



Boletim de Ciências Geodésicas

ISSN: 1413-4853

bcg_editor@ufpr.br

Universidade Federal do Paraná

Brasil

SILVA CENTENO, JORGE ANTONIO; DA PENHA PACHECO, ADMILSON
CLASSIFICAÇÃO DE SOMBRA EM IMAGENS ORBITAIS E AÉREAS UTILIZANDO
UMA MATRIZ DE CO-OCORRÊNCIA MODIFICADA

Boletim de Ciências Geodésicas, vol. 17, núm. 1, enero-marzo, 2011, pp. 75-92

Universidade Federal do Paraná

Curitiba, Brasil

Disponível em: <http://www.redalyc.org/articulo.oa?id=393937719005>

- Como citar este artigo
- Número completo
- Mais artigos
- Home da revista no Redalyc

redalyc.org

Sistema de Informação Científica

Rede de Revistas Científicas da América Latina, Caribe, Espanha e Portugal

Projeto acadêmico sem fins lucrativos desenvolvido no âmbito da iniciativa Acesso Aberto

CLASSIFICAÇÃO DE SOMBRA EM IMAGENS ORBITAIS E AÉREAS UTILIZANDO UMA MATRIZ DE CO- OCORRÊNCIA MODIFICADA

Shadow classification in orbital and aerial images analysing a modified co-occurrence matrix

JORGE ANTONIO SILVA CENTENO¹
ADMILSON DA PENHA PACHECO²

¹Universidade Federal do Paraná – UFPR
Caixa Postal 19.001 – 81.531-990 Curitiba, PR, Brasil
²Universidade Federal de Pernambuco – UFPE/PPGCGTG
Rua Acadêmico Hélio Ramos s/nº - 50740-530 – Recife, PE, Brasil
centeno@ufpr.br ; pacheco3p@gmail.com

RESUMO

Embora seja considerada útil para a identificação de objetos mais elevados, a presença de sombras pode ser um elemento prejudicial na extração de informações quando esconde objetos de menor altura. Neste trabalho é descrito o desenvolvimento conceitual e exemplos de aplicação de um método para a segmentação de sombras em imagens de satélite e fotografias aéreas baseado na análise da matriz de co-ocorrência. A matriz de co-ocorrência traduz a relação entre o pixel e sua vizinhança, o que permite identificar áreas uniformes e escuras, que correspondem a sombras. Com esta premissa, foi proposto um método que analisa a diagonal principal da matriz de co-ocorrência e identifica nela os agrupamentos associados a sombras. Para delimitar as sombras, é usada uma função contextual derivada da melhor reta perpendicular à diagonal principal da matriz de co-ocorrência que separa áreas escuras e uniformes. Testes com imagens aéreas e de satélite são apresentados para ilustrar o método. O método proposto é do tipo adaptativo e pode ser usado tanto em imagens de 8 bits como também estendido à maiores resoluções radiométricas, além disso seu funcionamento não é afetado pela eventual contribuição atmosférica, que afeta principalmente as bandas do visível.

Palavras-chave: Processamento de Imagens; Sensoriamento Remoto; Segmentação; Sombras.

ABSTRACT

Although shadows are considered useful for the identification of objects that rise up from the ground, they may made the extraction of information difficult when they hide lower objects. In this paper we introduce the conceptual development and show examples of the application of a method for the segmentation of shadows in satellite and aerial imagery that is based on the analysis of the co-occurrence matrix. The co-occurrence matrix shows the relationship between a pixel and its neighborhood, which allows to identify dark and uniform areas that correspond to shadows. Taking this in mind, a method is proposed to analyse the main diagonal of the co-occurrence matrix and to identify the cluster that is related to shadows. The mentioned segmentation enables to obtain the threshold along the main diagonal. A contextual function can be derived from the best perpendicular line to the main diagonal of the co-occurrence matrix that crossed the diagonal at the threshold point. Tests with aerial and satellite images are presented to illustrate the method. It is shown that the method is adaptive. It can be used in 8 bits images as well as extended to higher radiometric resolutions and it is not affected by the atmospheric contribution.

