

Avaliação da redução do efeito de sombreamento em imagens multiespectrais de áreas urbanas utilizando componentes principais e análise de agrupamento

Samara Calçado de Azevedo¹

Vilma Mayumi Tachibana²

Erivaldo Antônio da Silva³

Universidade Estadual Paulista - Faculdade de Ciências e Tecnologia – FCT/UNESP
Rua Roberto Simonsen, 305, 19060-900 Presidente Prudente - SP - Brasil

¹Programa de Pós-Graduação em Ciências Cartográficas - PGCC

²Departamento de Estatística, ³Departamento de Cartografia

samara_calçado@hotmail.com, vilma@fct.unesp.br, silva.erivaldo@gmail.com

Abstract. Shadows represent a problem for feature extraction in urban areas, mainly when dealing with high spatial resolution remote sensing images. This work aims to evaluate one proposed method to remove shadow effects in multispectral images. Two approaches have been followed and compared. First, each band was corrected individually and principal components analysis (PCA) used to reduce high correlation that exists among images and the quantity to be processed. In the second approach, the PCA was firstly applied and corrected after, in order to verify the correction behavior in transformed data. To alleviate the shadow effects, priori detection of shadow areas using black top-hat morphological operator and automatic binarization were done, and then, these areas were corrected by local histogram matching from neighborhoods statistics. The method was tested in WorldView-2 multispectral images from São Paulo city, which is one of the densest urban areas in the world. Experimental results and visual analysis have shown a decrease in radiometric differences caused by shadows in both approaches. Also, an increase on distinction between features that were occluded was observed and proven by unsupervised classification using k-media. However, further analysis and references data are necessary to guarantee that the radiometric value encountered corresponds that associated land cover. This study can contribute in the future with many applications such as 3D reconstruction, image matching, object recognition, etc.

Palavras-chave: Componentes principais, correção de sombras, classificação não-supervisionada, principals components, shadow correction, unsupervised classification.

1. Introdução

Os dados espectrais adquiridos por sensores aéreos ou orbitais têm sido de grande interesse em muitas aplicações, com o objetivo de extrair informações sobre os objetos presentes na superfície terrestre. Contudo, esses dados podem conter interferências, tais como as sombras, causadas pela oclusão da fonte de iluminação (no caso de sistemas passivos) por objetos mais elevados presentes na superfície considerada (ARÉVALO et al., 2008). As sombras prejudicam a identificação e o reconhecimento de alvos, o que resulta numa redução do desempenho de alguns métodos ou inviabiliza atividades como a segmentação e a classificação de imagens.

Em imagens de alta resolução espacial de áreas urbanas, o problema das sombras é particularmente maior, pois o detalhamento da cena aliado a grande quantidade de feições antrópicas, resulta em uma porção significativa de áreas sombreadas na imagem coletada, e com as respostas dos alvos influenciadas por este efeito. Apesar de não ser um alvo de superfície, as respostas que chegam ao sensor em relação à região de sombra são devido ao espalhamento da energia pela atmosfera, contribuição de alvos vizinhos e ao intervalo dinâmico dos atuais sensores, como QuickBird e WorldView, que coletam informações da superfície, mesmo se elas estiverem oclusas (ADELINE et al., 2013; LIU e YAMAZAKI, 2012).

O problema da remoção de sombras vem sendo estudado em diversos contextos, procurando proporcionar um melhoramento da informação visual e contribuir com outras técnicas. O objetivo é melhorar o sinal registrado nestas 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. Além disso, o grande volume de dados de Sensoriamento Remoto (SR) gerados diariamente dependem de métodos de análise sofisticados e complexos.

Atualmente, as preocupações científicas residem em estabelecer abordagens que reduzam a dimensionalidade dos dados sem que haja perda significativa de informações. Uma técnica que se destaca neste sentido é a análise por componentes principais (BIOUCAS-DIAS, 2013). Com o objetivo de concentrar a maior parte das informações em um número mínimo de imagens, fornece benefícios, por exemplo, na diminuição de custos e tempo para classificação de imagens, resultando em uma rápida análise de fenômenos da terra e facilita o gerenciamento dos recursos naturais.

