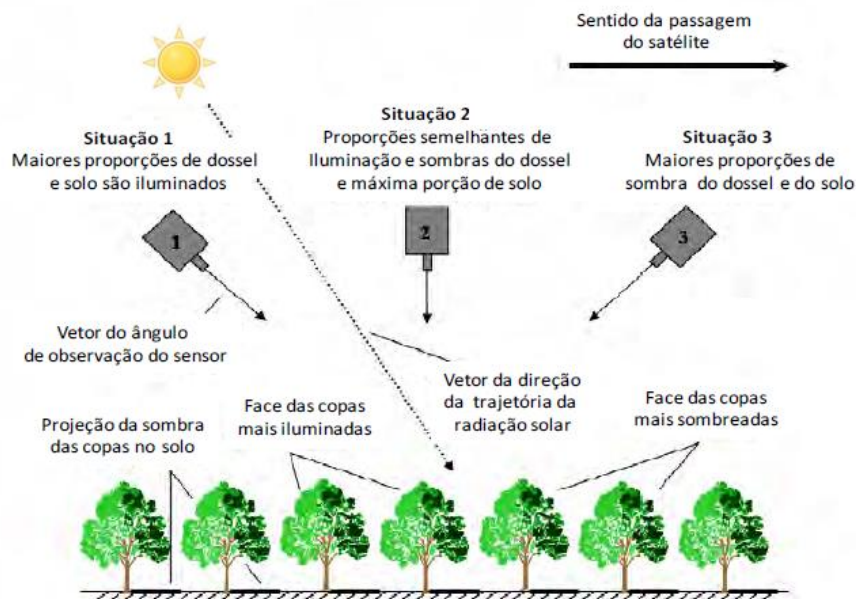


Figura 3. Influência do sombreamento na resposta do dossel em função da configuração da visada
Fonte: Adaptada de LIESENBERG (2005).

2.2.1 Características Gerais das Sombras

As sombras, de um modo geral, ocorrem nas imagens devido à oclusão da fonte de iluminação (no caso de sistemas passivos) por objetos mais elevados presentes na superfície considerada. Quando há o bloqueio total da fonte de luz tem-se a chamada *umbra*, e a superfície aparece inteiramente ofuscada pelo objeto que a causou. A região de transição entre a *umbra* e

a as áreas que foram iluminadas é chamada de *penumbra*, cujo significado em Latim “quase sombra”, representa que a fonte de luz foi parcialmente bloqueada, resultando em uma diferença nos valores de brilho desta região para a região de *umbra* (FUNKA-LEA e STEEDEMANN, 1994; ARÉVALO et al., 2008).

A ocorrência da penumbra está relacionada ao fato da fonte de luz não ser pontual e resultar numa difração dos raios de luz pelo objeto que provocou a oclusão. Sobretudo em imagens de SR o efeito da penumbra é notável, sendo considerados em algumas metodologias. Dare (2005), por exemplo, mostrou que o comprimento da penumbra para uma imagem Ikonos com 1 metro de resolução espacial de uma área urbana, chega a ser mais de um pixel e exatamente 2 pixels para imagens *QuickBird*. Como a fonte de luz não pode ser assumida como um ponto no infinito, o resultado é um limite indefinido de transição entre as regiões sombreadas e não sombreadas, difícil de ser determinado e corrigido.

Uma classificação comum adotada por muitos autores separa as sombras em: sombras próprias (*self shadows*) ou como sombras projetadas (*cast shadow*). As sombras próprias, de acordo com Arévalo, Gonzales e Ambrosio (2008), são as correspondentes ao(s) lado(s) do próprio objeto que promove a oclusão da luz incidente e que não são iluminados. As sombras projetadas são correspondentes à projeção do próprio objeto que promove a oclusão da luz incidente sobre a superfície na qual ele está elevado. Na Figura 4 é mostrado um exemplo dos tipos de sombras que podem ser encontrados nas imagens.




Figura 4. Exemplo das classificações das sombras.

Fonte: Adaptado de AL-NAJDAWI et al. (2011).

Em imagens com alta resolução espacial, as sombras são causadas em sua maioria por feições urbanas, sendo que sombras topográficas provocadas por montanhas, por exemplo, também são encontradas em imagens de alta e média resoluções. Esse destaque na topografia dada pelas sombras auxilia no processo de fotointerpretação, facilitando a sensação de tridimensionalidade para percepção cognitiva do ser humano. Além dessas, existem as sombras ocasionadas por nuvens que independem da resolução da imagem para serem encontradas (SHAHTAHMASSEBI et al., 2013).

A principal característica que os pixels de sombra apresentam nas imagens é possuir a menor radiância dentre seus vizinhos ao longo de todo espectro eletromagnético. Apesar de não ser um alvo de superfície, as respostas que chegam ao sensor (aéreo ou orbital) em relação à região de sombra, de acordo com Adeline et al. (2013) é devido ao espalhamento da energia pela atmosfera e também pela contribuição de alvos vizinhos. Logo, as áreas sombreadas realçam alguns efeitos atmosféricos que são capturados pelos sensores como se fossem respostas radiométricas dos alvos sombreados. A Figura 5 ilustra esses efeitos, na qual ainda de acordo com os autores, como a radiância das áreas de sombra é dependente dos materiais na qual são projetadas, torna-se possível a recuperação dessas regiões assim como nas áreas iluminadas. Além disso, devido ao intervalo dinâmico dos atuais sensores, como *QuickBird* e *WorldView*, informações da superfície podem ser coletadas, mesmo se elas estiverem oclusas (LIU e YAMAZAKI, 2012).




Figura 5. Diferentes contribuições na resposta das áreas de sombras.

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

As propriedades fornecidas pelas sombras, representadas pelos seus valores de radiância observado ao longo do espectro, servem para o desenvolvimento de métodos capazes de identificá-las perante os demais objetos presentes nas imagens. Embora os valores de radiância contenham influências de outras fontes, como a atmosfera, somente métodos físicos baseados nas reflectância dos materiais fazem a correção da atmosfera, segundo Adeline et al. (2013), que exige o conhecimento de parâmetros presentes na atmosfera no momento do registro pelo sensor. Outros parâmetros importantes para identificar sombras, principalmente para os métodos baseados em modelos tridimensionais, são os ângulos de orientação do sol e do sensor no momento de aquisição da imagem. A partir deles é possível inferir sobre a posição relativa dos objetos na cena e orientação das sombras na cena (FUNKA-LEA e STEEDMAN, 1994). Um exemplo dessa configuração geométrica fonte-alvo-sensor é mostrado na Figura 6, na qual está exemplificado o azimuth solar (Az_{sol}), do sensor (Az_{sat}), o ângulo zenital do sol (ϕ_{sol}) e do sensor (ϕ_{sat}) em uma vista perspectiva (a) e plana (b).

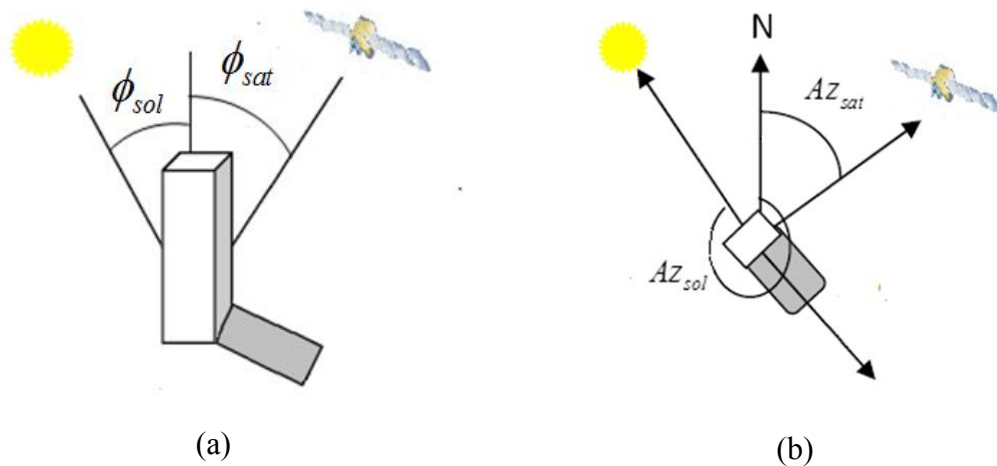


Figura 6. Geometria fonte-alvo-sensor. (a) Vista perspectiva, (b) vista plana.

Fonte: Adaptado de MASSALABI et al. (2004).

O problema da remoção de sombras tem sido estudado em diversos contextos, tanto no melhoramento da informação visual, quanto para contribuição com outras técnicas como a classificação de imagens, detecção de mudanças e análises e monitoramento ambiental. Para isso, a etapa de restauração se comporta como um pré-processamento, cujo objetivo é corrigir preliminarmente os erros que os dados originais possam apresentar em função dos efeitos do sombreado. Dessa maneira, é desejável um melhoramento do sinal registrado nas regiões de sombras ao invés de removê-los, já que mesmo fraco, possui informações úteis coletadas sobre a superfície (SHAHTAHMASSEBI et al., 2013). A partir dos dados corrigidos, novas

oportunidades de mapeamento detalhado da área urbana estarão surgindo e desafiando as técnicas de processamento dessas imagens, assim como acontece com a evolução na informação digital.

2.3 Processamento Digital de Imagens

O Processamento Digital de Imagens (PDI) tem proporcionado ao longo do tempo, recursos cada vez mais poderosos na manipulação de imagens. A evolução da tecnologia digital e a disponibilidade das imagens em formato matricial facilitaram operações matemáticas e estatísticas envolvidas na sua manipulação e análise. No âmbito do SR aéreo e orbital, sem os recursos do processamento digital seria difícil a extração e análise de informação devido ao grande volume de dados que integra uma cena em um conjunto de multibandas (MENESES e ALMEIDA, 2012). Aplicações como a classificação e reconhecimento de padrões, melhoria da informação e restauração de imagens são uns dos exemplos que destacam o PDI, como uma ferramenta poderosa para manipular e interpretar as imagens com o auxílio de um computador.

O interesse em métodos de processamento de imagens digitais decorre de duas áreas principais de aplicação: melhoria de informação visual para a interpretação humana e o processamento de dados de cenas para a percepção automática através de sistemas computacionais. Contudo, o processamento de imagens é caracterizado por soluções específicas, onde técnicas que funcionam bem em uma área podem se mostrar totalmente inadequadas em outra área (GONZALES e WOODS, 2010).

Com a evolução da visão computacional e a demanda crescente para a automatização das tarefas, os sistemas de processamento e análise de imagens vêm se desenvolvendo e tornando-se cada vez mais necessários em muitas aplicações. Hoje em dia eles são capazes de propiciar aos usuários ferramentas sofisticadas a fim de facilitar a identificação e a extração de informações relevantes contidas nas imagens. Muitos são os domínios de aplicação dessas técnicas, sendo destaque atualmente, o reconhecimento automático e em tempo real de padrões como, por exemplo, placas de automóveis e identificação de faces, visando um monitoramento em sistemas de vigilâncias.

Em conjunto, as técnicas de processamento e análise de imagens tornam-se importantes ferramentas para a extração de feições e objetos, descrição de formas e reconhecimento de padrões. A Morfologia Matemática é uma ferramenta neste sentido, desenvolvida a partir da teoria dos conjuntos para analisar a geometria e topologia das estruturas geométricas da

imagem. Muito dos algoritmos essenciais de processamento de imagens podem ser representados na forma de operadores morfológicos, que oferecem uma abordagem poderosa para vários problemas de processamento de imagens (SHI, 2009).

2.3.1 Processamento Morfológico de Imagens

O processamento morfológico de imagens (PMI) tem sido utilizado em muitos contextos e aplicações como uma ferramenta para extrair componentes das imagens, úteis na representação e descrição da forma de uma região (GONZALES e WOODS, 2010). Para isto, utiliza-se dos conhecimentos da Morfologia Matemática (MM), que consiste em uma teoria para análise da forma e estruturas dos objetos, o que a torna também, de acordo com Soille (2004), uma técnica poderosa na análise de imagens. Com suas primeiras noções desenvolvidas na França na década de 60, foi utilizada primeiramente em PDI com objetivo de analisar estruturas geométricas em imagens microscópicas.

Recentemente, o PMI vem sendo empregado com objetivos de realce, de segmentação, de detecção de bordas, de esqueletização, de afinamento, de análise de formas, dentre outros, com intuito de extrair informações relevantes da imagem. Tem como princípio básico, de acordo com Facon (1996), extrair informações relativas à geometria e à topologia de um conjunto desconhecido da imagem, por meio de um conjunto completamente conhecido denominado elemento estruturante (EE). O EE pode ser considerado como uma máscara completamente definida (origem, forma, orientação e tamanho) que se desloca na imagem realizando transformações, cujo resultado permite avaliar o conjunto desconhecido.

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. Um exemplo de EE com conectividade 4 é mostrado na Figura 7 (a), também chamado de cruz e, na Figura 7 (b) é exemplificado o EE caixa, que possui conectividade 8. Em ambos os casos, trata-se de EE planos, já que não foram associados pesos e, a posição marcada com “.” em vermelho indica a posição que receberá o novo valor resultante da transformação aplicada, porém não necessariamente deva coincidir com o centro da máscara.




Figura 7. Exemplo de Elementos Estruturantes (a) com conectividade 4 e (c) com conectividade 8.

Fonte: Adaptado de SOILLE (2004).

A abordagem morfológica de análise de imagens pode ser utilizada tanto em imagens binárias, quanto para imagens em tons de cinza. Na morfologia binária, as operações são baseadas na teoria de conjuntos, através de operações de intersecção, união, complementação e translação (SOILLE, 2004). Na morfologia cinzenta, as transformações ocorridas nas imagens consideram os valores de intensidade do pixel mais escuro (mínimo) e o valor mais claro (máximo), sendo a teoria de reticulados utilizada para as aplicações.

2.3.1.1 Conceitos Básicos

O primeiro conceito fundamental em MM, segundo Banon e Barrera (1998) é o de relação de ordem parcial. Os conjuntos providos por uma relação de ordem parcial são também considerados reticulados. No caso dos subconjuntos usa-se a relação habitual de inclusão, que permite a comparação de certos subconjuntos entre si. Um conjunto parcialmente ordenado L , de acordo com Soille (2004) é um conjunto que tem uma relação \leq definida para seus membros, por exemplo, a , b e c satisfazendo as seguintes condições:

- i. $a \leq a$ (Reflexividade)
- ii. $a \leq b$ e $b \leq a \Leftrightarrow a = b$ (Anti-simetria)
- iii. $a \leq b$ e $b \leq c \Rightarrow a \leq c$ (Transitividade)

Nesse caso, ainda é possível dizer que se quaisquer membros a e $b \in L$ satisfazem umas das seguintes propriedades de tricotomia: $a < b$ ou $a = b$ ou $b < a$, L é dito um *conjunto totalmente ordenado*. Além disso, o conjunto é um *reticulado completo* desde que exista, para cada subconjunto de L , um *supremo* e um *ínfimo*. O *supremo* \vee e o *ínfimo* \wedge entre duas imagens f e g de mesmo domínio são definidos, de acordo com Soille (2004), para cada ponto x como sendo:

$$\begin{aligned}(f \vee g)(x) &= \max[f(x), g(x)], \\ (f \wedge g)(x) &= \min[f(x), g(x)].\end{aligned}\tag{4}$$

Na Figura 8 estão ilustradas as operações de *supremo* e *ínfimo* entre duas funções f e g unidimensionais. O supremo de um conjunto é seu menor limite superior, e o ínfimo de um conjunto é seu maior limite inferior, ou seja, segundo Soille (2004), o menor limitante superior de A e B é um elemento C , tal que $C \leq A$, $C \leq B$ e não existe nenhum D para os quais $C < D \leq A$ e $D \leq B$. Analogamente, o maior limitante inferior de A e B pode ser definido.

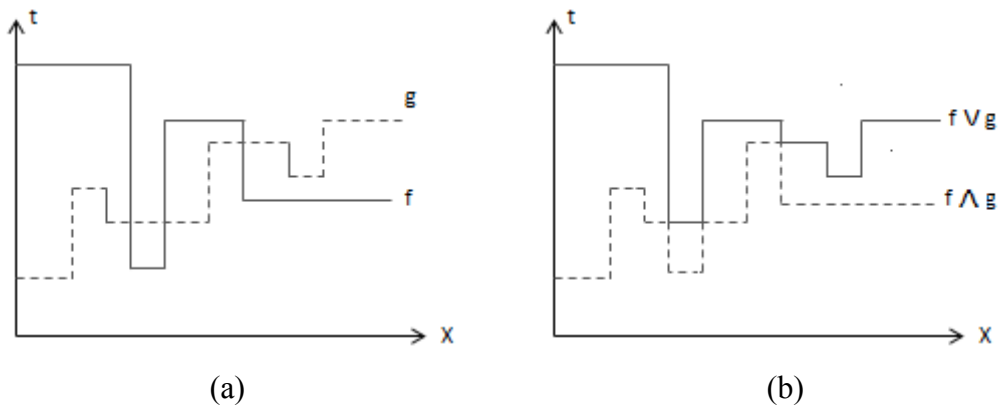


Figura 8. Exemplo de ínfimo e supremo de dois sinais unidimensionais. (a) Funções f e g unidimensionais (b) ínfimo e supremo das funções.

Fonte: Adaptado de SOILLE (2004).

Em termos de imagens binárias, as definições estabelecidas anteriormente para \vee e \wedge de funções, podem ser substituídas por operações de união \cup e intersecção \cap de conjuntos. Os operadores ou transformações morfológicas ψ empregados na MM devem estar de acordo com as propriedades de transformação de imagens. O conhecimento dessas propriedades permite prever de certa forma, o comportamento das transformações nas imagens e, portanto, fornece subsídios para a escolha do operador mais adequado para determinada aplicação de análise de imagens pretendida. De acordo com Soille (2004), algumas das propriedades básicas das transformações são: idempotência, extensividade, crescimento e conectividade. Dentre as transformações possíveis na imagem, existem duas que são a base para a construção das demais e consideradas elementares, denominadas de erosão e a dilatação.

2.3.1.2 Operadores Elementares

A partir das definições apresentadas anteriormente, de supremo e ínfimo, é possível definir as duas transformações básicas em MM: a *erosão* e *dilatação*. Estes dois operadores, chamados de elementares ou primitivos, segundo Banon e Barrera (1998), têm papel

fundamental porque a partir deles podem ser construídos quaisquer outros operadores com objetivo de processamento morfológico e análise de imagens.

Erosão

A erosão ε de uma imagem f , binária ou em tons de cinza, por um elemento estruturante B , segundo Soille (2004), é o valor mínimo entre as translações de f pelos vetores transpostos $-b$ de B mostrado na Equação 5.

$$\varepsilon_B(f) = \bigwedge_{b \in B} f_{-b}. \quad (5)$$

Em outras palavras e como apresentado pela Equação 6, o valor da erosão $\varepsilon_B(f)$ para um dado pixel x é o valor mínimo da imagem na janela definida pelo elemento estruturante, quando sua origem está em x :

$$\left[\varepsilon_B(f) \right](x) = \min_{b \in B} f(x+b). \quad (6)$$

Dessa maneira, a erosão em níveis de cinza é definida somente para pontos em que o elemento estruturante B estiver contido na função f . Em geral, os efeitos da erosão em uma imagem binária ou em tons de cinza com fundo escuro são: escurecer a imagem, alargar os vales (padrões escuros), conectar vales próximos, reduzir e, às vezes, eliminar picos (padrões claros) e separar picos próximos.

Dilatação

A dilatação δ de uma imagem f , binária ou em tons de cinza, por um elemento estruturante B , segundo Soille (2004), é o valor máximo entre as translações de f pelos vetores transpostos $-b$ de B :

$$\delta_B(f) = \bigvee_{b \in B} f_{-b} \quad (7)$$

Sendo o operador dual da erosão, o valor da dilatação $\delta_B(f)$ para um dado pixel x , de acordo com a Equação 8 é o valor máximo da imagem na janela definida pelo elemento estruturante quando sua origem está em x :

$$\left[\delta_B(f) \right] = \max_{b \in B} f(x+b) \quad (8)$$

Os efeitos da dilatação em uma imagem de fundo escuro são: clarear a imagem, alargar os picos (padrões claros), conectar picos próximos, reduzir e, às vezes, eliminar vales (padrões escuros) e separar vales próximos. À título de comparação, na Figura 9 são ilustrados os efeitos da erosão e dilatação sobre uma imagem em tons de cinza (a). O resultado da erosão com um EE *caixa* de dimensão 3 está disposto em (b), na qual é possível notar que a erosão escureceu a imagem, no sentido de que houve um aumento dos padrões escuros proporcionado pelo corpo d'água presente na imagem. O efeito da dilatação, com o mesmo EE está ilustrado em (c). Nota-se que oposto ao que aconteceu com a erosão, a dilatação provocou um aumento nos padrões claros suprimindo em certos casos, os padrões escuros.




Figura 9. Resultado dos operadores elementares em uma imagem em níveis de cinza: (a) imagem original; (b) imagem erodida e (c) imagem dilatada.