Keywords: Image Processing; Remote Sensing; Segmentation; Shadows.

1. INTRODUÇÃO

As sombras estão sempre presentes em imagens de cenas naturais. Com o aumento da resolução espacial das imagens de sensoriamento remoto, que hoje alcançam 50 centímetros, as sombras passaram a ser um elemento constantemente visível nas imagens.

Na fotointerpretação visual tradicional, as sombras são consideradas importantes no processo cognitivo, sendo um dos elementos básicos de fotointerpretação. Isto vale para a análise de imagens de alta resolução espacial, pois a sombra é um dos atributos da imagem que ajuda identificar diferentes alvos em imagens de satélite e fornecem a sensação de tridimensionalidade. Em áreas densamente urbanizadas, segundo Vu et al. (2008), as sombras tendem a se alinhar na direção longitudinal e transversal a edifícios, formando retângulos em função da geometria dos edifícios e facilitando com isso sua identificação.

Embora seja considerada útil para a identificação de objetos como construções, as sombras podem prejudicar a interpretação. Sombras de objetos mais altos podem estar sobrepostas a objetos menores, dependendo do ângulo de incidência solar. Assim, as sombras podem esconder objetos e diminuir o potencial uso da imagem. O mesmo vale para a ocorrência de sombras causadas pelas nuvens. As sombras podem alterar a resposta espectral dos objetos e conseqüentemente a cor das superfícies presentes na imagem, escurecendo estas superfícies e dificultando processos de classificação e segmentação. A má visibilidade na região de sombra influencia diretamente o reconhecimento espectral e geométrico de

objetos, detecção de mudanças, análise de correspondência e a geração de imagens e ortofotos verdadeiras.

A detecção de áreas sombreadas é um tema de pesquisa nos processo de análise de imagens e extração automática de feições. O presente artigo traz uma discussão dos métodos apresentados na literatura e apresenta um método para a detecção de áreas de sombra em imagens de satélite de alta resolução espacial. O artigo mostra o resultado de uma pesquisa cujo objetivo é classificar sombras em imagens de sensoriamento remoto de alta resolução espacial usando um algoritmo baseado na análise de contexto, traduzido pela matriz de co-ocorrência, e as características espectrais das áreas de sombra.

A organização do artigo é a seguinte: Na seção 2 é apresentada uma discussão a respeito das sombras nas imagens de sensoriamento remoto, com base nas leis da radiação. Soluções encontradas na literatura para o tratamento das sombras no espaço da imagem são apresentadas e discutidas na terceira seção. Na quarta seção é descrito o método proposto, o qual é avaliado através de testes apresentados na quinta seção. Finalmente, na sexta seção são apresentadas as conclusões.

2. CONCEITUAÇÃO DE SOMBRAS

Inicialmente deve-se entender o conceito de sombra para proceder a sua modelagem e detecção. Num modelo mais simples, áreas com sombras são regiões na imagem nas quais a incidência de radiação eletromagnética proveniente da fonte é nula. Este modelo assume que a fonte é única e não ocorre outro tipo de iluminação, como a iluminação difusa. Para imagens de satélite, pode se considerar uma fonte pontual, o sol, localizada a uma distância infinita, que atinge a superfície sob forma de raios paralelos.

O balanço do fluxo de energia na superfície do objeto pode ser modelado segundo a equação 1 (Swain e Davis, 1978).

$$\Phi_{\text{incidente}} = \Phi_{\text{absorvido}} + \Phi_{\text{refletido}} + \Phi_{\text{transmitido}} \quad (1)$$

onde: $\Phi_{\text{absorvido}}$ corresponde à porção absorvida do fluxo de radiação total incidente ($\Phi_{\text{incidente}}$), $\Phi_{\text{refletido}}$ é a porção refletida e $\Phi_{\text{transmitido}}$ a transmitida.