Para avaliar a redução do efeito de sombreamento em imagens multiespectrais, o presente trabalho utiliza-se da análise por componentes principais para reduzir a dimensionalidade e correlação dos dados, sendo duas abordagens testadas com o objetivo de verificar o comportamento da técnica perante os dados transformados. Os resultados obtidos foram submetidos a uma análise de agrupamento, procurando observar a contribuição da redução do sombreamento na classificação não-supervisionada da imagem antes e depois da correção.

2. Metodologia

Para o desenvolvimento do trabalho quatro bandas multiespectrais (vermelho, verde, azul e infra-vermelho) do satélite Worldview-2 foram utilizadas. Trata-se de imagens georreferenciadas no sistema UTM/WGS84, com 2 metros de resolução espacial e datada de maio de 2012. A Figura 1 apresenta o recorte da imagem utilizado para o estudo, no qual observa-se uma porção da cidade de São Paulo, cuja área urbana está entre as 10 maiores do mundo (DEMOGRAPHIA, 2014). Dessa forma, grande parte dos objetos presentes na cena correspondem a feições antrópicas, como as edificações, que geram uma grande quantidade de áreas sombreadas na imagem



Figura 1 - Composição colorida normal da área de estudo.

Os procedimentos envolvidos na metodologia podem ser entendidos em síntese pelo fluxograma mostrado na Figura 2. Duas abordagens distintas foram realizadas. A primeira teve o objetivo de corrigir as áreas sombreadas em cada uma das quatro bandas multiespectrais originais. Neste processo, as áreas de sombras foram detectadas e corrigidas

por meio de um algoritmo desenvolvido no *software* Matlab, conforme procedimento explicado na próxima seção.

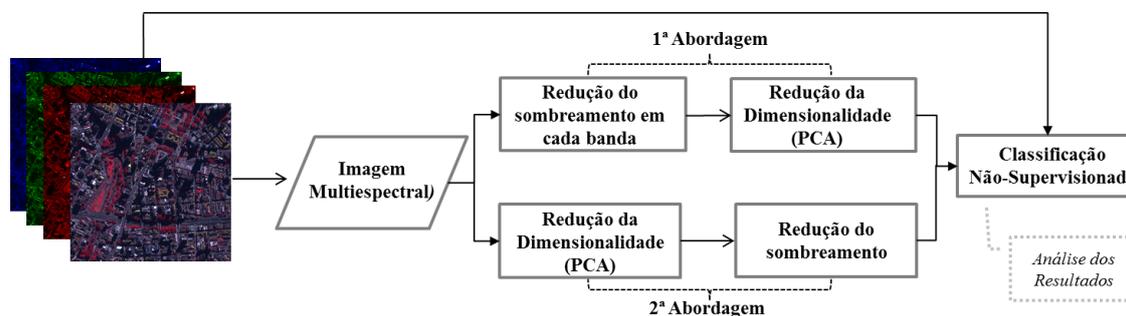


Figura 2 - Fluxograma das etapas envolvidas no desenvolvimento da metodologia.

As imagens corrigidas foram importadas no *software* livre Spring 5.2.6, no qual um banco de dados para área de estudo foi criado. Dessa maneira, uma transformação por componentes principais foi aplicada com o objetivo de decorrelacionar os dados pertencentes a mesma área, e reduzir a quantidade de imagens a serem analisadas após a correção dos efeitos de sombreamento. Esta técnica transforma o conjunto original dos dados em um conjunto substancialmente menor e mais fácil de interpretar, já que o máximo de informação possível encontra-se nas primeiras componentes principais (CP). O resultado, são novas bandas e não correlacionadas, representadas pelas CP's, cujo número resultante é igual ao número de bandas espectrais utilizadas (MATHER, 2004).

Na segunda abordagem o processo foi inverso, ou seja, foi realizada primeiramente no Spring a redução da dimensionalidade dos dados originais por PCA e na sequência, os efeitos de sombreamentos corrigidos. Neste caso, o objetivo foi verificar o comportamento do algoritmo de correção perante aos dados transformados, uma vez que após a rotação, os dados acabam não representando mais valores espectrais e sim combinações lineares dos dados originais.