A Figura 10 mostra um exemplo numérico do processo de erosão sobre uma faixa retirada da imagem original, disposta na Figura 10 (a). Assim, por meio do elemento estruturante *caixa* com origem no centro, conforme destacado em (b), o resultado dos pixels submetidos a esse processo está disposto em (c), cujas posições com valores modificados encontram-se destacadas. Portanto, de acordo com a conectividade estabelecida pelo EE, o resultado atribuído ao pixel analisado, será o valor mínimo da vizinhança para a erosão e o máximo no caso da dilatação.




Figura 10. Exemplo numérico do processo de erosão. (a) faixa retirada da imagem original; (b) elemento estruturante caixa e (c) resultado da erosão.

Quando aplicados 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, os operadores elementares fornecem condições para a elaboração de outros operadores, como os filtros morfológicos.

2.3.1.3 Filtros Morfológicos

Os filtros morfológicos são filtros não lineares adequados para remover seletivamente estruturas presentes nas imagens. Essas estruturas podem ser ruídos ou objetos irrelevantes da imagem, que por sua vez são removidos, enquanto ao mesmo tempo se preservam outros objetos. De acordo com Soille (2004), a condição para uma transformação Ψ ser um filtro morfológico é:

$$\Psi \text{ é um filtro morfológico} \Leftrightarrow \Psi \text{ é idempotente e crescente.}$$

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

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

Já uma transformação Ψ crescente é aquela que preserva a relação de ordem entre as imagens, ou seja, (SOILLE, 2004):

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

Na prática, 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 são os filtros morfológicos básicos.

Abertura morfológica

A abertura γ de uma imagem f por um elemento estruturante B é definida segundo Soille (2004), como sendo a erosão de f por B , seguida da dilatação com o EE transposto \check{B} :

$$\gamma_B(f) = \delta_{\check{B}}[(\varepsilon_B f)] \quad (9)$$

Como pode ser visto pela Equação 9, o princípio da abertura morfológica consiste em dilatar a imagem previamente erodida com o mesmo elemento estruturante, porém refletido. Contudo, estruturas completamente destruídas pela erosão não podem ser recuperadas.

Dentre os efeitos visuais da abertura estão a separação de padrões claros próximos, eliminação de padrões claros menores que o tamanho do EE e a conservação de padrões escuros distantes (FACON, 1996). Em geral, a imagem resultante do processo de abertura possui menos detalhes do que a imagem original, esta característica é devido à abertura ser uma transformação *anti-extensiva*, ou seja, a imagem transformada é menor ou igual à imagem original. O operador dual da abertura é o fechamento morfológico.

Fechamento morfológico

O fechamento ϕ de uma imagem f por um elemento estruturante B , segundo Soille (2004) é definido pela operação de dilatação de f por B , seguido pela operação de erosão com EE transposto \check{B} :

$$\phi_B(f) = \varepsilon_{\check{B}}[\delta_B(f)] \quad (10)$$

Como pode ser observado na Equação 10, o fechamento morfológico consiste em um operador que tenta recuperar as estruturas da imagem que foram dilatadas, sendo realizada através da erosão da imagem dilatada. Os efeitos do fechamento geralmente consistem na separação de padrões escuros próximos, na eliminação de padrões escuros menores que o tamanho do elemento estruturante, na conservação de padrões claros distantes e na conexão de padrões claros próximos.

Embora o fechamento seja uma transformação extensiva, ou seja, a imagem transformada é maior ou igual à imagem original, o resultado do fechamento é uma imagem com menos detalhes do que a imagem original.

De acordo com Soille (2004), uma transformação que tem as mesmas propriedades (crescente, idempotente e anti-extensiva) da abertura, mas que não pode ser escrita com uma única erosão seguida por uma dilatação com o EE transposto é chamada abertura algébrica. Uma abertura algébrica utilizada como ferramenta poderosa para filtrar componentes conectados é conhecida como abertura por área, sendo o fechamento por área sua transformação dual.

Abertura por área

A abertura por área γ_λ , segundo Soille (2004) é equivalente à união (ou supremo) de todas as aberturas com EEs conectados B_i , cujo tamanho em número de pixel é igual a λ :

$$\gamma_\lambda = \bigvee_i \{ \gamma_{B_i}(f) \} \quad (11)$$

em que B_i é conectado e sua área é igual a λ .

A abertura por área é muito utilizada em imagens binárias para remover algum tipo de ruído ou objetos conectados irrelevantes, cuja área seja menor que o parâmetro λ . No caso discreto, a área refere-se exclusivamente ao número de pixels. Por serem operadores duais, o mesmo efeito, só que agora em relação aos vales da imagem é encontrado no operador fechamento por área.

Fechamento por área

O fechamento por área ϕ_λ , 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 λ :

$$\phi_\lambda = \bigwedge_i \{ \phi_{B_i}(f) \} \quad (12)$$

em que B_i é conectado e sua área é igual a λ .

Portanto, um fechamento por área em uma imagem, remove todas as estruturas escuras conectadas de tamanho menores que λ . Vale ressaltar de que a palavra conectividade utilizada, se refere ao EE empregado na aplicação. Por exemplo, no caso do EE *cruz* que possui conectividade 4 (Figura 7 (a)) a operação de abertura por área é sempre mais ativa do que com o EE *caixa* de conectividade 8 (Figura 7(b)). Isto se deve ao fato de que o EE *caixa* considera uma vizinhança maior de pixels, aumentando a probabilidade de mais objetos estarem conectados, do que com o EE *cruz*. Sendo assim, quando se faz valer o parâmetro de área, a imagem obtida empregando-se um EE com conectividade 4 é um subconjunto da obtida com um EE de conectividade 8.

Desse modo, a vantagem de se utilizar a abertura ou fechamento algébrico é de que não há mais necessariamente a restrição na forma do EE. A restrição passa a ser no tamanho da área de seus objetos conectados.

Em imagens binárias a interpretação geométrica da abertura e do fechamento é trivial. No caso das imagens em tons de cinza, a transformação é aplicada a cada seção transversal da imagem. A seção transversal $CS_t(f)$ de uma imagem em tons de cinza f ao nível t é definida segundo Soille (2004) como o conjunto dos pixels da imagem cujos valores são maiores ou iguais a t . A imagem f pode ser então escrita como a soma das suas seções transversais (Equação 13), na qual o nível 0 contém toda a imagem. A esse processo dá-se o nome de decomposição em limiares e o princípio está ilustrado na Figura 11.

$$f = \sum_{t=1}^{t_{\max}} CS_t(f) \quad (13)$$

Assim, de acordo com Vincent (1992) as áreas dos máximos e mínimos regionais no caso da abertura e fechamento, respectivamente, são analisadas em cada seção transversal da imagem, ou seja, de intensidades iguais, desde a de maior limiar, 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.




Figura 11. Decomposição em limiares da imagem f com 4 níveis de intensidade.

Uma transformação Ψ é dita invariante a decomposição em limiares se ela atende a propriedade disposta na Equação 14, na qual nos mostra que Ψ invariante a decomposição se puder ser escrita como a soma das transformações de suas seções transversais (SOILLE, 2004).

$$\Psi \text{ é invariante à decomposição em limiares } \Leftrightarrow \Psi = \sum_{t=1}^{k_{\max}} \Psi CS_t \quad (14)$$

Outra propriedade importante dos filtros morfológicos é a idempotência, ou seja, sucessivas aplicações da transformação de abertura ou fechamento em uma imagem não irão modificá-la. Soille (2004) faz uma analogia dos filtros morfológicos a um processo de peneiramento, onde os materiais que já foram peneirados não serão mais filtrados pela mesma peneira. A Figura 12 (a) apresenta uma imagem em tons de cinza, que foi filtrada por uma abertura (b) e por um fechamento (c) de área igual a quinhentos pixels.




Figura 12. Exemplo de filtros morfológicos algébricos. (a) imagem original, (b) abertura por área e (c) fechamento por área de quinhentos pixels.

Fonte: Adaptado de SDC *Information Systems*.

Nota-se que na Figura 12 (b), todos os padrões claros conectados com área inferior ao critério de área foram removidos, já em (c) os padrões escuros foram removidos, permanecendo os objetos que possuem mais de quinhentos pixels, de acordo com a conectividade 4 empregada.

Os operadores de abertura e fechamento quando aplicados isoladamente, são transformações que nem sempre evidenciam características das imagens. Porém, quando combinados com algum tipo de operação com a imagem original é possível recuperar informações relevantes e ao mesmo tempo eliminar a heterogeneidade e o ruído das imagens, como é o caso das combinações da transformação *top-hat* (FACON, 1996).

2.3.1.4 Transformação *Top-hat*

A transformação *top-hat*, assim como os filtros clássicos, tem a finalidade de obter estruturas relevantes nas imagens, e se apresenta como uma ferramenta de detecção de padrões claros e escuros nas imagens. A transformação *top-hat* 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. Isto ocorre devido ao fato de que um fechamento ou uma abertura por um EE que não se ajusta às estruturas relevantes presentes na imagem removem-nas. Em seguida essas estruturas removidas são então recuperadas, através da diferença aritmética com a imagem original. Existem dois tipos de *top-hats*, o *top-hat* por abertura e o por fechamento.

Top-hat por Abertura

De acordo com Soille (2004), o *top-hat* por abertura (denominado por *White Top-Hat*) de uma imagem f é a diferença entre a imagem f e sua abertura γ :

$$WTH(f) = f - \gamma(f) \quad (15)$$

A diferença mostrada na Equação 15, entre os sinais originais e o resultado da abertura, permite eliminar estruturas que não contém o EE e a falta de homogeneidade com o fundo da imagem, ressaltando as informações dos maiores valores de intensidade da imagem, ou seja, ressaltando os picos. Assim, devido a Abertura morfológica ser uma transformação *anti-extensiva*, os níveis de cinza da imagem resultante do *top-hat* por abertura serão sempre maiores ou iguais à zero. Esse princípio é ilustrado na Figura 13.




Figura 13. Exemplo teórico da transformação *top-hat* por abertura em um sinal unidimensional.

Fonte: Adaptado de SOILLE (2004).

O operador dual do WTH é o *top-hat* por Fechamento (também denominado por *Black Top-Hat*).

Top-hat por Fechamento

A transformação *top-hat* por fechamento (*BTH*) consiste na diferença entre o fechamento da imagem original $\phi(f)$, e a imagem original f , (SOILLE, 2004):

$$BTH(f) = \phi(f) - f \tag{16}$$

A diferença mostrada na Equação 16, entre a imagem resultante do processo de fechamento e a imagem original consiste na detecção de vales e possui resultado sempre positivo, devido o fechamento ser um processo extensivo. A Figura 14 ilustra o princípio, na qual todas as estruturas escuras relevantes do fundo foram suprimidas e após a diferença com a imagem original mostrada em (b) foram recuperadas. Contudo, as propriedades de idempotência e de crescimento já não são mais garantidas. Na Figura 14 é exibido o resultado teórico do *top-hat* por fechamento.




Figura 14. Exemplo teórico da transformação *Top-hat* por fechamento de um sinal unidimensional.

Fonte: Adaptado de SOILLE (2004).

O sucesso desta abordagem na MM deve-se ao fato de que não existe necessariamente uma correspondência de um-para-um entre o conhecimento sobre o que um objeto da imagem é e o que ele não é. Por isso a restrição na forma adequada do EE para remoção das estruturas neste caso não é fundamental, como em outras aplicações morfológicas. Assim, a sondagem é feita com base somente na conectividade imposta pelo EE, sendo simplesmente de 4 ou 8 conectados. Além disso, torna-se mais fácil muitas vezes remover objetos relevantes da imagem, do que tentar diretamente suprimir os irrelevantes (SOILLE, 2004).

2.3.1.5 Gradiente Morfológico

Em análises de imagens, quando áreas da imagem são separadas em objetos, assume-se que eles possuem características homogêneas de intensidade em seu interior. As discontinuidades geradas quando os objetos são formados, também chamadas de bordas, possui uma maior taxa de variação apontada pelo vetor gradiente.

Os gradientes morfológicos segundo Soille (2004) são operadores que realçam variações de intensidade dos pixels dentro da vizinhança determinada pelo EE, sendo muito utilizado para detectar bordas dos objetos na imagem.

Assim como os outros operadores morfológicos apresentados, a combinação entre erosão e dilatação é a base na definição dos gradientes morfológicos. Diferenças aritméticas entre o resultado dessas transformações consegue identificar tanto as bordas externas, quanto as internas dos objetos.

O gradiente morfológico por erosão ρ_B^- , dado pela Equação 17, consegue identificar as bordas internas de um objeto mais claro que o fundo, como mostrada para uma imagem binária disposta na Figura 15, através da diferença aritmética entre a imagem original f e sua imagem erodida $\varepsilon_B(f)$ por um elemento estruturante B (SOILLE, 2004).

$$\rho_B^-(f) = f - \varepsilon_B(f) \quad (17)$$

Já o gradiente morfológico por dilatação ρ_B^+ , dado pela Equação 18, permite identificar neste caso para a mesma imagem da Figura 15, as bordas externas através da diferença aritmética entre a imagem dilatada δ_B pelo elemento estruturante B e a imagem original f (SOILLE, 2004).

$$\rho_B^+(f) = \delta_B(f) - f \quad (18)$$

No caso do da diferença aritmética entre a erosão e dilatação pelo mesmo elemento estruturante B , têm-se o gradiente morfológico por dilatação e erosão ρ_B , também chamado de gradiente *Beucher* segundo Soille (2004), dado pela Equação 19 e mostrado na Figura 15,

$$\rho_B(f) = \delta_B(f) - \varepsilon_B(f) \quad (19)$$

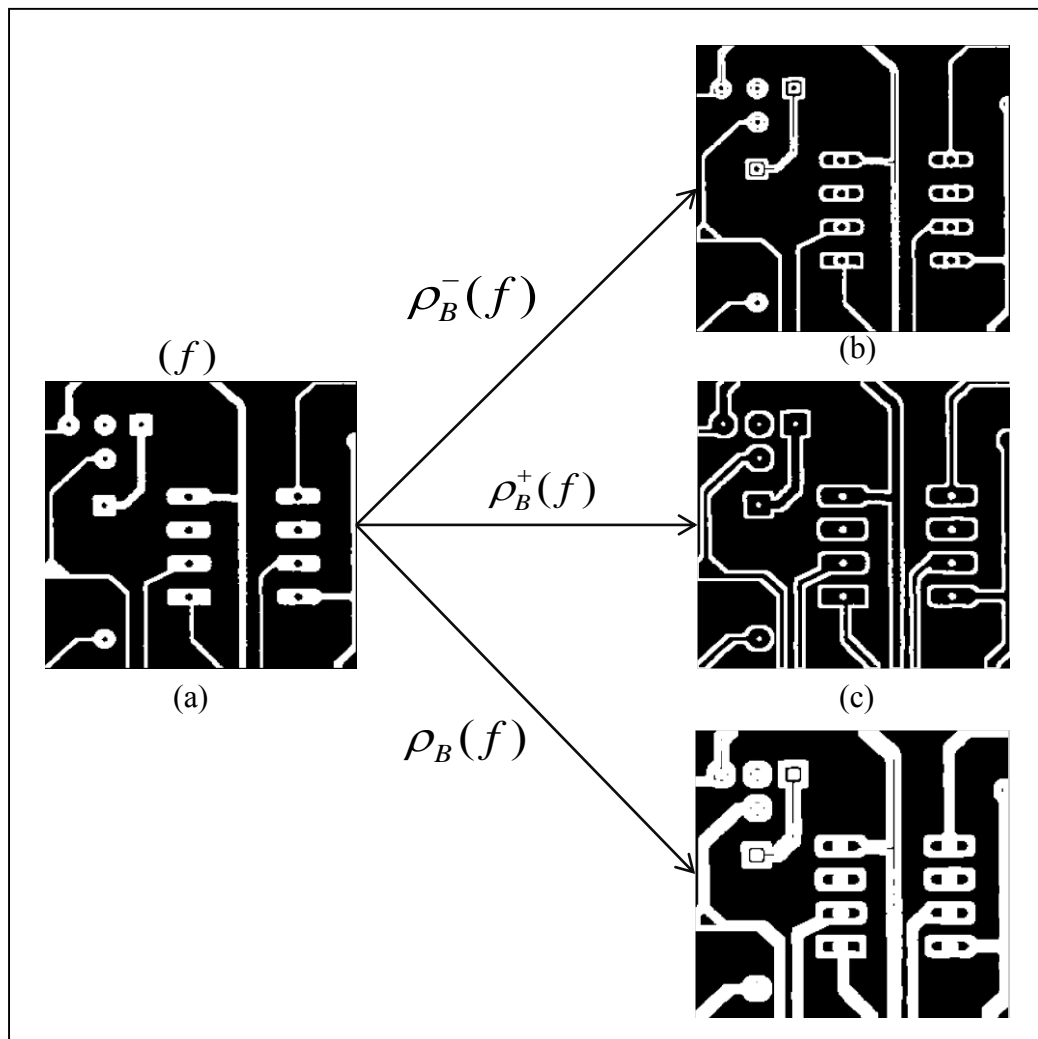


Figura 15. Gradientes Morfológicos da imagem f com um EE caixa 3x3. (a) Imagem binária f ; (b) Gradiente morfológico por erosão com bordas internas detectadas; (c) Gradiente morfológico por dilatação com as bordas externas detectadas; (d) Gradiente morfológico por dilatação e erosão.

2.3.2 Limiarização de Imagens

A limiarização consiste em umas das técnicas mais simples de segmentar uma imagem através da separação das regiões pertencentes à imagem em duas classes: a classe do objeto e o fundo da imagem. Este mapeamento é feito com base em um limiar t , daí o nome de limiarização (ou em inglês, *Thresholding*) que muitas vezes é definido a partir da análise do histograma. De acordo com Pedrini e Schwartz (2008), a binarização de uma imagem $f(x, y)$ por um limiar t que separa os pixels do objeto e do fundo em uma imagem $g(x, y)$ é dada por:

$$g(x, y) = \begin{cases} 0, & \text{se } f(x, y) \leq t \\ 1, & \text{se } f(x, y) > t \end{cases} \quad (20)$$

Devido ao fato da limiarização produzir uma imagem de saída com apenas dois níveis de intensidade, o processo também é denominado, muitas vezes, de binarização (MARQUES FILHO e VIEIRA NETO, 1999). A binarização de uma imagem consiste no mapeamento de seus tons de cinza para o intervalo $[0,1]$, em que 0 (zero) denota a intensidade do fundo da imagem, cor preta e 1 (um) denota o objeto, a cor branca.

Apesar de seguir a convenção de associar 0 para o fundo e 1 para o objeto, de acordo com Gonzalez e Woods (2010), quaisquer outros dois valores distintos podem ser utilizados na Equação 20. Quando apenas um limiar t é aplicado para segmentar uma imagem inteira, o processo é conhecido como limiarização global. Torna-se limiarização variável, quando t muda ao longo da imagem (GONZALEZ e WOODS, 2010).

O sucesso na segmentação depende diretamente da imagem de entrada, ou seja, de acordo com a profundidade e largura do(s) vale(s) do histograma. Quando a imagem a ser segmentada é relativamente uniforme e as regiões de interesse, representadas pelos objetos, possuem um contraste adequado com o fundo da imagem, a seleção do limiar t se torna facilitada. Contudo, alguns fatores podem interferir no sucesso da segmentação, como ruídos presente na imagem, variações nos níveis de cinza por causa da iluminação, tamanho relativo dos objetos e do fundo (GONZALES e WOODS, 2010). Assim, a seleção de um limiar global por meio somente da análise da distribuição das intensidades dos pixels, não representará uma segmentação adequada.

Algumas técnicas conseguem determinar o valor do limiar por meio da otimização de certas medidas de separação entre as classes (PEDRINI e SCHWARTZ, 2008). Existem métodos que definem este limiar de maneira automática como é o caso do método de Otsu (1979). Neste trabalho utilizou-se o método de binarização por limiar global proposto por Otsu, apresentado na sequência, devido a binarização não ser realizada na imagem original e sim, numa imagem resultante de um processo que a beneficia com um contraste entre os objetos da imagem.

2.3.2.1 Método automático de Otsu

Este método, proposto por Otsu (1979) define de maneira automática o limiar global mais adequado para uma imagem, com base somente na distribuição dos níveis de cinza dispostos no histograma. Inicialmente, sendo N o número total de pixels, n_i o número de pixels

com nível i ; o método considera o histograma da imagem de L níveis de cinza, como uma distribuição de probabilidade dada por (OTSU, 1979):

$$p_i = \frac{n_i}{N} \quad (21)$$

em que p_i é a probabilidade de um pixel apresentar o tom i , com $p_i \geq 0$ e $\sum_{i=1}^L p_i = 1$.