Segundo este modelo, sendo a radiação incidente igual a zero, a parcela refletida também é nula ($\Phi_{\text{refletido}} = 0$). Logo, no modelo simplificado, as áreas de sombra teriam valores nulos e seriam facilmente detectáveis. Porém, na superfície da Terra a ocorrência deste tipo de sombra é incomum, pois a camada de atmosfera causa iluminação difusa, além de que outros objetos (o ambiente em torno da superfície) podem refletir a energia, redirecionando-a na direção da superfície. Logo, o fluxo de energia eletromagnética incidente deve ser desdobrado em várias componentes:

$$\Phi_{\text{incidente}} = \Phi_{\text{solar}} + \Phi_{\text{atmosfera}} + \Phi_{\text{ambiente}} \quad (2)$$

Onde:

Φ_{solar} o fluxo solar diretamente incidente na superfície;

$\Phi_{atmosfera}$ o fluxo de radiação proveniente do espalhamento atmosférico e

$\Phi_{ambiente}$ o fluxo refletido por outras superfícies.

Sendo o fluxo solar diretamente incidente na superfície (Φ_{solar}) nulo, apenas o fluxo de radiação proveniente do espalhamento atmosférico ($\Phi_{atmosfera}$) e refletido por outras superfícies ($\Phi_{ambiente}$) deve ser considerado. Além disso, no caminho da superfície até o sensor, a parcela de energia refletida é afetada pela atmosfera. O espalhamento atmosférico se constitui numa parcela aditiva na energia detectada e medida pelo sensor, ou seja, aumenta o valor registrado.

Para uma região uniforme e suficientemente grande (Superfície Lambertiana), a radiação medida no sensor L_m é dada por (Kaufman and Sendra, 1988, Fraser et al., 1992).

$$L_m = L_0 + (\rho S T_{up} T_{down}) / (\pi (1-s \rho)) \quad (3)$$

Onde:

L_0 = radiação adicionada no trajeto objeto-sensor

ρ = reflectância da superfície

S = irradiância solar espectral média

T_{down} = transmitância total (para baixo) do topo da atmosfera à superfície da terra

T_{up} = transmitância total da superfície da terra ao sensor (para cima)

s = albedo esférico da atmosfera.

Esta suposição é adotada na correção radiométrica do espalhamento em imagens de satélite por um dos métodos mais tradicionais, o método do pixel mais escuro (Chavez, 1975 e Chavez, 1988). O método consiste em identificar, no histograma da imagem, as regiões mais escuras, aquelas cobertas por sombras. Como teoricamente estas regiões deveriam ter valor digital nulo, os valores mínimos do histograma são atribuídos à contribuição atmosférica. A correção é feita separadamente para cada banda espectral, pois o espalhamento afeta cada banda espectral, de maneira diferenciada em função do comprimento de onda, segundo a lei do espalhamento de Rayleigh (Schanda, 1986).

$$\sigma_s = \frac{2}{3} \frac{\pi^5 d^6}{\lambda^4} \left(\frac{n^2 - 1}{n^2 + 2} \right)^2 \quad (4)$$

Aqui:

d = diâmetro médio das partículas,

n = quantidade de partículas por unidade de volume

λ = comprimento de onda da radiação eletromagnética.

3. TRATAMENTO NO ESPAÇO IMAGEM

Duas diferentes abordagens podem ser encontradas na literatura para o tratamento das sombras (Salvador et al., 2001). A primeira se baseia na modelagem geométrica das sombras e a segunda na análise de propriedades espectrais das sombras.

Na primeira abordagem são usados modelos geométricos para representar o conhecimento sobre a geometria tridimensional de cena, os objetos e a geometria de iluminação, como é apresentado em Gonçalves (2006a), Gonçalves (2006b) ou Zahn et al (2005). Neste caso, os elementos da geometria da cena são conhecidos. O ângulo de elevação solar, por exemplo, é calculada a partir da data de aquisição da imagem e o local de estudo. Ao mesmo tempo, uma descrição detalhada dos objetos em três dimensões é necessária. Como estas informações nem sempre se encontram disponíveis para uma imagem, a aplicação destes métodos é restrita.

A segunda abordagem é mais geral e identifica sombras explorando suas propriedades em termos de brilho, cor e forma, como é mostrado em Salvador et al. (2001). Estes métodos se baseiam na análise dos valores digitais, separando pixels com valores baixos e analisando os agrupamentos formados, a fim de constituir áreas de sombra significativas.