A verificação dos resultados foi feita por meio da comparação entre a classificação dos dados corrigidos pelas duas abordagens e a classificação da imagem original. Utilizou-se para isto, uma classificação não-supervisionada pelo método do k-médias disponível no *software* Spring.

2.1 Redução dos efeitos de sombreamento

A maioria dos métodos utilizados para minimizar os problemas ocasionados pelas sombras dependem de duas etapas principais. A primeira trata-se de identificar a localização das áreas de sombras na imagem através da detecção. Enquanto a segunda etapa constitui-se da correção dessas áreas de forma a recuperar a informação que foi obstruída (ŞEREF, 2010; SHAHTAHMASSEBI et al., 2013).

No trabalho, a detecção das áreas sombreadas é realizada partindo da premissa básica que as sombras correspondem aos menores valores de brilho da imagem (ADELINE et al., 2013). Dessa forma, o operador morfológico top-hat, é utilizado para recuperar as estruturas de interesse através da diferença aritmética entre a imagem original e a imagem resultante de um processo de fechamento por área. No fechamento por área, de acordo com Soille (2004), o elemento estruturante, que representa uma máscara de convolução na imagem, 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, garantido pela propriedade de idempotência dos filtros morfológicos, dentro do limiar de área e conectividade estabelecida. Quando a diferença com a imagem original é realizada, os mínimos da imagem representados pelas sombras são então recuperados e realçados, sendo recuperados pela binarização automática

proposta por Otsu (1979). Na Figura 3 é apresentado um exemplo da detecção para a banda do infravermelho.

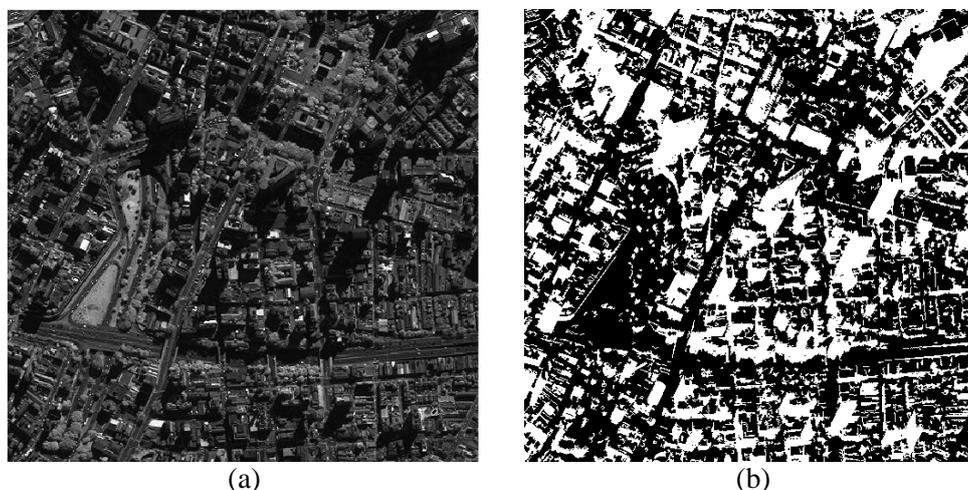


Figura 3 - Exemplo do resultado da detecção para a banda do infravermelho. (a) Banda 4 original e (b) Resultado binário da detecção.

Com a identificação das áreas de sombras, a minimização dos seus efeitos consiste em utilizar um histograma de referência para corrigir as áreas afetadas. Neste caso, 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.

O algoritmo então calcula as estatísticas de cada objeto e sua respectiva área de influência, 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 (RICHARDS, 2012). Ao final do processo, as sombras são restauradas na imagem original proporcionando uma imagem corrigida das diferenças radiométricas provocadas pelas áreas de sombras, e que possam representar as feições geográficas presentes na cena original.

2.2 Classificação não-supervisionada por K-médias

A classificação de imagens é o processo para reconhecer padrões e objetos da superfície. As técnicas de classificação são normalmente baseadas em duas abordagens (RICHARDS, 2012). A primeira é denominada classificação supervisionada, pois implica em treinar o algoritmo de classificação através de informações específicas das classes, também chamada de amostras. Quando não se tem disponível amostras para o treinamento do algoritmo, a classificação pode ser feita através de técnicas chamadas de não-supervisionadas.