Assim, dado um limiar k e supondo que os pixels da imagem podem ser classificados em duas classes C_0 e C_1 (objeto e fundo, ou vice e versa), as probabilidades de ocorrência das classes (ω_0 e ω_1) e suas médias (μ_0 , μ_0 e μ_1 , μ_1), são dadas, respectivamente, por:

$$\omega_0 = \sum_{i=0}^k p_i = \omega(k) \quad (22)$$

$$\omega_1 = \sum_{i=k+1}^L p_i = 1 - \omega(k) \quad (23)$$

$$\mu_0 = \frac{\sum_{i=1}^k ip_i}{\omega_0} \quad (24)$$

$$\mu_1 = \frac{\sum_{i=k+1}^{L-1} ip_i}{\omega_1} \quad (25)$$

O objetivo então é encontrar um limiar k , que irá fornecer a melhor separação entre as classes, ou seja, k deve ser capaz de maximizar a variância entre as classes σ_B^2 , ou minimizar a variância intraclasse σ_w^2 , dadas, respectivamente, por:

$$\sigma_B^2 = \omega_0 \omega_1 (\mu_1 - \mu_0)^2 \quad (26)$$

$$\sigma_w^2 = \omega_0 \sigma_0^2 + \omega_1 \sigma_1^2 \quad (27)$$

onde, as variâncias σ_0^2 e σ_1^2 das classes são calculadas por:

$$\sigma_0^2 = \frac{\sum_{i=1}^k (i - \mu_0)^2 p_i}{\omega_0} \quad (28)$$

$$\sigma_1^2 = \frac{\sum_{i=k+1}^L (i - \mu_1)^2 p_i}{\omega_1} \quad (29)$$

Dessa maneira, o algoritmo de Otsu testa todos os k limiares possíveis para encontrar o limiar ótimo k^* , tal que:

$$\sigma_B^2(k^*) = \max_{1 \leq k \leq L} \sigma_B^2(k) \quad (30)$$

O algoritmo de Otsu é um dos métodos mais utilizados para seleção de um limiar adequado, estando implementado na maioria dos softwares de processamento de imagens. A Figura 16 mostra um exemplo da binarização de uma imagem (a), com 255 tons de cinza, por meio do algoritmo de Otsu implementado no *software Matlab*. Com base nos cálculos propostos por Otsu para a distribuição dos valores da imagem, o limiar ótimo $k^* = 148$ encontrado e mostrado em (b), resultou em uma imagem (c) com duas classes: o objeto dado pela folha em preto e o fundo branco.

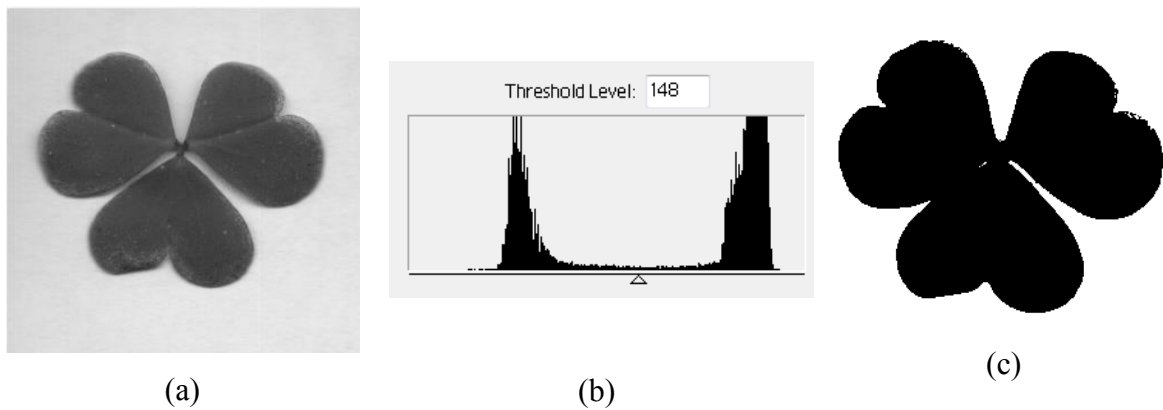


Figura 16. Exemplo da Binarização de uma imagem. (a) Imagem de 8 bits de intensidade; (b) Histograma da imagem a ser segmentada pelo limiar 128 e (c) Imagem binária resultante.

2.4 Correção Radiométrica de Imagens

As distorções radiométricas que afetam a medida dos valores de brilho em uma imagem, resultam numa distribuição incorreta dos valores de brilho em uma dada banda e, portanto, diferente do que se observa em relação à cena real (RICHARDS, 2012). O pixel então acaba não representando a verdadeira característica do alvo a ele associado, comprometendo a qualidade por parte das imagens e impactando em aplicações que fazem o uso desses dados, como a classificação da cobertura da terra.

Como mencionado anteriormente, a presença de sombras nas imagens pode ser considerada uma degradação que limita de certa forma, a interpretação dessas imagens. Elas causam, de acordo com Arévalo, Gonzales e Ambrosio (2008) parcial ou total perda da informação radiométrica das áreas afetadas por sua presença, e conseqüentemente tornam mais

difíceis ou até mesmo falhos os processos de análise de imagens. O objetivo da melhoria radiométrica neste caso é então, estabelecer um equilíbrio entre as diferenças de iluminação dessas áreas afetadas, de forma a melhorar o contraste e permitir um aumento na qualidade visual das imagens digitais. A melhoria radiométrica contribui tanto para a análise visual, quanto para análise e reconhecimento por meio automático. Quando se conhece a fonte da degradação, o processo é denominado de restauração da imagem.

A restauração de uma imagem, segundo Gonzales e Woods (2010), procura recuperar uma imagem corrompida, a partir da definição da degradação e aplicando o processo inverso para recuperar a imagem original. Na restauração são realizados procedimentos para reconstruir ou reduzir degradações ocasionadas por algum fenômeno que impossibilita a imagem original de representar fielmente a cena. Diferentemente das técnicas de realce, que se preocupam com o aspecto subjetivo do observador através da melhoria na definição da cena, na restauração torna-se importante o desenvolvimento de critérios que definam o que seria uma imagem boa para estabelecer uma estimativa do resultado desejado.

Existe uma variedade de técnicas para a restauração, sendo a mediana no domínio espacial uma das mais adequadas na presença de ruídos aditivos, e outras mais utilizadas no domínio da frequência, como é o caso do filtro rejeita-banda Butterworth para o ruído periódico (GONZALES e WOODS, 2010).

No processo de melhoria radiométrica, se faz amplamente uso do histograma da imagem. O histograma é uma das formas mais comuns de representar a distribuição da frequência dos níveis de cinza de uma imagem, e possivelmente a mais útil em PDI. A partir da análise do histograma é possível obter informações sobre a imagem, tais como contraste, brilho, intervalo dinâmico etc. Contudo, ele fornece apenas informações espectrais, não dando nenhuma indicação da distribuição espacial dos ND's. Uma imagem que tem um bom arranjo dos valores de brilho possui um histograma com frequência ocupada em todo alcance do mesmo. Já uma imagem com baixo contraste, tem um histograma estreito com baixa variância da escala de intensidade.

No domínio espacial, os histogramas são a base para várias técnicas de processamento, os quais podem ter sua forma modificada para atender determinada aplicação. Um método não linear de melhoria do contraste e que tem o objetivo de produzir um histograma aproximadamente uniforme é a Equalização de Histograma. O método de equalização de histograma produz uma distribuição mais uniforme dos níveis de cinza. Sua vantagem, segundo Schowengerdt (2007) é que não são necessários parâmetros para implementar essa

transformação, tornando-a fácil de ser aplicada. Contudo, produz resultado contrário ao pretendido quando aplicada em imagens que tenham uma área extensa e homogênea de brilho constante. Neste caso, uma única classe de alvo com alta frequência, interfere no histograma acumulativo, tendo como consequência a perda de contraste e pouco detalhamento da cena, resultado contrário ao pretendido.

Dessa forma, existem situações em que se torna desejável poder definir a forma específica para o histograma da imagem de saída. Uma técnica que permite combinar o contraste e a característica de brilho entre duas imagens é denominada de Especificação de Histograma.

2.4.1 Especificação de Histogramas

A técnica conhecida por Especificação de Histograma (ou em inglês, *Histogram Matching*) procura igualar as curvas dos histogramas acumulados de duas imagens: a imagem de entrada com uma imagem de referência. O processo gera uma nova imagem com um histograma específico, determinado pela imagem referência. O método tem por objetivo minimizar as diferenças radiométricas na imagem, provocadas, por exemplo, na geração de mosaicos ou por variações nas condições atmosféricas e no ângulo de visada de cenas adjacentes, tomadas de duas órbitas ou faixas do mesmo sensor (RICHARDS, 2012).

No processo de recuperar as informações afetadas pela presença de sombras, normalmente assume-se uma relação linear entre a radiação na área de sombra e na área que não foi afetada por este efeito, ou seja, em uma área iluminada. Essa relação na verdade é assumida devido a condição de iluminação entre essas regiões serem a mesma na aquisição da imagem (SHAHTAHMASSEBI et al., 2013). Assim a especificação de histograma pode ser uma, dentre as soluções para corrigir diferenças radiométricas entre áreas da imagem. Rau, Chen e Hen (2002) utilizaram os histogramas de uma região vizinha à região de sombra, como referência para transformar os valores de brilho dentro dessa região sombreada. Assim, as diferenças radiométricas entre essas áreas foram equilibradas localmente, conduzindo a um aumento da possibilidade de interpretação das áreas sombreadas.

O trabalho é o mesmo que na equalização de histograma, o qual pode ser calculado pela Equação 31, na qual n_i representa o número de pixels com nível i , e N o total de pixels da imagem com L níveis de cinza.

$$y(i) = \frac{L-1}{N} \sum_{i=0}^{L-1} n_i \quad (31)$$

No entanto, na Especificação de Histograma, o processo é feito tanto para imagem de entrada quanto para a de referência especificada. Seja então, com base em Richards (2012), $z = f(x)$ a transformação que equaliza e mapeia o histograma original $h_i(x)$ para o histograma intermediário $h^*(z)$, e $z = g(y)$ a transformação de equalização do histograma especificado $h_0(y)$. A imagem resultante é obtida aplicando-se a inversa: $y = g^{-1}\{f(x)\}$. Isto representa um mapeamento dos valores da imagem de entrada equalizada para seus valores mais próximos no histograma especificado, cujas etapas estão ilustradas na Figura 17.




Figura 17. Etapas da especificação de histograma.

Fonte: Adaptado de RICHARDS (2012).

Novamente, assim como acontece na equalização de histograma, o histograma resultante não possui exatamente a mesma forma do especificado, uma vez que se tratam de valores discretos. Quando o número de pixels e valores de brilho $h_i(x)$ e $h_0(y)$ forem os mesmos, o fator de escala $L-1/N$ da Equação 31 será cancelado na etapa de equalização. Porém, se o número de pixels for diferente, ou seja, $N1$ na imagem a ser modificada e $N2$ na imagem de referência, então o fator de escala $(N2/N1)$ deverá ser utilizado. Contudo, o fator de escala não deverá ser aplicado, caso o histograma acumulado tenha sido normalizado.

2.5 Métricas para Avaliação da Qualidade

Avaliações de resultados em procedimentos de extração/detecção são sempre necessárias e essenciais, principalmente em métodos ditos automáticos ou semiautomáticos, para que os usuários possam verificar a qualidade dos dados obtidos, com base em valores estatísticos ou alguma métrica que permita validar o processo. Uma possibilidade é analisar

visualmente os resultados, através da sobreposição dos vetores dos objetos extraídos em sua imagem original, delimitando o objeto de interesse e permitindo visualizar possíveis erros de posicionamento e falhas na execução do método.

Outra possibilidade refere-se a uma análise quantitativa dos resultados, com base em medidas de qualidade como aquelas apresentadas por Wiedemann et al. (1998) denominadas de Completeza e Correção. As medidas de Completeza e Correção foram propostas, em sua concepção original, para uma avaliação da extração automática de eixos de vias em imagens aéreas. Para avaliar a área detectada, por exemplo no caso da detecção das sombras, a completeza e a correção revelam os erros de comissão e omissão, respectivamente, conforme mostrado por Hermosilla et al. (2011) na detecção de edifícios. Trata-se de quantificar a porcentagem de sobreposição e acerto da feição de interesse detectada em relação ao dado de referência.

Para avaliação do processo, compara-se o resultado pixel a pixel da imagem processada (PI) na detecção, com uma imagem tomada como de referência, também 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, o que não as isentam de erros.

Dessa maneira, a Completeza na detecção de sombras, definida pela Equação 32, representa a porcentagem da área referente aos pixels corretamente identificados como sombras pelo método, dentro do limite de tolerância de PI e tendo como base o GT da imagem analisada. O valor do índice varia no intervalo [0; 1], sendo 1 o valor ideal esperado.

$$Completeza = \frac{\text{total de pixels sombra da PI coincidentes com o GT}}{\text{total de pixels sombra do GT}} \quad (32)$$

Já a Correção definida pela Equação 33, representa a porcentagem dos pixels detectados como sombra da PI e que são coincidentes com o GT, dentro do limite de tolerância estabelecido para ele. Assim, o índice da correção indica dentro do intervalo [0;1], qual o nível de acerto do método em rotular um pixel como sendo de sombra, tendo o valor 1 como ótimo.

$$Correção = \frac{\text{total de pixels de sombra da PI coincidentes com o GT}}{\text{total de pixels de sombra da PI}} \quad (33)$$

De acordo com as considerações sobre avaliação feitas por Prati et al. (2003), um método que possui uma boa detecção é aquele que tem baixa probabilidade de classificar erroneamente um pixel de sombra, ou seja, uma alta completeza. Já um método com boa discriminação é aquele que tem baixa probabilidade de classificar como sombras, pixels que não pertencem às regiões de sombras, ou seja, com um valor mínimo de correção.

3 MATERIAIS E METODOLOGIA PROPOSTA

Nesta seção serão apresentados os materiais utilizados no desenvolvimento do trabalho, bem como os recursos computacionais necessários e os procedimentos metodológicos envolvidos.

3.1 Materiais

Os dados utilizados neste trabalho compreendem duas cenas adquiridas pelo sensor orbital WorldView-2, ambas abrangendo área urbana de aproximadamente 30 km², sendo uma do município de Presidente Prudente adquirida em maio de 2012 e a outra da cidade de São Paulo referente a julho de 2012. As imagens em formato digital possuem 8 bits de resolução radiométrica e correspondem a banda pancromáticas do sensor, com 0,5 metro de resolução espacial. Trata-se de imagens de alta resolução espacial, cujo detalhamento, principalmente em áreas urbanas densas como é o caso de São Paulo, acarreta em um número elevado de áreas de sombras de diferentes tamanhos, ocasionadas por diversas feições. A Figura 18 mostra uma das imagens utilizadas, justamente a de São Paulo, evidenciando os tipos de sombras comuns encontrados e o tamanho dos recortes utilizados para testar a metodologia. As imagens apresentadas foram realçadas, de modo a proporcionar uma visualização melhor dos detalhes da cena.




Figura 18. Imagem WorldView-2 pancromática da área urbana de São Paulo e um exemplo do tamanho de um recorte utilizado elucidando os detalhes.

Para efeito de comparação e análise da metodologia, duas imagens aéreas RGB do município de Presidente Prudente também foram utilizadas. As imagens foram tomadas com uma câmara digital Hasselblad pela empresa Engemap em parceria com o Departamento de Cartografia da Faculdade de Ciências e Tecnologia (FCT) da Universidade Estadual Paulista através dos projetos nº 478782/2009-8 e 312909/2009-8 do CNPq. Na Figura 19 uma das imagens está disposta para exemplificar o grau de detalhamento da imagem original. Neste caso, a resolução espacial do pixel no terreno corresponde a 0,30 metro, sendo os testes feitos separadamente para cada faixa espectral, e a faixa do vermelho utilizada para as análises, por proporcionar maior distinção de respostas entre as feições antrópicas, maioria dos alvos presentes em áreas urbanas.



Figura 19. Exemplo de imagem aérea utilizada para verificar a metodologia. (a) Imagem RGB original; (b) Recorte 1000x1000 da faixa espectral do vermelho.

A metodologia foi desenvolvida no *software Matlab* o qual forneceu os recursos necessários, tanto pela facilidade em operações com imagens e funções específicas para o processamento digital de imagens, quanto por servir como plataforma para a caixa de ferramentas de Morfologia Matemática *SDC Morphology Toolbox for Matlab*. A partir desta *toolbox* foi possível realizar operações como fechamento e abertura por área, necessários para

detecção de sombras. Ainda como recurso computacional, o *software Photoshop* foi utilizado para a geração manual dos dados de referências (*Ground Truth - GT*) através de ferramentas para vetorização dos mesmos. O *software Google Earth* também foi utilizado como uma ferramenta de auxílio para a visualização e identificação de determinadas áreas que causaram incerteza no momento da geração do GT.

Devido à complexidade na geração manual do GT, optou-se por trabalhar com recortes do conjunto de imagens. Além de facilitar na visualização de regiões menores de sombras, os recortes também proporcionam uma eficiência computacional, já que houveram restrições de memória do computador empregado quanto à dimensão da imagem a ser processada no *Matlab*. Os recortes das imagens WorldView-2 foram de 300x300 pixels gerados automaticamente, com uma sobreposição lateral e superior de 100 pixels, resultando num total de 3000 recortes aproximadamente para cada cena. No total, foram gerados 37 GT's que serão utilizados para avaliação quantitativa da etapa de detecção. No caso das imagens aéreas que possuem resolução espacial maior, os recortes foram de 1000x1000 pixels.

3.2 Metodologia Proposta

Os procedimentos envolvidos na metodologia proposta serão apresentados nesta subseção, na qual todo processo pode ser entendido em síntese pelo fluxograma mostrado na Figura 20. O desenvolvimento é realizado em duas etapas principais. A primeira etapa abrange as tarefas necessárias para discriminar e detectar na imagem, as regiões influenciadas pela presença das sombras para que na sequência, possam ser corrigidas na etapa de restauração.

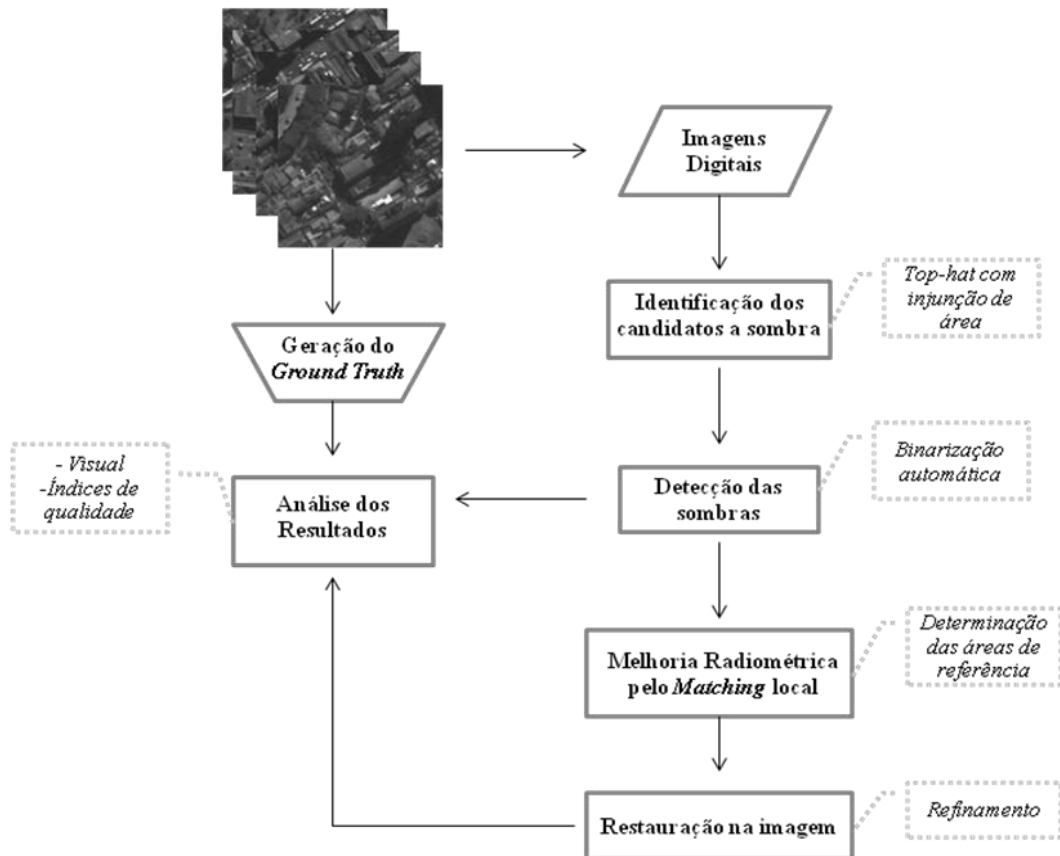


Figura 20. Fluxograma das etapas envolvidas no desenvolvimento da metodologia.

3.2.1 Etapa de Detecção

As sombras, mesmo não sendo alvos de superfície, possuem propriedades que podem ser utilizadas na sua identificação. O baixo padrão de resposta em relação a sua vizinhança é a principal característica que as evidenciam dos demais objetos presentes na cena. Partindo desta premissa, a detecção de sombras é realizada neste trabalho através de técnicas de PDI, com base em operadores morfológicos e dos conceitos estabelecidos sobre eles nas imagens, sendo uma ferramenta de destaque na análise dos mínimos regionais.