A proposta de métodos robustos para a detecção de sombras é considerada como um problema difícil por Wang e Wang (2008), pois a sombra normalmente detém algumas propriedades especiais em espaços de cor diferente. É esperado que a sombra diminua a resposta espectral, por isso parece lógico utilizar métodos que busquem áreas de sombra no espaço IHS. Porém, como Tsai (2006) aponta, objetos azuis escuros e objetos escuros são confundidos durante a segmentação no espaço IHS.

Considerando apenas a imagem, a primeira etapa consiste na análise das características espectrais das sombras para identificar os pixels escuros. Para isto, a forma mais direta é a aplicação de técnicas de limiarização na busca de pixels escuros no histograma. Com um limiar estabelecido, procede-se à etapa de binarização dos valores dos pixels, segundo a equação 5. O problema, neste caso, consiste em determinar o valor do limiar ótimo.

$$\begin{aligned} &\text{Se } x < \text{limiar, então } y = 0 (\text{sombra}) \\ &\text{caso contrário, } y = 255 (\text{outros}) \end{aligned} \quad (5)$$

Aqui x corresponde ao valor digital do pixel e y o valor da imagem de saída.

Um resultado similar pode ser obtido multiplicando o valor digital por um valor positivo ou adicionando uma constante, de maneira a forçar os valores maiores ao limiar a superar o valor máximo da imagem, 255 para imagens de 8 bits, segundo a equação 6. Neste caso, tanto uma constante B ou um fator multiplicador A podem ser usados para esta finalidade.

$$y = x * A + B \quad (6)$$

Na equação 6, y representa o novo valor da imagem. Caso este valor seja superior a 255, ele recebe o valor 255.

A limiarização (*thresholding*) de imagens de nível de cinza é um problema clássico no processamento de imagens largamente pesquisado (ver, por exemplo, a publicação clássica de Fu e Mui, 1981 ou Sahoo et al, 1988) e consiste na seleção do limiar mais adequado para separar a informação desejada do fundo, ou objetos indesejados. Como as sombras são caracterizadas por ocupar a região inferior do histograma e quando outros objetos não são tão escuros, a limiarização é potencialmente ideal para sua detecção, desde que o limiar mais adequado seja encontrado, como reporta Dare (2005). Exemplos são encontrados em Nagao et al. (1979) tratando fotografias aéreas, ou Shettigara e Sumerling (1998) usando imagens SPOT.

Também existe a opção de efetuar a classificação (ou segmentação e classificação) de imagens multiespectrais, separando as sombras em uma classe espectral do conjunto a ser classificado. A classificação permite a integração de outras bandas espectrais, no caso das imagens de alta resolução, como IKONOS ou Quickbird. Porém, o uso de mais de uma banda não será abordado neste artigo.

3.1 Métodos de contexto

Dentro do grupo de métodos de contexto entendem-se, para fins deste artigo, aqueles métodos que analisam também a vizinhança do pixel em questão. Uma abordagem é a utilização de filtros. Neste caso, o valor resultante do pixel é calculado como a soma ponderada da vizinhança.

$$y = \sum_{i=1}^{NV} w_i \cdot x_i \quad (7)$$

Onde y é o valor de saída do pixel central, x o valor do pixel na vizinhança, w o peso atribuído ao vizinho e NV o número total de pixels na vizinhança. Esta mesma operação pode ser desdobrada, separando o pixel central de seus vizinhos adjacentes, da forma:

$$y = A \cdot c + \sum_{i=1}^{NV-1} w_i \cdot v_i \quad (8)$$

Neste caso, A representa o peso do pixel central c , e v_i representa os elementos na vizinhança excluindo o pixel central. Representando o produto total na vizinhança por B , e o peso do pixel central por A tem-se uma formulação similar à equação 6. A diferença é que, neste caso, a componente B depende dos valores na vizinhança.