Os classificadores não-supervisionados identificam e separam pixels na imagem que são espectralmente semelhantes. Neste caso a classificação é baseada em métodos estatísticos de análise de agrupamento e não há uma intervenção direta de algum operador. Os métodos de agrupamento buscam organizar um conjunto de pixels em grupos relativamente homogêneos (clusters). A relação entre os rótulos atribuídos pelo classificador para os pixels da imagem e os tipos de cobertura da terra existentes na área abrangida é determinada posteriormente a classificação não-supervisionada, sendo as informações das classes fornecidas pelo analista

O método de agrupamento k-médias é uma das abordagens mais comum utilizada em análise de imagens, de acordo com Richards (2012). Trata-se de um processo iterativo não-

supervisionado por pixel, onde inicialmente é necessário definir a quantidade de clusters (grupos) desejado e seus centros (sementes), que são representados pelo vetor média dos cluster definidos a priori. A partir daí, cada pixel da amostra é atribuído ao cluster do centroide mais próximo, ou seja, com vetor média mais próximo. Os centros dos clusters são recalculados a cada iteração, a partir dos elementos alocados e o processo repete-se quantas vezes forem necessárias, até que não haja uma mudança significativa nos pixels alocados ou apresente uma mudança muito pequena

No trabalho, a classificação pelo método do k-médias foi realizada no *software* Spring 5.2.6, e analisando a imagem da área de trabalho, foram definidas 6 classes de interesse a priori, devido ao caráter de alta resolução espacial. Dentre as classes foram observadas as sombras, áreas impermeáveis representadas por feições antrópicas, vegetação, piscinas, solo exposto e exemplo de telhado com alta reflectância.

4. Resultados e Discussões

Na primeira abordagem, a redução do sombreado aplicada a cada banda original separadamente resultou em quatro imagens corrigidas, as quais foram importadas para o Spring, onde a transformação por PCA foi aplicada. A primeira componente do conjunto gerado (Figura 4b) representa a maioria das informações correlacionadas, principalmente as sombras, que possuem o mesmo comportamento em todas as bandas.

Uma análise do comportamento da transformação por PCA retirando-se a banda 1 foi feita, pelo fato dessa banda possuir menor comprimento de onda e sofrer maior influência da atmosfera. Uma nova transformação por PCA foi gerada e o resultado disposto na Figura 4c. Um aumento de quase 5% na variabilidade explicada foi observado, ou seja, mesmo com a retirada de uma banda, aproximadamente 73% dos dados estão explicados pela 1ª CP. Pela análise visual e comparando-se com a imagem original em tons de cinza (Figura 4a), nota-se alguns detalhes evidenciados e que as diferenças radiométricas causadas pela grande quantidade de áreas sombreadas foram minimizadas.

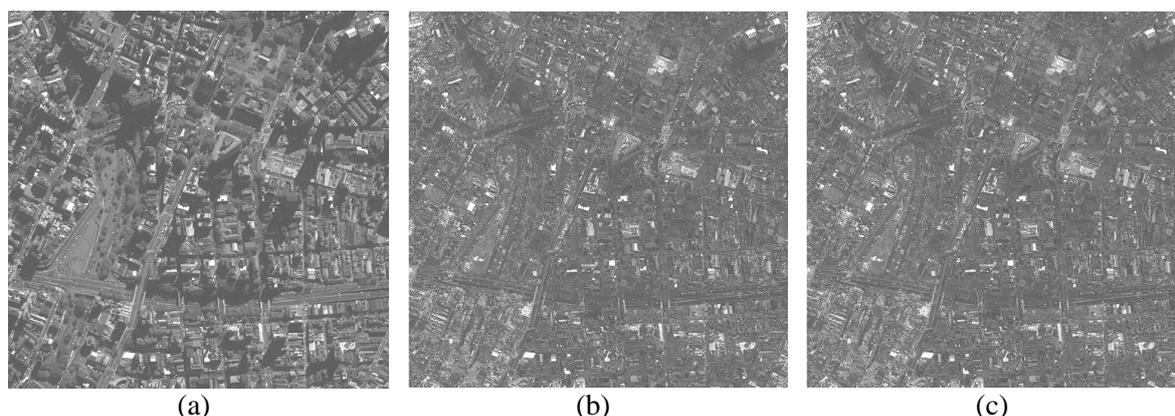


Figura 4 - Resultado da correção do sombreado para a primeira abordagem. (a) Imagem original em tons de cinza (b)1ªCP de todas as bandas corrigidas e (c)1ªCP sem a banda 1.