Para a identificação dos pixels candidatos a sombra, a transformação *top-hat* por fechamento de área é realizada. Em sua concepção original, a transformação *top-hat* por fechamento consiste em evidenciar padrões escuros da imagem (também conhecidos como vales), através da diferença aritmética entre a imagem original e a imagem resultante do processo de fechamento. No entanto, neste trabalho propõem-se a utilização do fechamento algébrico por área para esta tarefa. O critério de área foi imposto para que não haja a necessidade de estabelecer uma forma particular para o EE, assim como a maioria das operações

morfológicas. Isto se deve ao fato das sombras não possuírem um padrão específico, visto que sua forma varia de acordo com as feições que as ocasionam. Dessa maneira, ao se utilizar o fechamento por área, o EE passa a ser adaptativo e faz valer o critério de área sobre cada uma das seções transversais da imagem. O resultado é a filtragem de todas as sombras dentro do limiar de área e conectividade estabelecida. Na sequência, quando a diferença com a imagem original é realizada, as sombras são recuperadas e realçadas.

O parâmetro de área considerado no fechamento varia de acordo com a resolução da imagem e também com a dimensão dos objetos de interesse na cena. As imagens empregadas neste trabalho são do mesmo sensor e possuem a mesma resolução espacial. No entanto, um fator de área maior é necessário no caso das imagens de São Paulo devido à grande extensão de área coberta por sombras, em função da densidade urbana elevada.

O próximo passo da metodologia consiste em binarizar as imagens resultantes da transformação *top-hat* por fechamento de área, para detectar as sombras que foram realçadas na etapa anterior. Optou-se pela binarização de Otsu, pelo fato desta determinar o limiar mais adequado para cada imagem de forma automática, com base numa medida de separação entre classes. Trata-se de um algoritmo simples e rápido, o qual pôde ser escolhido, devido ao comportamento do histograma das imagens resultantes da aplicação do *top-hat* ser aproximadamente bimodal, isto é, os alvos de interesse destacam-se em relação aos demais alvos da cena. A saída do processo é uma imagem binária contendo os objetos de interesse, ou seja, as sombras em branco. Uma abertura de área de cinco pixels foi aplicada, com o intuito de remover os pixels conectados inferiores ao limiar definido, pois assumiu-se que componentes conectados com área inferior a esse limiar, não representam áreas de sombra significativas e, portanto podem ser considerados como ruídos e eliminados das imagens.

O comportamento da transformação *top-hat* em evidenciar as feições de interesse, contribui para que não sejam necessárias etapas de realce e remoção de ruído como na maioria dos métodos de extração de informação. O pré-processamento acaba sendo realizado pelo fechamento de área, que se comporta como uma filtragem da cena e depois, com a posterior abertura de área, possíveis ruídos que permaneceram são removidos. Este aspecto contribui na simplificação da tarefa e quanto menos transformações são necessárias, mais facilidade de aplicação e, conseqüentemente, mais abrangente se torna o método.

Uma vez definido o parâmetro de área, o processamento é feito de forma automática para uma ou mais imagens, através do algoritmo implementado no Matlab e utilizando os recursos da *toolbox* de MM. A partir das imagens binárias resultantes da detecção, o próximo

passo consiste em verificar se o que foi detectado nas imagens correspondem as áreas de sombra e, em quantificar a eficiência do método.

3.2.1.1 Formas de avaliação dos resultados da detecção

A avaliação do desempenho do método é feita de maneira qualitativa e quantitativa. A avaliação qualitativa consiste em uma análise visual do resultado da detecção através da sobreposição da imagem contendo as bordas das feições detectadas como áreas de sombra, na imagem original. Essa operação permite delimitar o objeto de interesse e visualizar se ocorreram possíveis erros de posicionamento ou falhas na execução do método.

Já a avaliação quantitativa consiste em analisar a qualidade da detecção por meio dos índices de completeza e correção. Essa análise permite comparar o que foi detectado pelo algoritmo, como sendo áreas de sombras, com o que foi gerado manualmente como referência (GT). A metodologia também foi avaliada em imagens aéreas, como forma de verificar o comportamento e a eficiência do método perante outras fontes de dados.

3.2.2 Etapa de Restauração

Durante o processo de aquisição da imagem, diferenças radiométricas ocasionadas por sombras podem ser registradas devido à obstrução da fonte de iluminação por objetos presentes na superfície. Em áreas urbanas a ocorrência dessas obstruções é mais frequente e possui grandes proporções, a medida que o detalhamento da cena é maior, como no caso das imagens de alta resolução espacial. O resultado são variações no valor de brilho registrado para um objeto sob o efeito de sombra em relação aos demais em condições normais de iluminação.

No entanto, estas distorções radiométricas alteram somente o valor de radiância do pixel, não influenciando na textura em relação aos seus vizinhos (SHAHTAHMASSEBI et al., 2013). Dessa forma, a recuperação de informações sobre a superfície em áreas sombreadas se mostra possível, sendo a melhoria radiométrica uma alternativa para amenizar esse efeito e proporcionar a restauração da imagem original.

A correção radiométrica através da especificação de histograma tem por objetivo minimizar as variações dos valores de brilho entre imagens. Trata-se de um processo que auxilia na melhoria da qualidade das imagens, e quando utilizada para corrigir os efeitos ocasionados pelas sombras, o processamento passa a ser local para reduzir as diferenças entre áreas vizinhas na imagem. Para que isto ocorra, primeiramente é necessário saber onde essas áreas de sombras

estão localizadas. A etapa de detecção passa a ser de suma importância, pois uma vez que a identificação dessas áreas não esteja correta, os processos subsequentes se tornam falíveis.

De posse das áreas de sombras detectadas, o próximo passo consiste em utilizar um histograma de referência para corrigir essas áreas, através da combinação entre o histograma de referência e o histograma da região sombreada identificada. Em muitas aplicações com imagens aéreas, os valores de referência são tomados em imagens adjacentes ou de outra faixa, dentro da superposição. Já com imagens orbitais esses dados se tornam mais complicados de serem obtidos, principalmente em aplicações com imagens de alta resolução espacial, que geralmente são comerciais e possuem alto custo para uma nova aquisição. Além disso, quando adquiridas com sombras, dificilmente a aquisição de uma nova imagem pelo mesmo sensor não sofrerá com o mesmo efeito (SHAHTAHMASSEBI et al., 2013).

3.2.2.1 Determinação das áreas de referências

Para superar as limitações dos dados orbitais em adquirir dados de referência, uma alternativa proposta na metodologia é utilizar informações retiradas da própria imagem, mais especificamente dos alvos imediatamente vizinhos como referência para a técnica. Com isto, o processo visa garantir que de posse somente da imagem, a correção dos efeitos de sombreamento possa ser realizada de maneira automatizada, sem exigir informações externas ou registro entre dados.

A MM oferece ferramentas úteis neste sentido sem que ocorram alterações na forma e localização do objeto. O gradiente morfológico por dilatação é então utilizado para criar um *buffer* nas regiões detectadas. No processo, a imagem binária resultante da detecção é rotulada formando objetos de acordo com a conectividade entre eles. A partir de cada objeto, o gradiente morfológico é aplicado definindo uma região de influência maior que o objeto, ou seja, um *buffer* ao redor deles. Os valores de brilho da imagem original são recuperados para cada região de influência, que fornecerá os parâmetros utilizados na correção de seus respectivos objetos. A Figura 21 mostra as etapas da obtenção das regiões de referências. A imagem original mostrada em (a) teve as regiões de sombras detectadas pela primeira etapa da metodologia proposta, e então rotulada (b), definindo os objetos como mostrados em diferentes cores em (c) que serviram para definir o *buffer* representado em (d) pela área em branco, utilizadas como referência na correção.

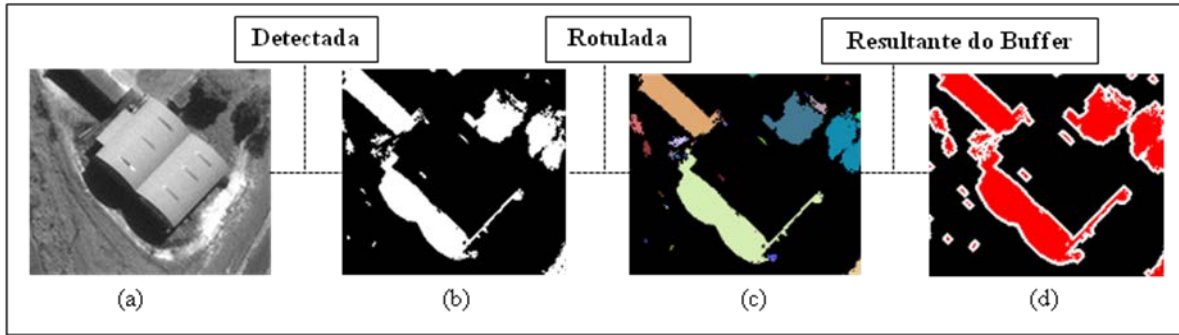


Figura 21. Exemplo da criação das regiões de referência. (a) Imagem original; (b) Detectada pela metodologia; (c) Rotulada em diferentes objetos da imagem; (d) Buffer em branco sobre os objetos em vermelho.

Quando se utiliza parâmetros de referência retirados da própria imagem, assume-se um relacionamento linear entre a radiância das áreas de sombras e suas áreas vizinhas que estão iluminadas. Isto se torna possível, segundo Shahtahmassebi et al. (2013) porque as condições de iluminação as quais ambas estão expostas são as mesmas, seguindo uma distribuição normal para os dados. Uma vez definida as áreas que servirão de referência, o algoritmo extrai automaticamente os parâmetros a partir da estatística dos valores de brilho de cada região, de sombra e de referência, para que o procedimento de combinação entre eles possa ser realizado.

3.2.2.2 Procedimento para o matching

A técnica de especificação de histograma, também chamada de *matching* de histograma, utilizada neste contexto para a correção de áreas de sombras, consiste em homogeneizar as diferenças radiométricas ocasionadas pela presença de sombras na imagem e proporcionar a minimização dos seus efeitos.

Com as sombras devidamente identificadas na imagem e suas áreas de referência geradas, o processo consiste em nivelar ambos os histogramas de forma a atribuir novos valores de média e variância para as áreas sombreadas, mais próximas possíveis de suas áreas vizinhas. Para que isso seja feito, o algoritmo calcula as estatísticas de cada objeto e sua respectiva área de influência local, gerando um histograma equalizado contendo os valores acumulados para ambos os casos. A etapa de equalização é intermediária e necessária para que ambos os dados possam ser comparados, já que a função de transformação é a mesma e os dados são colocados numa mesma escala. Dessa forma, para cada pixel da região sombreada, mapeia-se o valor de brilho para aquele correspondente à transformação obtida nas áreas de referência. O princípio é ilustrado na Figura 22 na qual em (a) o histograma de uma área de sombra (objeto) é combinado, a partir da função acumulada de transformação da sua área de referência (b). O

resultado são histogramas aproximadamente semelhantes, já que ao se tratar de valores discretos resulta em valores bem próximos.




Figura 22. Procedimento para o *matching* entre os histogramas: (a) Referente a uma área de sombra e (b) de sua área vizinha correspondente.

Fonte: Adaptado de NIELSEN (2004).

Em metodologias onde o número de pixels e os valores de brilho são os mesmos para as regiões que se pretende combinar, a etapa de equalização passa a ser dispensada, sendo o *matching* realizado com base somente nos histogramas acumulados originais. Contudo, a equalização se faz necessária na metodologia proposta, pois os dados combinados localmente não possuem a mesma área, isto é, possuem diferentes quantidades de pixels. Dessa forma, para cada objeto sombra detectado e sua área de influência gerada, realiza-se o ajuste local pelo *matching* de histogramas, que se encontram na mesma escala após a função acumulada obtida pela equalização.

O resultado obtido pela aplicação do *matching* para todas as áreas de sombras identificadas na etapa de detecção é restaurado na imagem original. O processo é denominado de restauração porque corrige as diferenças radiométricas provocadas pelas áreas de sombras, proporcionando uma imagem livre desses efeitos, e que possa representar fielmente as feições geográficas presentes na cena original.

3.2.2.3 Refinamento do método

Alguns efeitos podem ocorrer quando os valores são restaurados na imagem original, como por exemplo, a descontinuidade entre as áreas corrigidas e as que não sofreram nenhum

tipo de processamento. O resultado são bordas visíveis na imagem final, causando a degradação da qualidade da imagem, fato oposto à finalidade pretendida.

Na Figura 23 são apresentados exemplos de duas metodologias que sofreram com a influência de descontinuidade no resultado da restauração. De acordo com Dare (2005), um fator agravante para que este fenômeno ocorra é devido à existência de penumbra, influenciando principalmente as imagens de alta resolução, onde essas áreas chegam a ser do tamanho de um pixel. A existência da penumbra implica em mudança gradual de intensidade entre a região de sombra e sua vizinhança, em menor escala do que em relação as áreas iluminadas. Dessa forma, quando aplicado algum método de correção como o *matching*, os novos valores calculados para esta região apresentam comportamento acentuado, resultando em descontinuidades mais claras em relação as demais áreas vizinhas.

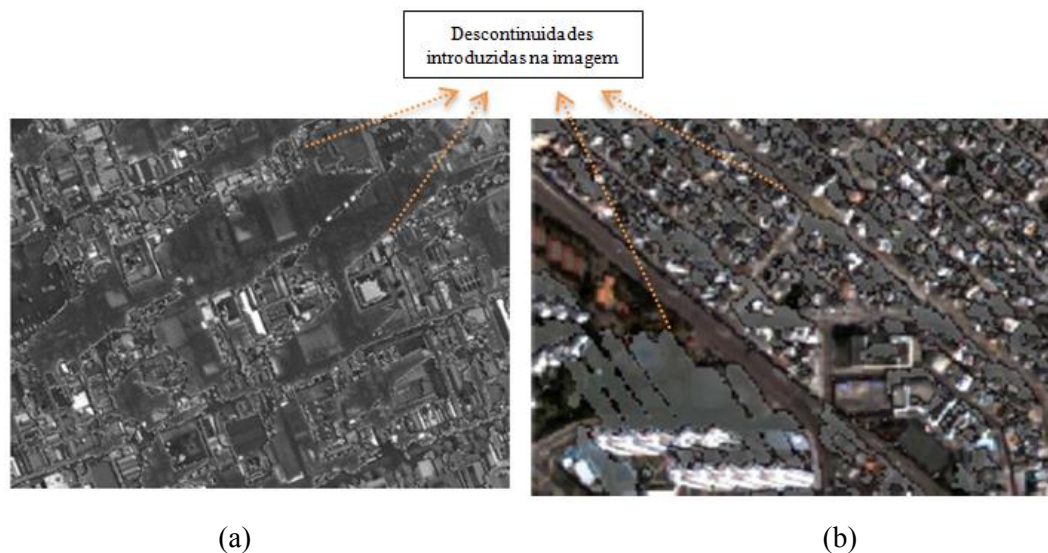


Figura 23. Exemplo de metodologias que sofreram com a descontinuidade entre as regiões na restauração. (a) Resultado da metodologia proposta por Dare (2005); (b) Resultado para a metodologia proposta por Wan, King e Li (2012).

Para reduzir os efeitos decorrentes da penumbra na restauração da imagem, a metodologia mais uma vez utiliza o gradiente morfológico para definir as áreas de influência da penumbra. Assim, cria-se novamente um buffer, só que dessa vez na área de transição entre sombras e regiões iluminadas. O processo consiste então em recalcular o *matching* sem a influência dessa área e uma suavização pela mediana é aplicada, como forma de reduzir os ruídos presentes nas áreas corrigidas e proporcionar descontinuidades de menor magnitude no momento de restaurar o resultado na imagem original.

A técnica é semelhante a utilizada na mosaicagem de imagem, na qual diferenças ocasionadas pela linha de junção são suavizadas, conforme exemplifica a Figura 24. Os

resultados serão comparados através da análise visual, já que não se dispõe de dados de referência sobre os valores radiométricos das áreas sem a influência de sombras.




Figura 24. O efeito da suavização entre as bordas para restauração na imagem original. (a) Região de transição sem e (b) com suavização.

Fonte: NIELSEN (2004).

3.3 Comparação com outras técnicas

Existem outras técnicas abordadas na literatura que também são utilizadas na correção das diferenças radiométricas ocasionadas pelas sombras. Uma delas é correção por *gamma*, que segundo Shahtahmassebi et al. (2013) é mais apropriada para imagens de alta resolução espacial. Sarabandi et al. (2004) em seu trabalho considera as sombras como fonte de um ruído multiplicativo que corrompe o brilho dos pixels oclusos e utiliza a correção *gamma* como um método padrão para codificar valores de luminância das imagens. Esta função não linear usada para restaurar pixels sombreados é dada por:

$$y = (x)^{\frac{1}{\gamma}} \quad (34)$$

A compensação então é simplesmente obtida pela exponenciação dos valores de entrada dos pixels de sombra (x) por meio do inverso de γ . Contudo, a escolha do parâmetro não é trivial, sendo utilizadas geralmente estatísticas retiradas de amostras da imagem sem o efeito de sombra. Na metodologia serão usados os valores da média entre as áreas de sombras detectadas e de sua área de influência gerada pelo buffer para determinar o melhor valor usado na correção. O resultado será restaurado na imagem original pretendendo contribuir para eliminação dos efeitos das sombras. Outras metodologias que abordam sobre a correção de áreas de sombras com um parâmetro *gamma* podem ser encontradas em Nakajima, Tao e Yasuoka (2002) e Zhan et al. (2005).

4 APRESENTAÇÃO E ANÁLISE DOS RESULTADOS

Nesta seção são apresentados os resultados obtidos e as análises realizadas para validar a metodologia proposta. Primeiramente, os experimentos para as imagens orbitais serão mostrados de acordo com a sua região de estudo e na sequência, os resultados da validação da metodologia para as imagens aéreas são apresentados.

4.1 Experimentos para área urbana de São Paulo

Neste primeiro experimento, a metodologia de detecção e restauração de sombras é aplicada para as imagens de São Paulo, de acordo com as etapas apresentadas na seção anterior. Os recortes foram submetidos ao algoritmo que realiza o processamento de forma semi-automática, sendo necessário apenas determinar o parâmetro de área para o processo da detecção. Na Figura 25 estão dispostos alguns exemplos de recortes utilizados para validar a metodologia, que conforme mencionado anteriormente, foram definidos para uma melhor visualização dos resultados e também superar limitações do *Matlab*, onde o algoritmo foi desenvolvido. Como pode ser observado, o principal problema da aplicação da metodologia em recortes urbanos é a quantidade de sombras heterogêneas, desde as de pequeno porte ocasionadas por veículos, até as de grande dimensão ocasionadas por edifícios, o que ocasiona, muitas vezes, um conglomerado de sombras.




Figura 25. Exemplo de recortes da imagem de São Paulo.

Um realce nas imagens foi realizado para que fosse possível discernir os objetos da cena, já que as imagens pancromáticas apresentavam baixo contraste. O realce foi feito através do ajuste global das imagens para uma intensidade média igual a 90 e desvio padrão de 20,

definidos com base na melhoria visual das imagens. Desta forma, as imagens originais que possuíam baixo contraste, como observado pelo exemplo de um recorte disposto na Figura 26 e seu respectivo histograma disposto em (b). Mais informações podem ser observadas na imagem (Figura 26 (c)) que teve seus níveis de intensidade melhores distribuídos em torno da média adotada (Figura 26 (d)) e não sofreram alterações em suas características originais.




Figura 26. Ajuste global da média aplicado para as imagens utilizadas. (a) Recorte original e (b) seu histograma; (c) Imagem contrastada e (d) o histograma resultante do ajuste da média.

A primeira etapa da metodologia consistiu na detecção dos objetos de interesse. A palavra objeto neste caso refere-se às áreas com sombras como o alvo a ser isolado em relação aos demais componentes da cena. Para isto, um *top-hat* por fechamento de área foi aplicado nas imagens, pois como já mencionado, realça padrões escuros como as sombras. Na metodologia, o fechamento por área foi utilizado para garantir que o EE atue nas estruturas da imagem de acordo com sua conectividade, que neste caso foi de vizinhança igual a oito pixels (caixa). Assim, o EE independe da forma para aplicação e se torna adaptativo, ou seja, a cada seção transversal da imagem é realizada a filtragem dos padrões escuros com área igual ou menor ao valor definido, dentro da conectividade imposta.

Para a definição de um valor adequado do critério de área nas imagens de São Paulo, uma análise do comportamento da metodologia em função do parâmetro foi realizada. Na Figura 27 a comparação do resultado da metodologia aplicada a diferentes valores de área é mostrada, sendo utilizado o recorte disposto na Figura 25(a) utilizado para ilustrar essa comparação e as demais etapas do método. O alto valor dos limiares levam em conta a alta resolução espacial das imagens e a dimensão dos objetos, que neste caso, devido à densidade urbana de São Paulo ser elevada, apresenta grande parte da superfície coberta por sombras. Além disso, a conectividade do EE analisa uma grande quantidade de pixels vizinhos e com um parâmetro inadequado, a transformação não fará efeito em sombras próximas que se encontram aglomeradas. Este efeito pode ser visto na Figura 27 (a) e (b), na qual o parâmetro foi ineficaz para identificar a grande área de sombra central. Já com o aumento desse valor, uma detecção sucessiva das áreas de interesse pode ser percebida, até certo momento em que não há mais diferenças expressivas entre os objetos identificados.

Dessa maneira, ao se adotar um limiar entre os da sequência da Figura 27 (d-f), não haverá perdas significativas de objetos de interesse. Este comportamento ilustra a vantagem da metodologia ao se utilizar dos filtros morfológicos, pois mesmo que um valor de área seja superestimado, a propriedade de idempotência garante um controle na perda de informação.




Figura 27. Comportamento da metodologia de detecção em função do limiar de área (em pixels): (a) 5.000; (b) 10.000; (c) 20.000; (d) 25.000; (e) 30.000; (f) 35.0000.

Um fechamento de área igual a 30.000 pixels foi então aplicado sobre as imagens, como forma de garantir que todas as sombras fossem filtradas e recuperadas na sequência pela transformação *top-hat*. O resultado da metodologia é mostrado na Figura 28, na qual a imagem após o processo de fechamento (a) apresenta em destaque os padrões mais claros, já que os vales foram removidos. Essa seleção feita de maneira indireta é realçada quando realizado o *top-hat*, conforme mostrado em (b). Para melhor visualização do resultado, um realce pelo ajuste da média também foi aplicado na imagem do *top-hat*, onde se percebem de maneira sutil informações ofuscadas pela presença de sombras, passíveis de serem recuperadas. O resultado do *top-hat* é uma imagem de padrão bimodal, com o fundo e objetos bem separados entre si, o que facilita na aplicação da binarização automática pelo método de Otsu (1979), cujo resultado é mostrado em (c).




Figura 28. Exemplo da etapa de detecção aplicada a um recorte com áreas de sombras. (a) Fechamento por área de 30.000 pixels; (b) *Top-hat*; (c) Binarização automática por Otsu.

Posteriormente uma abertura de área com 5 pixels foi aplicada, com o intuito de remover somente os pixels conectados inferiores ao limiar citado, pois estes acabam não representando áreas de sombras significativas e por isso pode ser considerados como ruídos. Além disso, estes pixels podem apresentar problema na etapa de restauração, pois não carregam muitas informações sobre eles resultando em valores saturados, que degradam a qualidade visual da imagem restaurada. A Figura 29 mostra a comparação entre a imagem binarizada (a) e o resultado da remoção dos ruídos pela abertura de área (b), destacando alguns detalhes removidos pela abertura de área.




Figura 29. Resultado da abertura de área com limiar de 5 pixels. (a) Imagem Binarizada com ruídos destacados; (b) Imagem Binarizada com os ruídos removidos.

A partir das imagens binárias resultantes da detecção, o próximo passo consiste em verificar se o que foi detectado nas imagens corresponde mesmo as áreas de sombras presentes nas áreas de estudo e, quantificar a eficiência do método.

Avaliação da qualidade da detecção

A avaliação do desempenho do método foi feita de duas formas: primeiramente a análise qualitativa foi realizada através da sobreposição das bordas dos alvos detectados como sombras, na imagem original. Nesta etapa, uma análise visual foi realizada, na qual verifica-se, por meio da delimitação das feições, se ocorreram possíveis erros de posicionamento ou falhas na execução do método. Na Figura 30 é ilustrado um exemplo da sobreposição das bordas das feições detectadas (b) nas imagens originais (a).

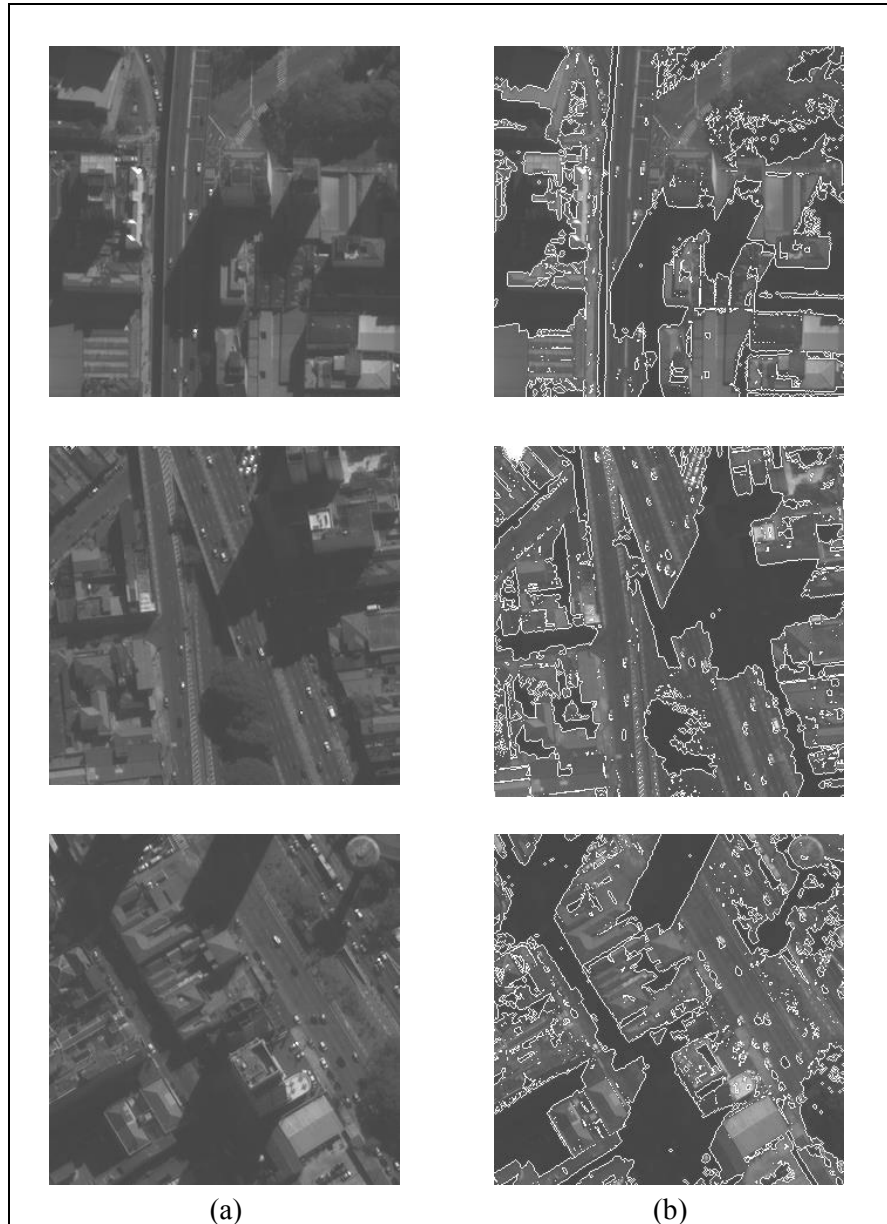


Figura 30. Análise qualitativa do resultado da detecção através da comparação visual entre: (a) Recortes originais e (b) Sobreposição das bordas das feições detectadas, nas imagens originais.

Da análise visual dos resultados apresentados, embora seja mais fácil perceber as maiores áreas de sombras detectadas, verifica-se que a metodologia mostrou-se adequada e sensível mesmo em pequenas áreas, como no caso de sombras ocasionadas por árvores e por automóveis. A Figura 31 mostra detalhes de sombras projetadas por veículos que foram detectadas pelo algoritmo, evidenciando o sucesso na identificação de pequenas sombras em imagens com heterogeneidade de alvos elevados. Portanto, a partir da verificação qualitativa dos resultados pôde-se perceber a coerência da detecção. Contudo, para não ficar somente na análise visual, uma análise quantitativa dos resultados com base nos índices de completeza e correção foi realizada.

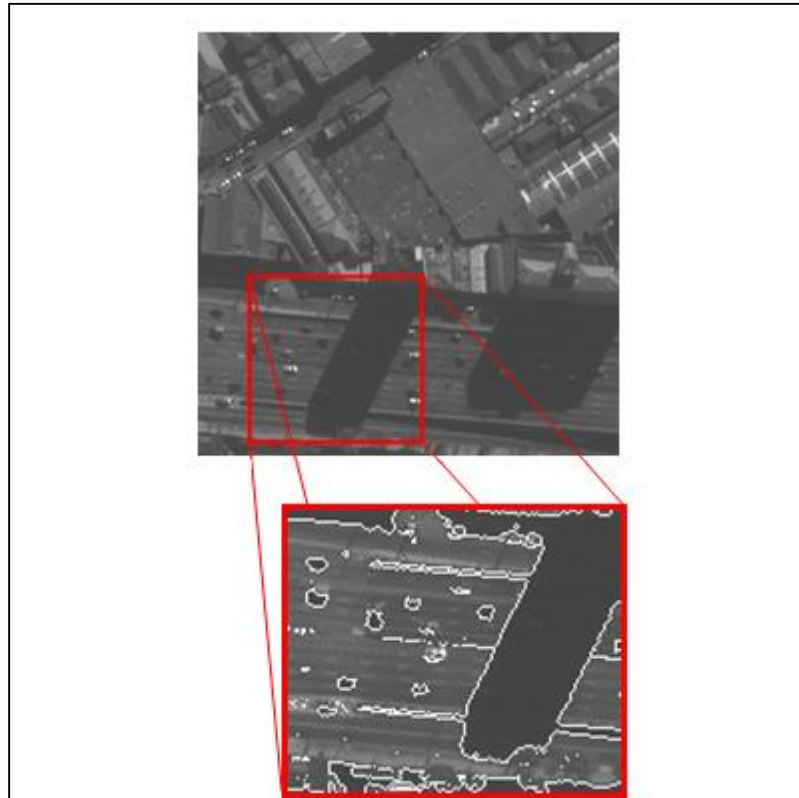


Figura 31. Exemplos do desempenho do algoritmo frente aos diversos alvos. (a) e (b) Detalhe do sucesso na identificação de pequenas sombras ocasionadas por veículos.

Avaliação quantitativa da detecção

Para avaliar a eficiência do método, além da análise visual, uma análise quantitativa dos resultados da detecção foi realizada a partir dos índices de completeza e correção, calculados conforme descrito na seção 2.5. Para isto, foram gerados manualmente os dados de referência, também chamados de *ground truth* (GT), os quais contêm a demarcação das áreas de sombras, extraídas com base no recorte da imagem original. No momento da geração do GT, a inclusão ou não de uma área de sombras foi guiada pela interpretação da imagem com ajuda da manipulação do contraste e do *software Google Earth* para visualização de detalhes. Em posse dos dados de referência, o algoritmo realiza o processo de detecção, compara ambos (feições detectadas com dados de referência) e calcula automaticamente os valores dos índices para cada recorte e os armazena em um arquivo.txt. Foram gerados 16 GT's de recortes da imagem de São Paulo, sendo alguns deles mostrados na Figura 32, na qual também estão dispostos para efeito de comparação, o recorte original e a imagem contendo as feições detectadas (resultante da aplicação da primeira etapa da metodologia).

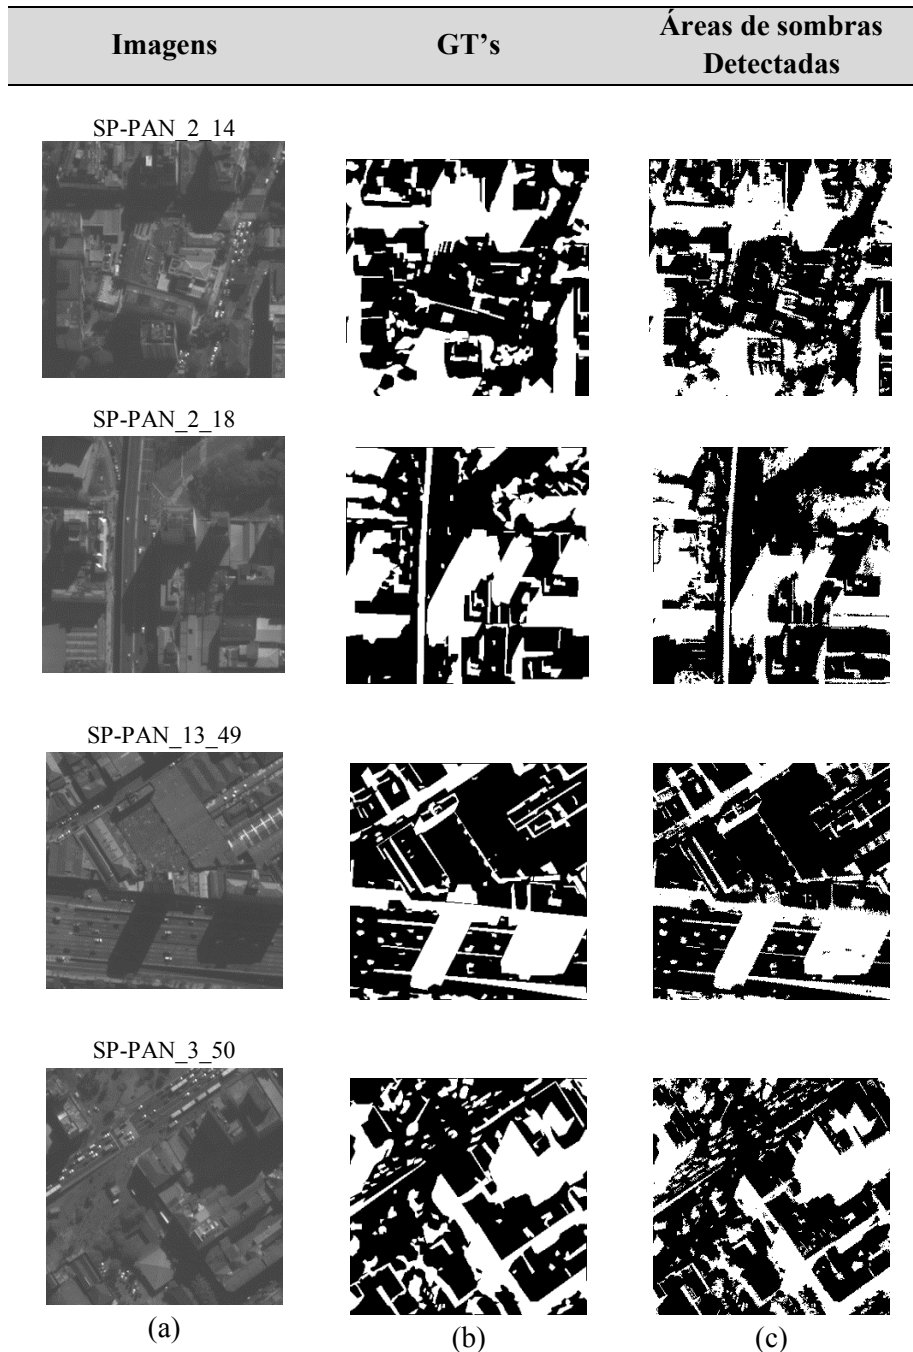


Figura 32. Exemplos de dados utilizados para avaliação quantitativa da primeira etapa da metodologia. (a) Imagem original; (b) *Ground Truth* gerado manualmente; (c) Resultado da detecção.

A Tabela 1 apresenta o resultado dos índices calculados para os 16 recortes que dispunham de GT's. No geral, o método alcançou em média completudeza de $95,82\% \pm 3,22$ e correção de $93,45 \pm 2,54$. Para visualizar o comportamento dos índices, a Figura 33 apresenta um gráfico contendo os valores de completudeza e correção para as 16 imagens, conforme sequência apresentada na Tabela 1.

Tabela 1. Índices utilizados para a avaliação quantitativa da detecção.

Recortes	Completeza(%)	Correção(%)
SP-PAN_2_14	98,00	90,78
SP-PAN_2_18	92,38	90,93
SP-PAN_2_32	94,94	91,99
SP-PAN_2_39	98,59	86,95
SP-PAN_2_52	98,74	97,07
SP-PAN_3_50	95,60	93,36
SP-PAN_4_39	99,17	94,46
SP-PAN_6_27	98,26	94,13
SP-PAN_8_40	93,70	94,28
SP-PAN_11_40	94,79	96,53
SP-PAN_11_43	96,85	95,03
SP-PAN_13_49	96,29	95,10
SP-PAN_14_20	98,43	95,07
SP-PAN_36_39	86,32	91,24
SP-PAN_44_31	94,87	94,30
SP-PAN_50_30	96,14	94,04

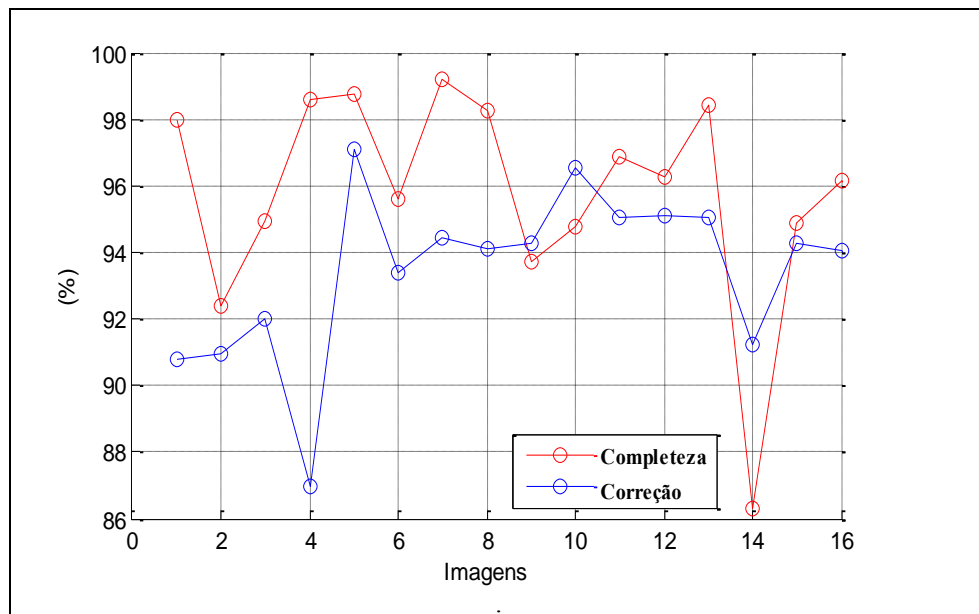


Figura 33. Comportamento dos índices de completeza e de correção para os recortes conforme a Tabela 1.

Os índices indicaram um bom desempenho do método para as imagens avaliadas, o que deve ser destacado, uma vez que são recortes de uma região urbana muito complexa, a qual contém diversos objetos ocasionando sombras de variados tipos e tamanhos. O índice de completeza, conforme pode ser observado na Figura 33 apresentou para a maioria das imagens, valor superior aos de correção. No entanto, o recorte SP-PAN_36_39 apresentou um valor

discrepante em relação aos demais com completeza abaixo de 90%. Na Figura 34 (d) é apresentada uma comparação entre o resultado da detecção e o GT para verificar as possíveis causas do baixo índice alcançado. Na Figura 34 (d) as áreas em vermelho representam as áreas que não foram identificadas pelo método como sendo áreas de sombra, mas que constam no GT, chamadas de falsos negativos (FN). Já as áreas em azul representam os falsos positivos (FP), ou seja, áreas que foram detectadas pelo método incorretamente, pois não constam no GT. A partir da análise das imagens da Figura 34, é possível verificar que o método apresentou problemas para identificar as sombras de uma área de vegetação densa, presente no canto inferior direito da imagem. A vegetação é um dos problemas enfrentados pela maioria dos métodos presentes na literatura, pois devido a variação no dossel, sombras são formadas sobre suas próprias folhas, o que gera feições fragmentadas e dificulta a geração de um GT que represente com exatidão a cena real.




Figura 34. Análise do baixo índice de completeza para o recorte SP-PAN_36_39. (a) Recorte original; (b) Resultado da detecção; (c) *Ground Truth* e (d) Comparação entre a detectada e o *GT*.

Entretanto, apesar do resultado da completeza ter apontado que algumas áreas que constam no GT deixaram de ser identificadas pelo método, nota-se que o GT engloba algumas áreas da própria vegetação que não fazem parte da sombra. A dificuldade em delimitar certas áreas de sombras, como neste caso, com fragmentos de sombras ocasionadas por folhas, reflete

no baixo índice de completeza do método, mesmo que inverídico em certos casos, já que os dados de referência são tidos como verdade.

Um dos maiores problemas enfrentados pelos métodos que visam a segmentação das regiões de sombras nas imagens segundo Adeline et al. (2013) é a confusão causada por objetos que possuem baixa resposta espectral, como os corpos d'água. Para verificar a eficiência do método neste sentido, a Figura 35 apresenta uma comparação do recorte SP-PAN_11_40 que contém um corpo d'água de grande extensão, com o resultado da detecção. Nota-se na Figura (b) que a sombra projetada devido a diferença de altura entre a estrada marginal e o córrego foi corretamente identificada pelo método. Apenas uma pequena faixa (em vermelho) representando FN's pode ser vista, a qual indica uma região de sombra que não foi detectada pelo método. Uma explicação pode ser atribuída à geração manual do GT, que foi imprecisa ao delimitar o fim da sombra sobre o córrego, mesmo porque, regiões de penumbra dificultam essa delimitação.