Na segunda abordagem, a transformação por PCA foi aplicada aos dados originais. Neste caso, a variabilidade explicada pela primeira componente sem incluir a banda 1 foi de aproximadamente 88%, o que corresponde a trabalhar com a maioria das informações de interesse. Dessa forma, a 1ªCP (Figura 5a) foi exportada para o Matlab, onde a detecção (Figura 5b) e correção (Figura 5c) foram realizadas. Apesar dos dados transformados não fornecerem valores espectrais dos alvos, o resultado mostrou-se coerente, uma vez que trata-se de combinações lineares dos dados originais. Nesta combinação, os valores foram

escalados para o mesmo range dos níveis digitais das imagens originais utilizadas na transformação, sobre os quais a metodologia de detecção e correção ocorreu.

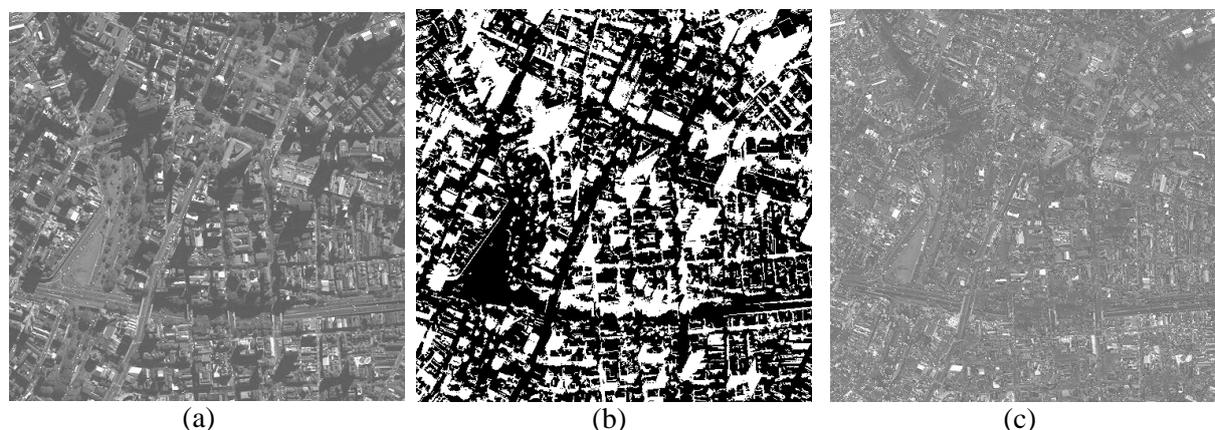


Figura 5 - Resultado da correção do sombreamento para a segunda abordagem. (a) 1^oCP; (b) Resultado binário da detecção; (c) Resultado da correção do sombreamento para a 1^oCP.

A partir da análise visual, pode-se perceber que a redução do sombreamento nos dados transformados por PCA (Figura 5c) tiveram um comportamento semelhante ao resultado da primeira abordagem (Figura 4c). Estas diferenças podem ser percebidas, principalmente, nas sombras projetadas pelos edifícios mais elevados, onde é possível identificar alguns tipos de telhados ou arruamento. Na Figura 6 encontra-se em destaque o zoom de uma área da imagem para melhor visualização entre os resultados. Em geral, alvos que estavam sob o efeito de sombras anteriormente (Figura 6a) foram evidenciados em ambas as abordagens. No segundo caso inclusive (Figura 6c), a imagem corrigida apresentou menor quantidade de áreas saturadas, que podem ser causadas pela dimensão da área de referência utilizada. Contudo, o resultado ainda está aquém do que se espera de uma imagem livre dos efeitos de sombras, sendo que a dificuldade da tarefa reflete no interesse de muitos trabalhos neste sentido.