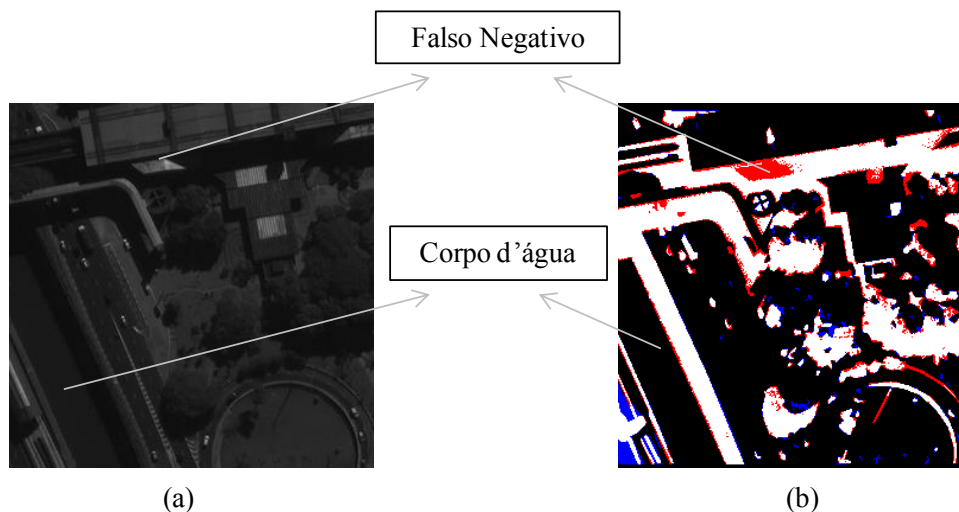


Figura 35. Análise do desempenho do método na presença de corpo d'água. (a) Recorte SP-PAN_11_40 original; (b) Resultado da detecção sobreposto ao GT.

Outro problema frequentemente observado nas metodologias, como apontado na revisão realizada por Adeline et al. (2013) é a classificação dos objetos brilhantes presentes nas áreas de sombra, que muitas vezes são classificados como regiões de não sombra. Ainda na Figura 35 (b), pode ser visto um exemplo da ocorrência deste fato, na qual a região apontada pela seta, classificada como FN devido não ter sido detectada pelo método como sendo uma região de sombra, por não possuir a característica principal das sombras, que é a baixa resposta radiométrica. Mesmo com a ocorrência de falhas, tais como as apontadas, o método conseguiu resultado favorável alcançando aproximadamente 96% de completeza e 93% de correção.

Etapa de Restauração

Uma vez identificadas as áreas de sombras nas imagens, o próximo passo consiste em realizar uniformização entre essas áreas e suas áreas vizinhas, proporcionando uma melhoria visual para toda a imagem. A minimização das diferenças radiométricas, conforme abordado anteriormente, foi feito com base nos fatores radiométricos das áreas vizinhas às regiões de sombras identificadas. Em outras palavras, assume-se que a textura dos pixels com influência de sombras não é radicalmente diferente dos seus vizinhos. Assim, os níveis de intensidade dos seus vizinhos próximos podem ser utilizados para substituir os que foram prejudicados pelas sombras. Na Figura 36 é apresentado um exemplo da região de influência considerada, para cada feição detectada como sendo região de sombra. A Figura 36 (a) apresenta o recorte original, enquanto que a (b) apresenta as regiões de sombras detectadas pela primeira etapa da metodologia e em (c) o *buffer* da região de influência gerado pelo gradiente morfológico por dilatação.

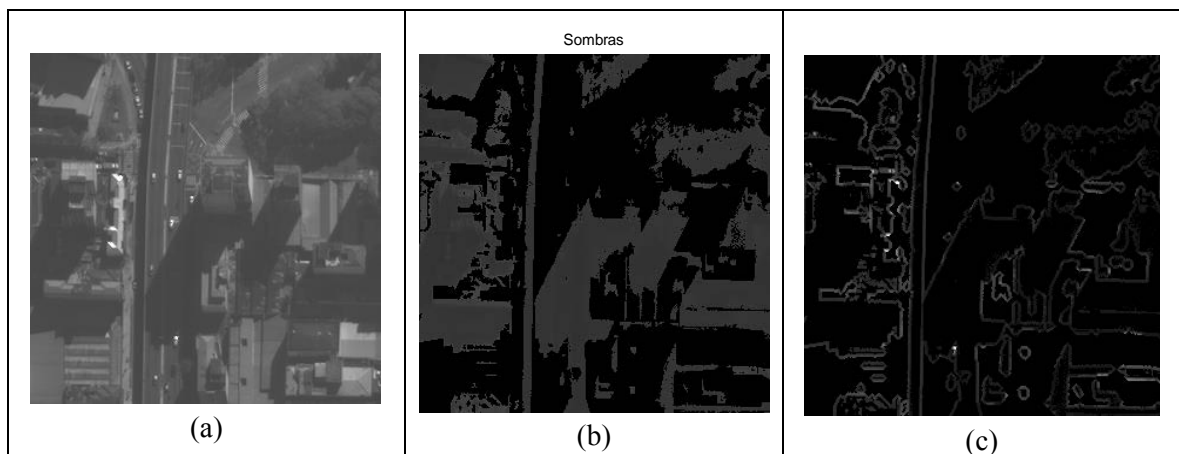


Figura 36. Exemplo da geração do buffer. (a) Imagem original; (b) Resultado da metodologia para a detecção das áreas de sombras e (c) *Buffer* gerado.

O *matching* entre as áreas é realizado localmente, ou seja, para cada objeto rotulado e sua respectiva região de influência gerada, calcula-se o histograma equalizado acumulado. Com base nesses histogramas atribui-se para cada pixel da área de sombra, um valor de ND da área de referência, de modo a igualar ou aproximar os histogramas transformados. Utilizando a mesma cena da Figura 36, a Figura 37 apresenta em (a) a identificação de cada objeto, em (b) o exemplo de um objeto e seu histograma transformado e sua respectiva área de influência em (c).

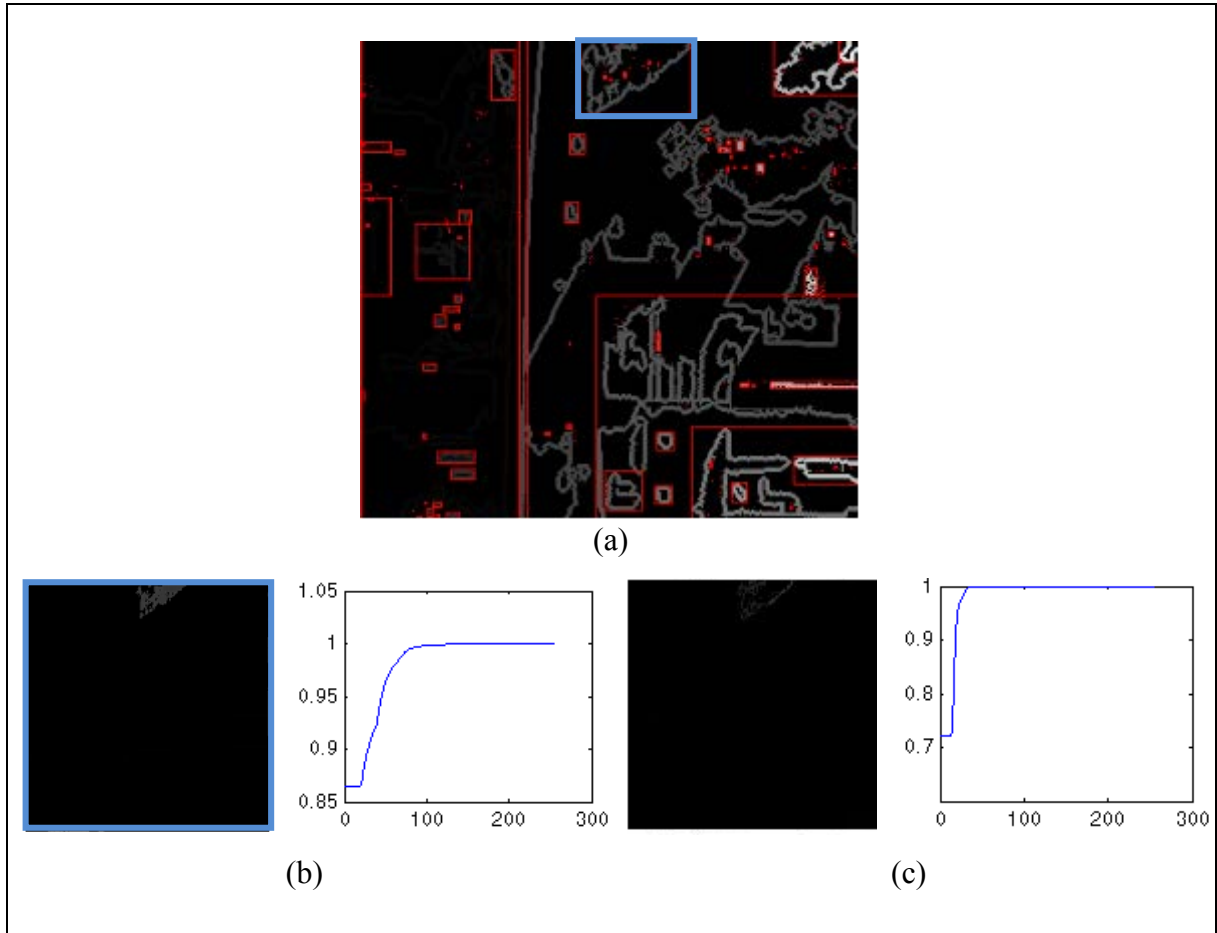


Figura 37. Procedimento para o matching local. (a) Objetos identificados individualmente; (b) Área de sombra rotulada e seu respectivo histograma equalizado acumulado e (c) Área de referência e seu histograma utilizado para o matching.

O algoritmo implementado realiza a detecção e a correção para as imagens de maneira automática, necessitando apenas da informação do parâmetro de área, como já comentado anteriormente. O algoritmo realiza todo o processo, independentemente da quantidade de imagens, e fornece como resultado, uma imagem restaurada. A complexidade do cálculo da equalização para cada objeto da imagem e o *matching* para cada pixel, acaba resultando num aumento do tempo de execução do algoritmo. Contudo, como não é o foco do trabalho, a otimização poderá ser prevista em trabalhos futuros. Alguns exemplos do resultado da aplicação do algoritmo são mostrados na Figura 38.

O resultado apresentou uma melhoria na qualidade visual da imagem, minimizando as diferenças radiométricas proporcionadas pelas sombras e conseguiu em alguns casos, deixar evidentes alvos, tais como carros, detalhes de vias e algumas construções que estavam ocultas. Contudo está aquém do que se espera de uma imagem livre dos efeitos de sombra. Além disso, alguns ruídos permaneceram nessas áreas, principalmente nas áreas de transição, com uma borda percebida entre elas depois da restauração. Em áreas com grande extensão de sombra,

muitos são os objetos que são ocultos e a área de referência gerada pode não ser representativa para todos eles, uma vez que considera apenas uma pequena região ao redor.



Figura 38. Resultado da restauração. (a) Recorte original; (b) Resultado da restauração na imagem.

Na Figura 39 é feita uma comparação entre os valores originais de uma região de sombra e os valores obtidos com o *matching*.

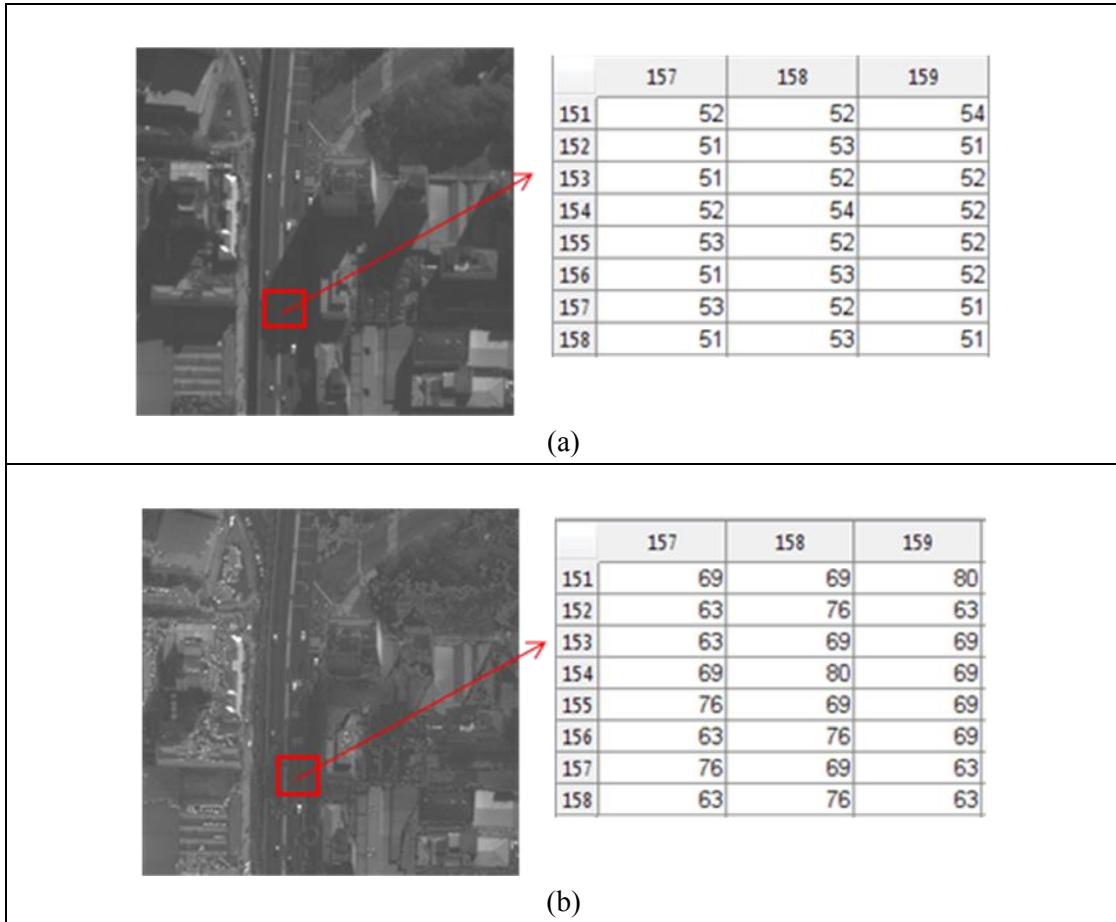


Figura 39. Resultado numérico do matching para uma região do recorte. (a) Região identificada em vermelho e seus respectivos valores originais com efeito de sombras dispostos na tabela; (b) Valores obtidos após o *matching* para a mesma região.

Apesar da análise visual do resultado aparentar que não houve grandes melhorias, o resultado numérico se mostra coerente, contudo não há com o que se comparar, uma vez que não se dispõe de dados radiométrico de referência da área restaurada. Sendo assim, vale a pena verificar o comportamento do histograma da imagem original e o da sua imagem restaurada dispostos na Figura 40. Como é possível observar, uma distribuição dos valores ocorreu, sendo que o pico apresentado no começo do histograma da Figura 40 (a) representado pela quantidade de padrões escuros provocados pelas sombras foi reduzido em comparação ao histograma em (b).



Figura 40. Comparação entre os histogramas de um recorte: (a) antes e (b) depois do *matching*.

Refinamento do método

Com o objetivo de amenizar os efeitos da penumbra e dos ruídos, provocados nas bordas das feições restauradas, na imagem original, um pós-processamento foi realizado com base no filtro da mediana, o qual permite remover o ruído sem alterações significativas na imagem. As bordas podem ser consequência da penumbra, e seu surgimento se deve ao fato da escolha de um único limiar para a binarização da imagem. Essas regiões possuem valor de brilho intermediário, por serem regiões de transição, e ao serem incluídas no *matching*, geraram valores discrepante resultando em bordas brilhantes. Assim, utilizando o gradiente morfológico por erosão, os pixels pertencentes a região de penumbra foram removidos e o *matching* recalculado. Com o gradiente morfológico por dilatação, as áreas entre as regiões recuperadas e a imagem original foram encontradas, e na sequencia aplicou-se a mediana, a qual reduziu o efeito esbranquiçado da borda, além de eliminar alguns ruídos nas regiões recuperadas. O resultado obtido é apresentado na Figura 41, na qual se pode notar a presença de detalhes não perceptíveis anteriormente (Figura 39), como no caso da faixa contínua entre o arruamento destacado na Figura 41(a). Já em (b) podem ser notados os telhados recuperados, que haviam sido obstruídos pelos edifícios. Os resultados mostrados em (c) e (d) também exibem a melhoria da informação recuperada, com efeito reduzido da borda brilhante, o que evidencia a importância do refinamento do método.

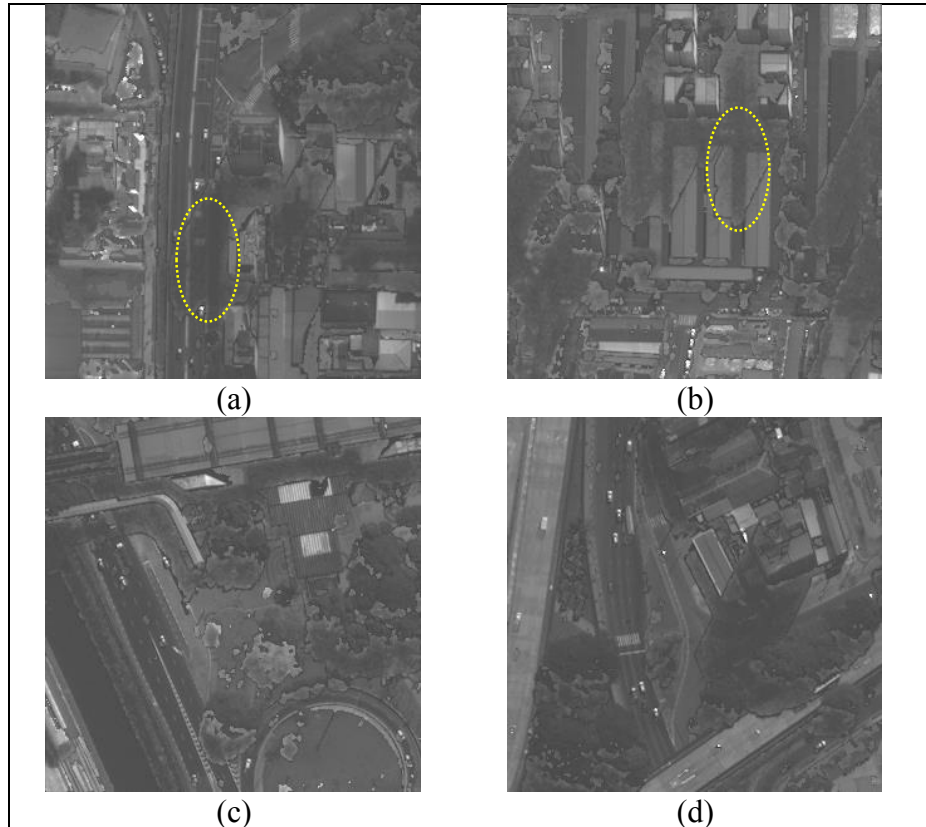


Figura 41. Resultado do refinamento aplicado às imagens.

4.2 Experimentos para área urbana de Presidente Prudente

A metodologia foi avaliada da mesma forma para os recortes da imagem de Presidente Prudente que contém menor densidade de construções elevadas, as quais são responsáveis por extensas áreas de sombras. Neste caso, a maioria das áreas de sombras encontradas, conforme pode ser observado na Figura 42 são provenientes devido referente à presença de vegetação, construções de pequeno porte como casas e alguns edifícios intermediários. Portanto, a região apresenta ocorrência esparsa de sombras de grande dimensão.

Assim como as imagens de São Paulo, os recortes da região de Presidente Prudente também precisaram de um realce para permitir a visualização dos seus detalhes e facilitar a interpretação dos resultados. Apesar de possuírem a mesma resolução espacial, também foi preciso uma análise do comportamento da metodologia em função do parâmetro de área, assim como realizado para as imagens de São Paulo, já que os recortes apresentaram diferentes dimensões de sombras. Os testes foram feitos de modo a encontrar um valor único para os recortes e garantir que todas as áreas sejam identificadas.



Figura 42. Exemplos de recortes da imagem da região urbana de Presidente Prudente, utilizados para a validação da metodologia.

Um fechamento por área de 15.000 foi então realizado e o *top-hat* na sequência aplicado. Os resultados para um recorte pode ser observado na Figura 43, na qual também está disposto em (c) o resultado da binarização automática. Pode-se perceber que muitas das sombras detectadas são pequenas, geralmente ocasionadas por casas, mas que o limiar garantiu a identificação de uma região maior de sombras disposta na parte inferior direita do recorte, ocasionada por um edifício de porte intermediário. Ruídos e regiões muito pequenas foram removidos pela abertura com 5 pixels de área e a verificação dos resultados é feita na sequência.




Figura 43. Resultado da metodologia aplicado a um recorte. (a) Fechamento por área de 15.000 pixels; (b) *Top-hat*; (c) Binarização automática por Otsu.

Avaliação da qualidade da detecção

Uma vez obtido o resultado da detecção, é feita a sobreposição da borda das feições detectadas, na imagem original, conforme mostra a Figura 44. Pela análise visual é possível comprovar que a metodologia se mostrou coerente, também para as imagens de Prudente, pois conseguiu delimitar as principais regiões de sombras existentes nos recortes conforme pode ser visto na Figura 44 (b).

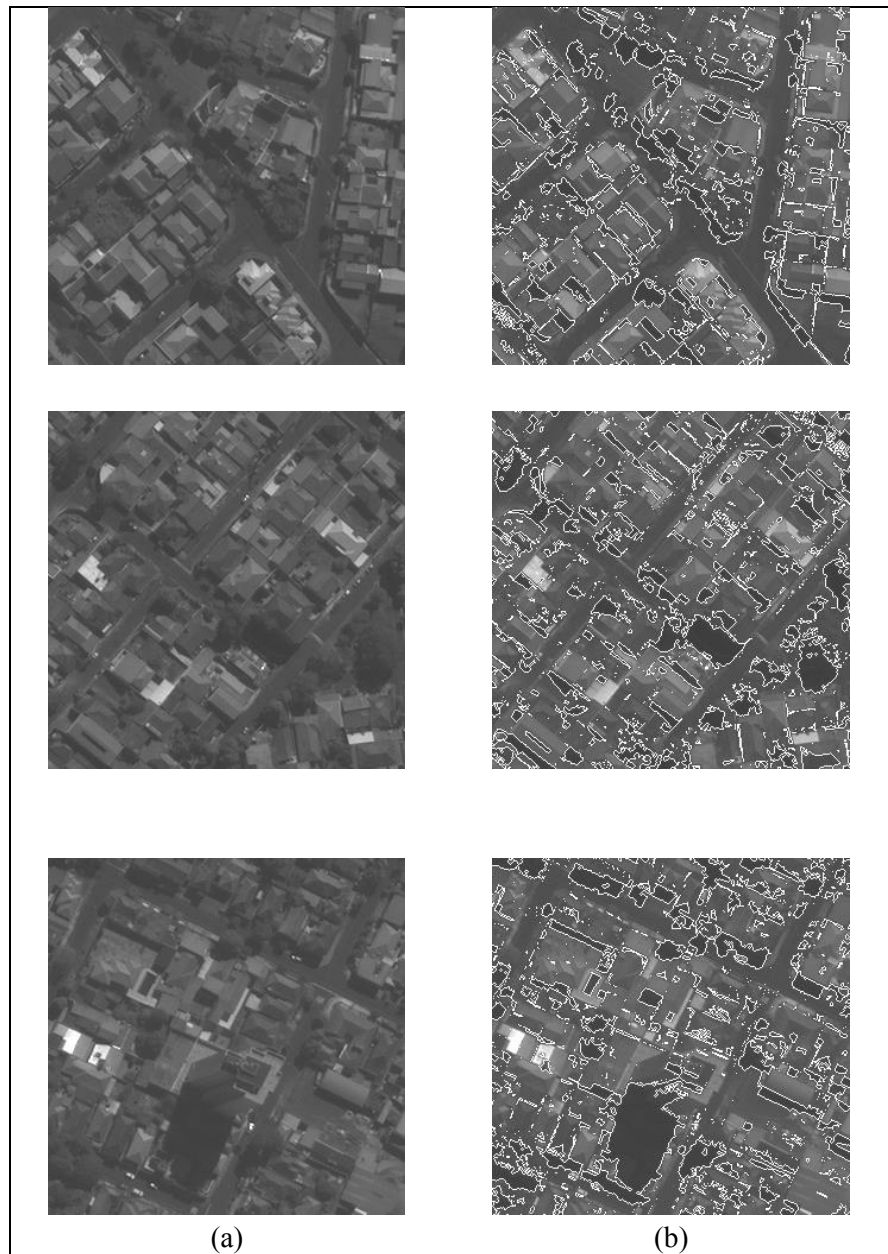


Figura 44. Análise qualitativa do resultado da detecção através da comparação visual entre: (a) Recortes originais e (b) sobreposição dos vetores detectados nos recortes originais.

A análise do desempenho quantitativo também foi realizada, por meio do cálculo dos índices de completude e correção. Foram gerados 22 GT's para as imagens de Prudente sendo alguns deles apresentados na Figura 45, juntamente com seus respectivos recortes utilizados e o resultado da detecção para efeito de comparação.


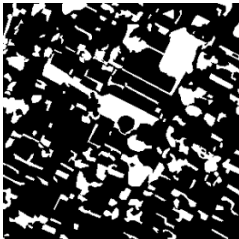
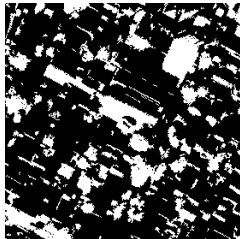

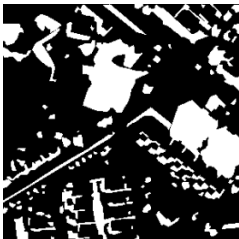


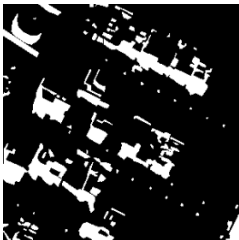




Imagens	GT's	Áreas de sombra Detectadas
Prudente-PAN_41_36 		
Prudente-PAN_7_39 		
Prudente-PAN_4_12 		
Prudente-PAN_5_17 		
(a)	(b)	(c)

Figura 45. Exemplos de dados utilizados para avaliação quantitativa da primeira etapa da metodologia. (a) Imagem original; (b) Ground Truth gerado; (c) Resultado da detecção.

Na Tabela 2 podem ser conferidos os resultados encontrados para os índices. No geral, o método apresentou para os 22 recortes referentes a imagem de Prudente completude média de $93,33\% \pm 2,47$ e correção de $83,75\% \pm 8,06$. Para melhor visualizar o comportamento dos índices, a Figura 46 apresenta os valores de completude e correção para os 22 recortes analisados, conforme sequência apresentada na Tabela 2.

Tabela 2. Índices calculados para a avaliação quantitativa da detecção.

Recortes	Completude (%)	Correção (%)
PP-PAN_1_28	93,97	92,48
PP-PAN_2_44	96,53	91,31
PP-PAN_2_6	97,45	83,54
PP-PAN_3_10	97,67	86,57
PP-PAN_3_29	90,78	89,81
PP-PAN_3_48	98,32	74,85
PP-PAN_4_12	94,23	88,71
PP-PAN_5_11	93,61	89,55
PP-PAN_5_15	93,26	85,57
PP-PAN_5_17	94,45	93,28
PP-PAN_6_42	97,26	79,79
PP-PAN_7_23	91,18	84,25
PP-PAN_7_39	93,71	83,10
PP-PAN_12_21	96,64	68,42
PP-PAN_28_29	90,64	88,30
PP-PAN_39_4	95,39	85,11
PP-PAN_44_24	94,59	61,54
PP-PAN_48_26	90,70	71,01
PP-PAN_21_50	92,96	85,90
PP-PAN_22_47	90,67	86,21
PP-PAN_40_36	96,47	86,50
PP-PAN_41_36	94,81	86,72




Figura 46. Comportamento dos índices de completudeza e correção para os recortes conforme a Tabela 2.

Os resultados obtidos indicaram que o método teve um bom desempenho em relação ao índice de completudeza para a maioria das imagens. Porém os valores de correção apresentaram-se instáveis, com alguns entre 60% e 70% e uma análise dos motivos para que essa situação ocorresse foi realizada. O menor valor de correção foi apresentado pelo recorte PP-PAN_44_24, o qual é apresentado na Figura 47 (a). São apresentados, o resultado da detecção em (b), o GT em (c) e a sobreposição das feições detectadas no seu respectivo GT em (d). Assim, é possível perceber através da Figura 47 (d) a grande quantidade de áreas em azul (FP's), as quais foram classificadas erroneamente pelo método como sendo áreas de sombra. Pode-se notar que o método considerou grande parte da via como sendo sombra e também algumas áreas de vegetação rasteira. Além disso, existem áreas mostradas em vermelho (FN's), que estão no GT, mas que não foram detectadas. Entretanto, algumas regiões de vegetação no canto superior direito que em (d) aparecem como FP, parecem ter sido identificadas corretamente pelo método ao se olhar na imagem original (a), mas não estão devidamente delimitadas pelo GT.




Figura 47. Análise do baixo índice de completudeza para o recorte PP-PAN_44_24. (a) Recorte original; (b) Resultado da detecção; (c) *Ground Truth* e (d) Comparação entre a detectada e o GT.

O baixo valor apresentado para o recorte PP-PAN_12_21 também foi analisado, sendo as imagens mostradas na Figura 48. Como pode ser visto em (a), a cena possui algumas áreas de vegetação, porém um dos motivos do baixo valor do índice de correção é devido a detecção uma região de telhado, que foi detectado como sendo região de sombra. A segmentação excessiva causada pelo valor do limiar pode ter sido uma das causas, já que na imagem original comparecem somente áreas pequenas de sombras e um alto valor de área pode ter prejudicado a eficiência do método, neste caso.




Figura 48. Análise do baixo índice de completude para o recorte PP-PAN_12_21. (a) Recorte original; (b) Resultado da detecção; (c) Ground Truth e (d) Comparação entre a detectada e o GT.

Embora o baixo valor do índice de correção tenha sido atribuído ao fato do método falhar em algumas situações, como apresentadas anteriormente, vale a pena ressaltar que a adoção de um único limiar para todas as imagens na aplicação do *top-hat*, algumas vezes também é prejudicial ao método. Este fato, principalmente em áreas urbanas como a de Presidente Prudente, contendo em sua maioria sombras com pequena dimensão, mas com a presença de sombras maiores, em algumas partes da imagem. O valor de limiar que atendesse ambos os casos geraram confusões, como as mostradas na Figura 49 (a) e (b).

A região da rodovia destacada na Figura 49 (a), responsável pela confusão mostrada anteriormente na Figura 47 (d), aparece menos destacada em relação ao fundo do que as demais feições. O mesmo acontece como a região de telhado destacado na Figura 49 (b). Assim, apesar dessas regiões se encontrarem dentro do limiar de área e foram realçadas pelo *top-hat*, encontram-se menos destacadas do fundo do que outras regiões mais brilhantes presentes na mesma imagem. Quando se observa o recorte original, é possível concluir que essas regiões mais realçadas são regiões de sombras fáceis de perceber pela análise visual (Figura 47 (a) e Figura 48 (a)). Conseqüentemente, na etapa de binarização, a definição de um limiar inadequado, resultou posteriormente em um baixo valor do índice de correção. Um refinamento

da binarização neste caso conseguiria separar as diferentes classes de objetos presentes no resultado do *top-hat*, aumentando a eficiência por parte do método.

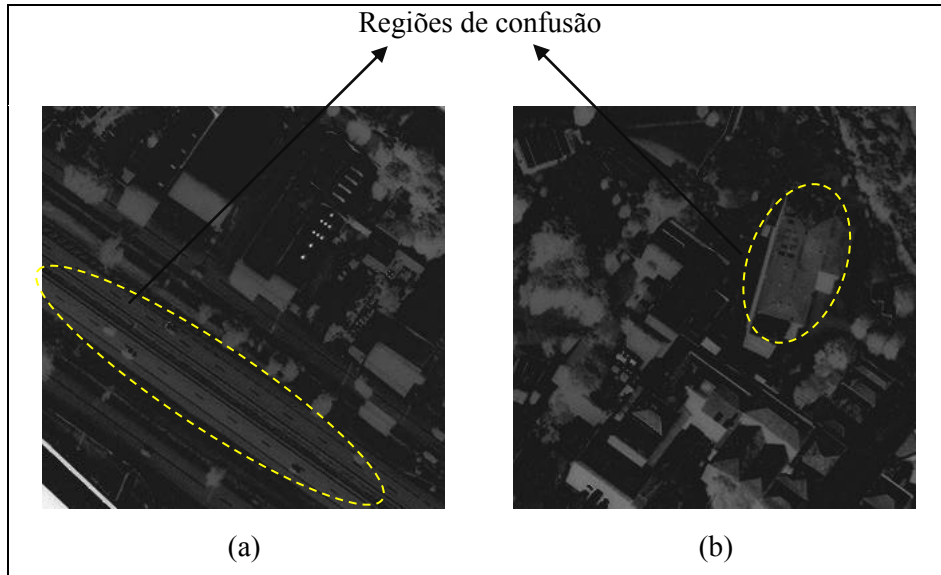


Figura 49. Análise das regiões de confusão na imagem *top-hat* antes da binarização.

Restauração das Imagens

De forma análoga às imagens de São Paulo, a minimização das diferenças radiométricas para as imagens de Presidente também utilizou as áreas identificadas como sombras para gerar o buffer de referência na aplicação do *matching* local. Na Figura 50 é apresentado um exemplo da obtenção da região de influência para um recorte original de Prudente mostrado em (a). Já em (b) estão às sombras detectadas na primeira etapa da metodologia e em (c) o buffer da região de influência gerado pelo gradiente morfológico por dilatação. Alguns dos resultados para os recortes de Prudente são mostrados na Figura 51.




Figura 50. Obtenção da região de influência para um recorte. (a) Recorte original; (b) Sombras detectadas; (c) Áreas de influência geradas




Figura 51. Resultado da restauração para um conjunto de recortes.

Conforme podem ser observadas na Figura 51, as regiões de sombras menores neste caso, apresentaram um resultado melhor do que em relação as de São Paulo. Isto pode estar ligado ao fato dos histogramas das regiões de influência representar aproximadamente os mesmos fenômenos oclusos pela sombra. Uma verificação do histograma antes e depois do matching para o recorte da Figura 50 está mostrada na Figura 52, na qual mais uma vez nota-se em (b) a suavização do pico no início do histograma de (a) representado a grande quantidade de sombras.



Figura 52. Comparação para um recorte de seus histogramas: (a) antes do matching e (b) depois.

Apesar de haver os efeitos das discontinuidades introduzidas pela restauração na imagem original, esses efeitos se apresentaram em menor grandeza. Contudo a etapa de refinamento do método também foi realizada e mostrada a seguir.

Refinamento do Método

A etapa de refinamento foi realizada da mesma forma para as imagens de Presidente Pudente, ou seja, as bordas ocasionadas pela restauração foram tratadas com o pós-processamento e os resultados obtidos são apresentados na Figura 53. Nota-se que os efeitos das bordas foram reduzidos e alguns detalhes foram revelados. Contudo, neste caso as sombras tem menor dimensão e por isso a variância de alvos oclusos é menor, resultando em regiões restauradas mais homogêneas. No caso da Figura 53 (a), a confusão com a vegetação rasteira, conforme pode ser vista no alto da imagem, gerou uma degradação visual, mas em contrapartida a restauração evidenciou o caminho por entre os edifícios. Os demais resultados obtidos não apresentaram fatores que degradaram a imagem, e possuem melhor qualidade visual do que a imagem original conforme expostas lado a lado na Figura 53.




Figura 53. Resultado do refinamento para recortes de Presidente Prudente.

4.3 Experimentos com imagens aéreas

Nesta seção são apresentados os resultados obtidos utilizando a metodologia proposta para imagens aéreas. Foram utilizados recortes de 1000 x 1000 pixels de duas imagens aéreas RGB, que abrangem a área urbana de Presidente Prudente. Uma análise para a definição do critério de área foi feita da mesma forma do que foi feita para as imagens orbitais, encontrando um valor de 50.000 pixels. O valor é coerente, uma vez que a resolução espacial é maior em comparação com as orbitais. Os canais foram processados separadamente para verificar a eficiência do método para as bandas disponíveis. Na Figura 54 é mostrado o resultado da detecção de um recorte para todas as suas bandas.

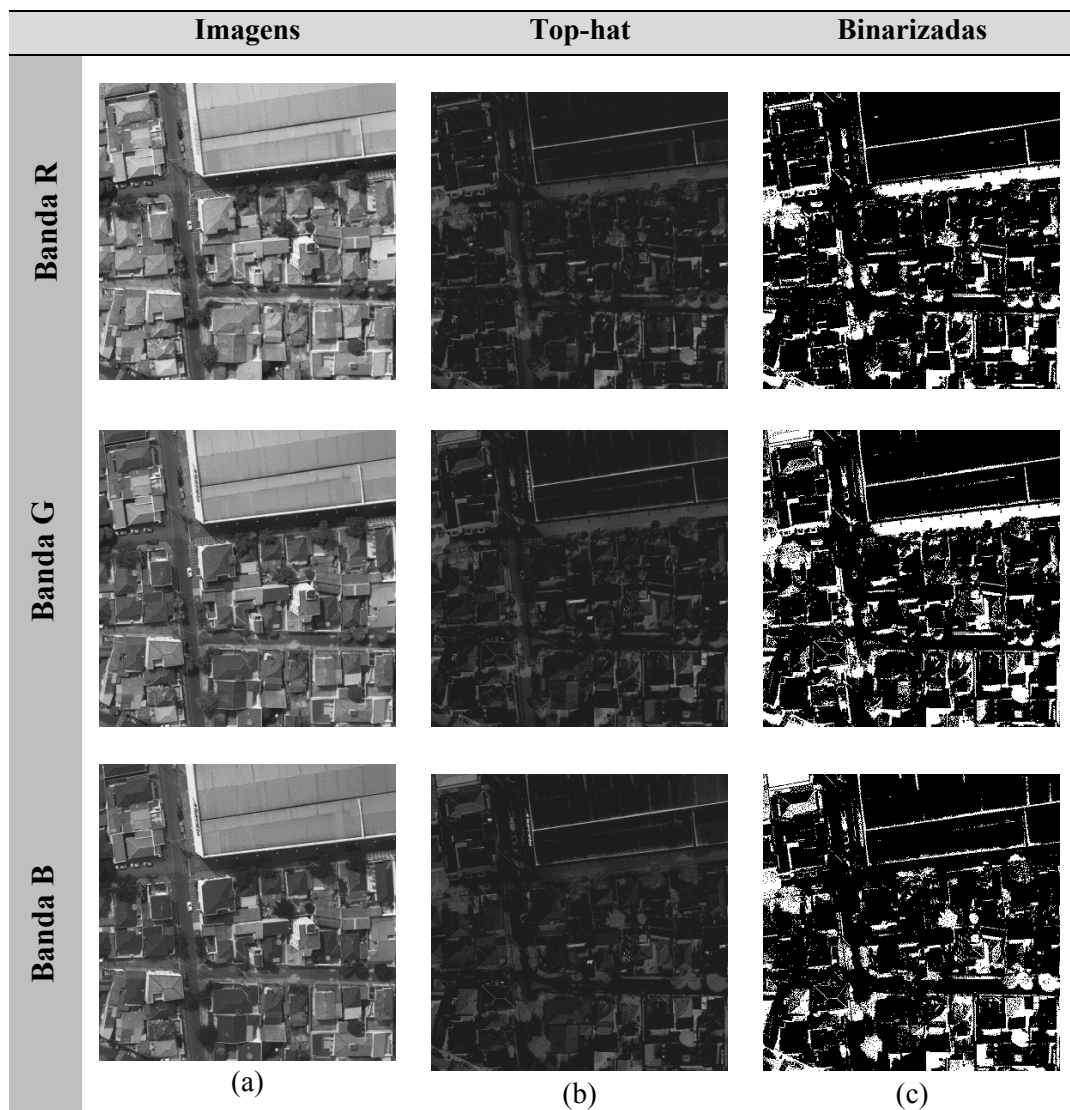


Figura 54. Resultado da metodologia para imagens aéreas. (a) Recorte original; (b) Resultado do top-hat realçado; (c) Binarização com remoção das áreas menores que 5 pixels.

Como pode ser visto na figura acima, a banda do vermelho apresenta mais contraste que as demais e o resultado se mostrou mais acertado. Contudo, nas demais bandas também a

metodologia conseguiu identificar a maioria de áreas de sombras, conforme pode ser visto pela comparação visual entre as imagens binarizadas.

A avaliação da qualidade para a detecção das imagens aéreas é somente qualitativa, uma vez que a geração do GT para elas é muito mais complexa. As imagens aéreas apresentam em geral, áreas de sombras com efeitos mais brandos do que as orbitais, deixando em evidência a maioria dos alvos oclusos, sendo difícil definir corretamente as regiões. Contudo, o algoritmo que atua sobre os vales da imagem, conseguiu ter um bom desempenho, evidenciado pela Figura 55, a qual apresenta os vetores da detecção sobre a imagem original para as três bandas. A banda do azul Figura 55 (c), não conseguiu identificar corretamente a sombra causada pelo maior edifício. Como pode ser observado pela sua imagem original (Figura 54(a)), a banda do azul apresenta o menor contraste entre os alvos, principalmente devido aos efeitos atmosféricos que são mais acentuados nessa banda e acabou gerando um resultado insatisfatório. Alguns exemplos dos resultados para outros recortes da imagem aérea, neste caso da banda vermelha são apresentados na Figura 56.




Figura 55. Análise do resultado da detecção através sobreposição dos vetores detectados nos recortes originais: (a) Banda do Vermelho; (b) Banda do Verde e (c) Banda do Azul.




Figura 56. Resultado da detecção para dois recortes referente à banda vermelha.