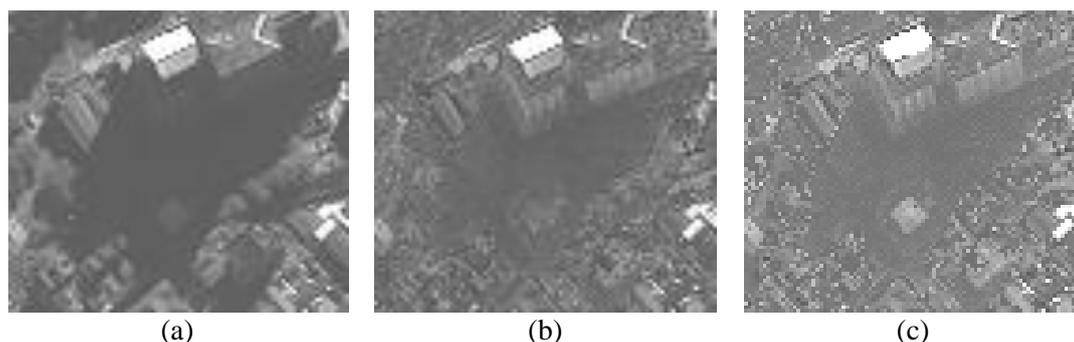


Figura 6 – Comparação entre os resultados para uma área em destaque da imagem. (a) Imagem original; (b) Resultado da primeira abordagem e (c) Resultado da segunda abordagem.

Na última etapa, a classificação não-supervisionada por k-médias foi realizada para avaliar o comportamento do resultado antes e depois da correção do sombreamento. Dessa forma, a classificação foi realizada tanto na imagem original (Figura 7a), quanto para as duas abordagens (Figura 7b e 7c). O classificador busca separar os pixels em grupos relativamente homogêneos (clusters), alocando cada pixel de acordo com sua proximidade espectral. A discrepância visual do resultado após a correção é claramente observada, sendo que foi utilizada para as três classificações os mesmos temas (rótulos).

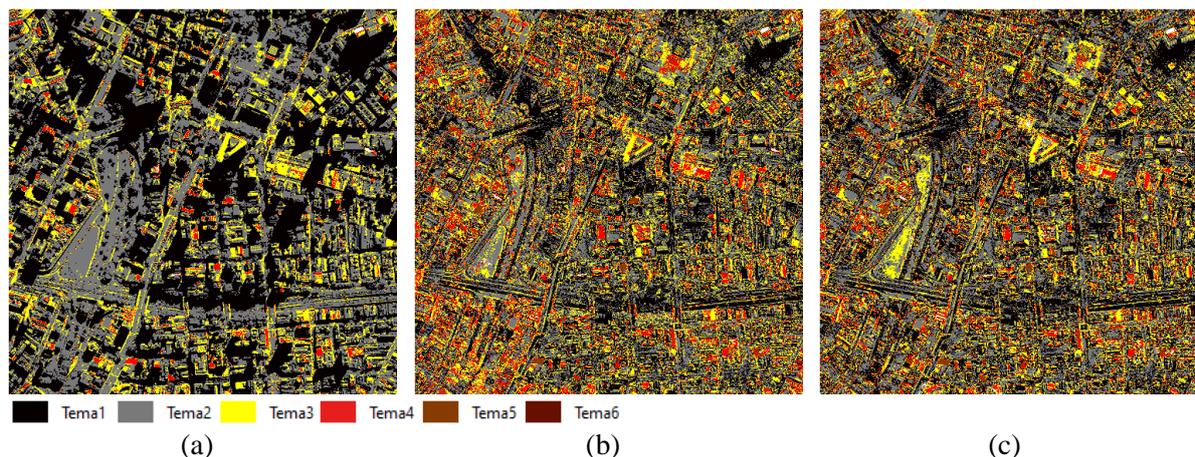


Figura 7 - Resultado do k-médias aplicado as imagens. (a) Imagem original; (b) Imagem resultante da 1ª abordagem e (c) Imagem resultado da 2ª abordagem.