Na Figura 56 (b) é possível perceber confusão com a vegetação, muito provavelmente ocasionada pela baixa resposta radiométrica que o alvo apresenta nesta banda. A etapa de restauração das imagens também foi realizada e os resultados mostrados na Figura 57, para os recortes já apresentados. Devido a grande quantidade de informações presentes nas imagens em função da sua resolução espacial elevada, o algoritmo tem sua eficiência reduzida em termos de tempo. A quantidade de objetos a serem rotulados e o cálculo da estatística local para as imagens exigem um tempo médio de 5 minutos para cada imagem. O resultado para as imagens conseguiu revelar alguns detalhes ofuscados pela presença de sombras. Na Figura 57 (b), a área destacada em vermelho mostra que a sombra projetada no estacionamento e nos carros (ver Figura 56(b)) foi perfeitamente restaurada evidenciando os objetos.




Figura 57. Resultado da restauração para dois recortes. (a) Recorte da Figura 53(a); (b) Recorte da Figura 54 (b).

4.4 Comparação da restauração com a correção *gamma*

Para a comparação com outra técnica que pudesse corrigir os efeitos das distorções radiométricas ocasionadas pelas sombras, a correção *gamma* foi utilizada. A técnica consiste na exponenciação dos valores degradados por um parâmetro *gamma*, o qual deve ser escolhido de tal forma, a proporcionar a melhoria das áreas de interesse. Dessa forma, se aproveitando das áreas de influência geradas para o *matching*, um valor médio de intensidade foi obtido para cada imagem testada. O valor médio da imagem original também foi obtido, sem levar em conta as áreas de sombra obviamente. Assim, o parâmetro pode ser calculado com base na Equação 34 e aplicado para corrigir cada pixel presente na imagem detectada.

O resultado disposto na Figura 58 mostra que mesmo que as áreas tenham evidenciado sutilmente alguns objetos, a melhoria da informação não ocorreu por completo e a homogeneização entre as áreas também não apresentou resultado satisfatório. O resultado também teve efeito de descontinuidades apresentadas na imagem restaurada, porém, neste caso não houve a presença de ruídos nas áreas restauradas, como ocorreu com o matching.

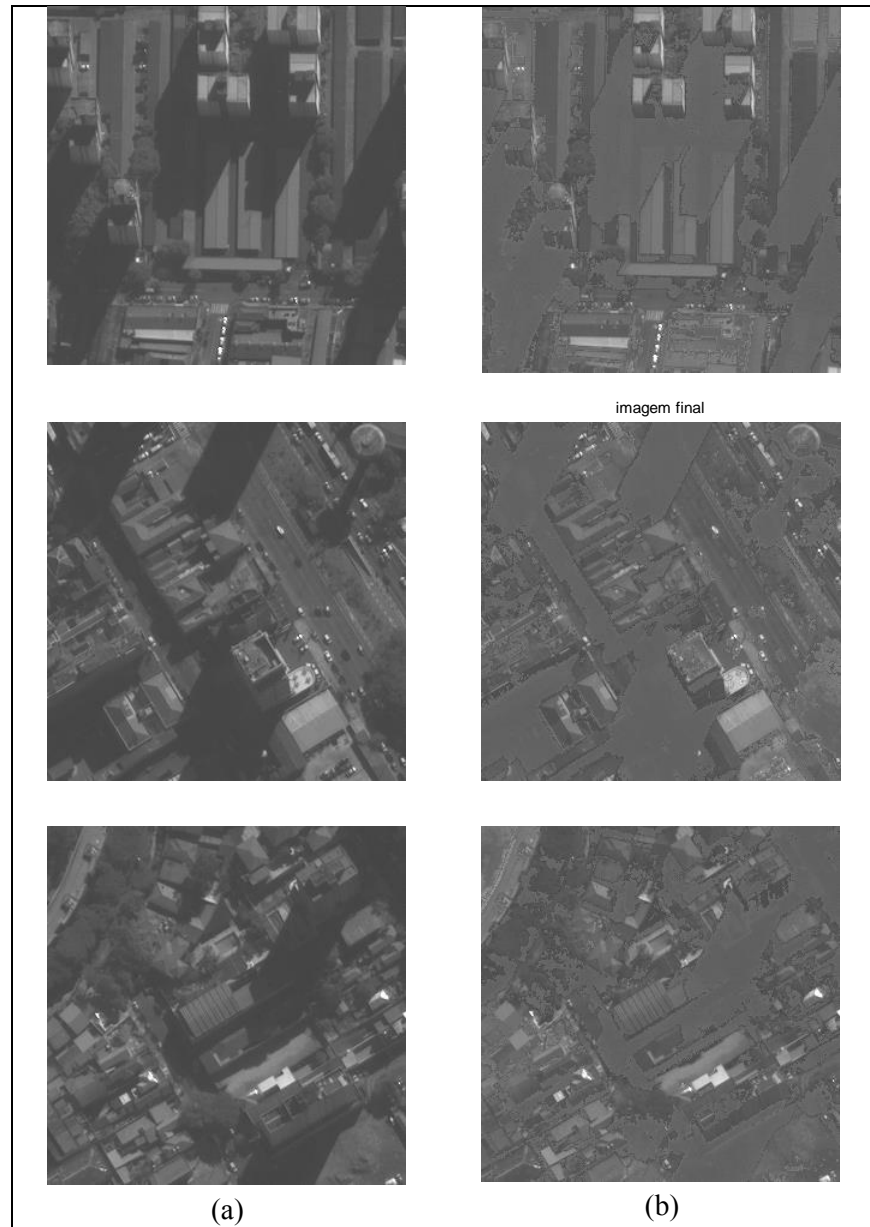


Figura 58. Resultado da restauração pela técnica de correção *gamma*. (a) Imagem original; (b) Restaurada pela correção *gamma*.

Para efeito de comparação, a mesma região mostrada na Figura 39 é usada para ilustrar o resultado numérico do *matching*, mostrado na Figura 59. Conforme pode ser visto, apesar do resultado em termos quantitativo tenha elevado a média dessas regiões, não apresentou efeito visual satisfatório em relação as demais áreas da imagem. A possível causa para isto é a adoção de valores globais, tanto das médias de referência, quanto as que se pretende alterar. Além disso, o parâmetro é também aplicado de maneira global, ou seja, um mesmo valor para todas as áreas de sombras.

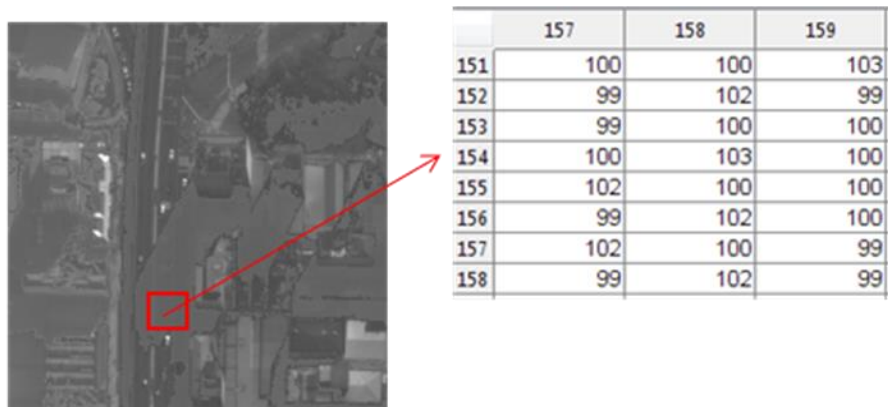


Figura 59. Resultado numérico da restauração por correção *gamma* para uma região do recorte identificada em vermelho e seus respectivos valores corrigidos.

5 CONCLUSÕES E RECOMENDAÇÕES

A metodologia desenvolvida neste trabalho teve como objetivo a detecção e restauração de áreas sombreadas em imagens digitais de alta resolução espacial. As degradações radiométricas que as sombras ocasionam nas imagens, principalmente em cenas urbanas, têm prejudicado tarefas e limitado várias aplicações. O método proposto combina as propriedades do operador morfológico *top-hat* com o fechamento de área para realçar padrões escuros das imagens, como é o caso das sombras, de acordo com sua principal propriedade de baixo padrão de resposta. O fechamento de área garante a independência da forma do elemento estruturante, passando a ser adaptativo as estruturas conectadas da imagem. O comportamento do critério de área foi observado e sua determinação facilitada pela propriedade de idempotência inerente ao filtro morfológico de fechamento. Em função da subtração pelo *top-hat*, sombras foram realçadas e detectadas através da binarização automática pelo método de Otsu.

Na restauração, o *matching* local é realizado entre as estatísticas das áreas detectadas e suas áreas de influência vizinhas, geradas a partir do gradiente morfológico por dilatação. Os histogramas de referência obtidos dessas áreas são combinados com os das sombras, de modo a se obter novos valores de estatística para cada objeto, definidos pela rotulação da imagem.

Os resultados experimentais da metodologia foram realizados com imagens digitais de alta e média densidade urbana, e o método conseguiu identificar as sombras dos mais variados tipos e tamanhos, o que foi comprovado pelo índice de completeza obtido, sendo maior que 90% para ambas as áreas. Já o índice de correção apontou algumas falhas da detecção, com a identificação de áreas como se fossem sombras, mas que na verdade não são, quando se observa o GT. Em especial áreas de vegetação densa foram responsáveis pela tal confusão, devido às múltiplas oclusões por parte da variação no porte e dossel dessas áreas vegetadas. Da análise qualitativa da detecção, realizada através da sobreposição da imagem contendo as bordas das feições detectadas como áreas de sombra, na imagem original, pode se perceber a coerência do método. Em alguns casos, a metodologia foi sensível até mesmo para identificar áreas que o GT não conseguiu delimitar, como no caso de áreas de vegetação densa, dada a dificuldade na sua geração manual.

Com base nos dados restaurados, diferenças radiométricas foram minimizadas conforme a análise visual, comprovando a evidência de detalhes, como carros, arruamentos, vegetação e telhados oclusos pelos efeitos das sombras. Os resultados foram satisfatórios quando comparados com a correção por um parâmetro *gamma*, que homogeneizou as regiões sem proporcionar melhoria da informação. Contudo, a melhoria da informação ainda está aquém do

que se espera de uma imagem livre de sombras, mas mostra-se coerente, já que a dificuldade da tarefa reflete na quantidade de trabalhos propostos para resolução do problema.

Os resultados foram alcançados com um número mínimo de transformações na imagem, o que se mostra uma vantagem e contribui para uma automação da tarefa. Além disso, a proposta de resolver o problema somente com as informações disponíveis na imagem, proporciona uma abrangência por parte de outras metodologias que necessitem remover os efeitos das sombras. A abrangência por parte do tipo de dado utilizado também se torna importante e a metodologia mostrou-se promissora neste sentido, conseguindo ser aplicada para imagens aéreas.

A fim de alcançar melhores resultados com a metodologia proposta, algumas recomendações são feitas para trabalhos futuros.

Para proporcionar uma maior discriminação das sombras e evitar confusões como as ocorridas, características espectrais baseadas em índices multiespectrais devem ser empregados na metodologia. As características apresentadas pelas sombras nos modelos de cores já vêm sendo abordadas na literatura, e quando aliadas com a metodologia proposta, podem proporcionar um aumento nos índices de qualidade. Imagens com melhor resolução radiométrica também devem ser comparadas na metodologia, uma vez que proporcionam mais características sobre as feições.

Outro fator importante na parte de detecção é o critério de área, que deve ser automatizado de maneira que a metodologia estabeleça o valor mais adequado para qualquer imagem de entrada, independente da sua resolução espacial e da dimensão dos objetos. A MM pode ser mais uma vez a alternativa, por disponibilizar transformações que permitem o estudo do tamanho, geometria e orientação dos objetos contidos em imagens.

Embora a determinação de um limiar único pela binarização automática ser importante, por facilitar a aplicação da metodologia, também pode ser um fator de confusão por parte do método. Maneiras de refinar o resultado devem ser propostas, como a utilização de limiares múltiplos, ou de restrição do espaço de busca de valores de brilho, já que as sombras são mais realçadas que as outras feições identificadas no *top-hat*.

Outras técnicas de correção devem ser estudadas e propostas para promover a melhoria da informação degradada pelas sombras. Como exemplo, pode ser testada a técnica de *inpainting* que proporciona a reconstrução das áreas de sombras pela propagação das suas estruturas vizinhas (LORENZI, 2012). Contudo, vale ressaltar que não se encontra na literatura uma maneira de verificar qual a técnica mais adequada para esta tarefa, pois dados de referência

sem sombras são de difícil obtenção. Este problema é maior quando se trata do SR orbital, onde as imagens são coletadas no mesmo período de passagem e adquirir dados de outras fontes implica em custos. Dessa forma, estudos de como dispor desses dados devem comparecer para verificar o quanto verdadeiro é o valor de intensidade obtido pela técnica utilizada, em relação à resposta do alvo em condições normais de iluminação.

REFERÊNCIAS

- ADELIN, K. R. M.; CHEN, M.; BRIOTTET, X.; PANG, S. K.; PAPANODITIS, N. *Shadow Detection in Very High Spatial Resolution Aerial Images: Comparative Study*. ISPRS Journal of Photogrammetry and Remote Sensing, v. 80, p. 21-38, 2013.
- AL-NAJDAWI, N.; BEZ, H. E.; SINGHAI, J.; EDIRISINGHE, E. A. *A survey of cast shadow detection algorithms*. Pattern Recognition Letters, vol. 33, no. 6, pp. 752-764, Abr, 2011.
- ARÉVALO, V.; GONZÁLEZ, J.; AMBROSIO, G. *Detecting Shadow QuickBird satellite images*. In: ISPRS Commission VII Mid-term Symposium 'Remote Sensing: From Pixels to Processes'. Enschede, Netherlands. May 2005.
- BANON, G. J. F.; BARRERA, J. *Bases da Morfologia Matemática para a análise de imagens binárias*, 2 ed. São José dos Campos: Instituto Nacional de Pesquisas Espaciais (INPE), 1998. 230p.
- CARVALHO, M. V. A. *Classificação da cobertura e uso do solo com imagens WorldView-2 utilizando mineração de dados e análise baseada em objetos*. 204 f. (Mestrado em Sensoriamento Remoto) - INPE, São José dos Campos - SP.
- CENTENO, J. A. S.; PACHECO, A. P. *Classificação de Sombra em Imagens Orbitais e Aéreas Utilizando uma Matriz de Co-Ocorrência Modificada*. Boletim de Ciências Geodésicas, Curitiba, v. 17, n. 1, p.75-92, 2011.
- 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.
- FACON, J. *Morfologia Matemática: Teoria e Exemplos*. Curitiba, PUC,1996. 303 p.
- FAZAN, A. J.; POZ, A. P. D. *Predição de Sombras de Edifícios sobre Vias Urbanas com Base 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.
- FUNKA-LEA, G. D.; STEEDMAN, M. *The Visual Recognition of Shadows by an Active Observer*. Dissertação - University of Pennsylvani, Computer and Information Science, 1994. 200 f.
- GONZALES, R.C.; WOODS, R.E. *Processamento de Imagens Digitais*. Tradução: Cristina Yamagami e Leonardo Piamonte. São Paulo. 3ª Ed. Peason Prentice Hall, 2010. 624p.
- HERMOSILLA, T.; RUIZ, L. A.; RECIO, J. A.; ESTORNELL, J. *Evaluation of Automatic Building Detection Approaches Combining High Resolution Images and LiDAR Data*. Remote Sensing, vol. 3, p. 1188-1210, 2011.
- IRVIN, R.B.; MCKEOWN, D. M. *Methods for exploiting the relationship between buildings and their shadows in aerial imagery*. IEEE Transactions on Systems, Man and Cybernetics, 19(6):1564–1575, 1989.

JENSEN, J. R. *Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres*. Tradução da 2ª ed. por (pesquisadores do INPE): José Carlos N. Epiphânio (coordenador); Antonio R. Formaggio; Athos R. Santos; Bernardo F. T. Rudorff; Cláudia M. Almeida; Lênio S. Galvão. São José dos Campos: Parêntese. 2009. 672 p.

LI, H.; ZHANG, L. *An Adaptive Nonlocal Regularized Shadow Removal Method for Aerial Remote Sensing Images*. IEEE Transactions on Geosciences and Remote Sensing, v. 52, n. 1, p. 106-120, jan. 2014.

LIESENBERG, V. *Análise multi-angular de fitofisionomias do bioma cerrado com dados MISR/Terra*. 2005. 120 f. Dissertação (Mestrado em Sensoriamento Remoto) - INPE, São José dos Campos.

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.

MARQUES FILHO, O.; VIEIRA NETO, H. *Processamento Digital de Imagens*, Rio de Janeiro: Brasport, 1999. 331p.

MASSALABI, A.; HE, D. -C.; BÉNIÉ, G. B.; BEAUDRY, É. *Restitution of information under and from shadow in panchromatic Ikonos images of the city of Sherbrook*. In: ISPRS, Istanbul – Turkey. Proceedings, p. 173-178. v. 35, 2004.

MENESES, P. R.; ALMEIDA, T. *Processamento de Imagens de Sensoriamento Remoto*. Brasília, 2012.

MOREIRA, M. A. *Fundamentos do Sensoriamento Remoto e metodologias de aplicação*. 4 ed. Viçosa: Ed. UFV, 2011. 422 p.

NIELSEN, M. O. *True Orthophoto Generation*. Master Thesis. Universidade Técnica da Dinamarca. Informatics and Mathematical Modelling. Kgs. Lyngby. 2004. 140 f.

NÓBREGA, R. A. A. *Análise do Balanceamento de imagens aplicado a Fotogrametria*. Dissertação (Mestrado em Engenharia de Transportes). Escola Politécnica. Universidade de São Paulo. São Paulo. 2002. 102 f

NOVO, E. M. L. M. *Sensoriamento Remoto: Princípios e Aplicações*. São Paulo, Edgard Blücher, 3ª edição, 2008. 358p.

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.

PEDRINI, H.; SCHWARTZ, R. W. *Análise de Imagens Digitais: princípios, algoritmos e aplicações*. São Paulo. Thomson Learning, 2008. 508p.

PRATI, A.; MIKIC, I.; TRIVEDI, M. M.; CUCCHIARA, R. *Detecting Moving Shadows: Algorithms and Evaluation*. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 25, no. 7, p. 918-923, 2003.

RAU, J. Y.; CHEN, N. Y.; HEN, L. C. *True orthophoto generation of built-up areas using multi-view images*. *Photogrammetric Engineering and Remote Sensing*, 68, 2002 581–588.

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 Letters*, v. 45, n. 4, p.1684–1695, 2011.

ŞEREF, A. *Shadow Detection and Compensation in Aerial Images with an Application to Building Height Estimation*. Tese - Graduate School of Natural and Applied Sciences of Middle East Technical University, 2010.

SCHOWENGERDT, R. A. *Remote Sensing: Models and Methods for Image Processing*. 3ed. London: Elsevier, 2007, 515 p.

SDC Morphology Toolbox for MATLAB v.1.6. *Tutorial*. Naperville, USA. Disponível em <<http://www.mmorph.com/>>. Acesso em: Maio 2013.

SHAHTAHMASSEBI, A.; 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.

SHIH, F. Y. *Image processing and Mathematical Morphology: fundamentals and applications*. CRC, 2009. 439 p.

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

SOUZA, I. M. *Sensoriamento Remoto Orbital Aplicado a Estudos Urbanos*. 2012. (Desenvolvimento de material didático ou instrucional - material didático) Disponível em: <<http://urlib.net/8JMKD3MGP7W/3BEFCJH>>. Acesso em: ago. 2013.

STATELLA, T. *Detecção Automática de Rastros de Dust Devils na Superfície de Marte*. Tese (doutorado) - Universidade Estadual Paulista, Faculdade de Ciências e Tecnologia, 2012.203 f.

TSAI, V. J. D. *A Comparative Study on Shadow Compensation of Color Aerial Images in Invariant Color Models*. *IEEE Transactions on Geosciences and Remote Sensing*, v. 44, n. 6, p. 1661-1667, jun. 2006.

VINCENT, L. *Morphological Area Opening and Closings for Grayscale Images*. In: *Shape in Picture 92, Workshop*. Anais do Shape in Picture 92, Holanda, 1992.

NAKAJIMA, T.; TAO, G.; YASUOKA, Y. *Simulated Recovery of Information in Shadow Areas on Ikonos Image by Combing ALS Data*. In: 23rd Asian Conf. Remote Sensing (ACRS), Kathmandu, Nepal, 2002.

WAN, C. Y.; BING, B. A.; LI, Z. *An Assessment Of Shadow Enhanced Urban Remote Sensing Imagery Of A Complex City - Hong Kong*. In: XXII ISPRS Congress. v. XXXIX-B6, p. 177-182, Melbourne, Australia. Ago/Spt, 2012.

WIEDEMANN, C., HEIPKE, C., MAYER, H., JAMET, O. *Empirical evaluation of automatically extracted road axes*. In: Empirical Evaluation Methods in Computer Vision. IEEE Computer Society Press, pp. 172-187, 1998.

ZHAN, Q., SHI, W.; XIA, Y. *Quantitative analysis of shadow effects in high-resolution images of urban areas*. In: International Archives of Photogrammetry and Remote Sensing, Vol 36, 2005.