Como pode ser visto na Figura 7a, a classificação identificou grande quantidade de pixels pertencentes a classe sombras. Já em (b) há uma grande diferença entre as classes, uma vez que as imagens originais foram corrigidas pela técnica de redução do sombreamento e a classificação aplicada a 1ª CP. Ainda é possível perceber pixels pertencentes a regiões oclusas, no entanto, de maneira moderada, conseguindo inclusive diferenciar o arruamento. Contudo, houve grande confusão da classe vegetação, não sendo possível nem mesmo distingui-la na classificação da imagem original. Na Figura 7c, observa-se uma confusão do classificador entre topos de edifícios e vegetação rasteira que estão destacados em amarelo. Ainda em (c), verifica-se que da mesma maneira que em (b), o comportamento da classificação mostrou-se distinto da classificação da imagem original, evidenciando que a técnica de correção do sombreamento foi eficaz inclusive em dados transformados, um dos objetivos da avaliação do estudo.

5. Conclusões

Sobre a metodologia desenvolvida para o conjunto de imagens, verificou-se que os resultados mostraram que a técnica de correção dos efeitos das sombras foi eficaz, ou seja, houve uma melhoria da informação visual comprovado através da análise visual da classificação não-supervisionada dos resultados e da imagem original. Estes efeitos foram satisfatórios inclusive na segunda abordagem, onde foi aplicada a técnica de redução de sombreamento após a transformação dos dados por PCA.

Dessa forma, levando em conta os danos que as sombras podem causar em diversas aplicações, novas formas de verificar e avaliar se os resultados da correção estão coerentes devem ser investigadas. Além disso, estudos como dispor de dados de referências para verificar o quão verdadeiro é o valor de intensidade obtido pela técnica utilizada, em relação à resposta do alvo em condições normais de iluminação devem comparecer. Visto que, no caso orbital, este problema é particularmente maior, pois as imagens são adquiridas na maioria das vezes no mesmo período de passagem do satélite, e a aquisição de dados de outras fontes implica no aumento significativo de custos.

Em trabalhos futuros a avaliação quantitativa dessa redução se faz necessária, podendo ser testados métodos de classificação supervisionada e com isto, obter índices de exatidão a partir da matriz de erros associada.

Agradecimentos

Os autores agradecem à UNESP, o Programa de Pós-Graduação em Ciências Cartográficas e à FAPESP pelo apoio e suporte financeiro dado a pesquisa.

Referências

- Adeline, K. R. M.; Chen, M.; Briottet, X.; Pang, S. K.; Paparoditis, 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.
- Arévalo, V.; González, J.; Ambrosia, G. **Shadow detection in color high-resolution satellite images. International Journal of Remote Sensing**, v. 29 (7), p. 1945–1963, 2008
- Bioucas-Dias, J. M.; Plaza, A; Camps-Valls, G.; Scheunders, P.; Nasrabadi, N. M.; Chanussot, J. Hyperspectral Remote Sensing Data Analysis and Future Challenges. **IEEE Geoscience and Remote Sensing Magazine**, vol. 1, no. 2, 2013.
- Demographia World Urban Areas. **10th Annual Edition: March 2014**. Disponível em: <<http://www.demographia.com/db-worldua.pdf>>. Acesso em: 05 set 2014.
- Liu, W.; Member, S.; 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.
- Mather, P. M. **Computer Processing of Remotely-Sensed Images: An Introduction**. 3 ed. John Wiley & Sons, 2004. 324 p.
- 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.
- Richards, A. J. **Remote Sensing Digital Image Analysis: An Introduction**. 5 ed. Canberra, Austrália: Springer-Verlag, 2012. 494 p.
- 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.
- 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.
- Soille, P. **Morphological Image Analysis**. Berlin. Springer-Verlag, 2004.
- SPRING: Integrating remote sensing and GIS by object-oriented data modelling. Camara G, Souza RCM, FreitasUM, Garrido J Computers & Graphics, 20: (3) 395-403, May-Jun 1996. Disponível em: <www.dpi.inpe.br/spring>.