3.2 Análise da matriz de co-ocorrência

A matriz de co-ocorrência de valores digitais, também referida pela sigla GLCM (*gray-level cooccurrence matrix*) provou ser uma ferramenta muito útil para a análise e descrição de textura. Proposta originalmente por Haralick et al (1973), o método da matriz de co-ocorrência se baseia na análise da repetição de uma certa configuração de valores digitais na imagem. Segundo é descrito em Sonka et al. (1999) a ocorrência de uma determinada configuração de valores digitais na imagem pode ser descrita por uma matriz de frequência relativa $P_{\square,d}(a,b)$, que descreve a frequência com que dois pixels com os valores a e b ocorrem na imagem separados por uma distância d na direção \square . Para isto, é contado o número de vezes (estimada a frequência) que ocorre o valor a no pixel central de uma janela ao mesmo tempo em que ocorre o valor b no vizinho localizado à distância d na direção \square . No exemplo mostrado na Figura 1, obtido em Sonka et al. (1999), é mostrada o resultado do cálculo da matriz de co-ocorrência (P) da imagem I, o quadro da esquerda, considerando a distância de um pixel e ângulo nulo, o que equivale ao pixel localizado à direita. A matriz P traduz quantas vezes um pixel com valor b ocorre à direita de um valor a . Por exemplo, o par $a=0$, e $b=0$ pode ser encontrado 4 vezes na imagem, enquanto o par $a=0$ e $b=4$ nunca ocorre.

Figura 1 – Exemplo de cálculo da matriz de co-ocorrência da imagem I, considerando a distância de um pixel e ângulo nulo. Adaptado de Sonka et al. (1999).

$$I = \begin{bmatrix} 0 & 0 & 1 & 1 \\ 0 & 0 & 1 & 1 \\ 0 & 2 & 2 & 2 \\ 2 & 2 & 3 & 3 \end{bmatrix} \quad P_{0^\circ,1} = \begin{bmatrix} 4 & 2 & 1 & 0 \\ 2 & 4 & 0 & 0 \\ 1 & 0 & 6 & 1 \\ 0 & 0 & 1 & 2 \end{bmatrix}$$


(a)
(b)

O problema é que, como é muito oneroso armazenar a relação entre o pixel central e todas as posições dos vizinhos, é escolhido geralmente um único vizinho, descrito com base nos parâmetros d e \square . O tamanho da matriz de co-ocorrência é definido pela resolução radiométrica da imagem, geralmente 256x256. Na prática, variando a relação espacial, orientação e distância, são obtidas diversas matrizes de co-ocorrência, a partir das quais são extraídos parâmetros de textura, como descrito em Haralick (1979) e Sonka et al (1999). Entre os parâmetros mais relevantes encontram-se a energia, entropia, contraste, variância, correlação e inversa de diferença de momento (Otsu, 1979).

Uma informação contida nesta matriz está relacionada à ocorrência de bordas, e conseqüentemente áreas uniformes. A identificação de sombras pode ser baseada

na análise do gradiente (Wang e Wang, 2008), pois altos valores de gradiente são esperados no perímetro da região de sombra. Como aponta Mokji e Bakar (2007) a magnitude de borda também pode ser definida pela diferença de valor digital entre pixels vizinhos, o que corresponde à distância à diagonal principal na matriz de co-ocorrência, mostrada na Figura 2a.

Figura 2 – Esquema da Matriz de Co-Ocorrência. (a) segundo o conceito de uniformidade segundo Haddon e Boyce (1989) e Mokji e Bakar (2007), áreas de menor contraste se concentram perto da diagonal principal; (b) divisão proposta por Mokji e Bakar (2007) A e D correspondem a áreas uniformes na imagem, sendo C e D os elementos da matriz que resultam de regiões de alto contraste.



A análise da matriz de co-ocorrência apresentada por Haddon e Boyce (1989) e Mokji e Bakar (2007) para separar sombras de objetos em imagens fotográficas pode ser estendida à identificação de sombras em imagens de satélite. Esta análise consiste na divisão da matriz de co-ocorrência em quatro regiões, que são separadas pelo valor de limiar T na Figura 2b. A região A apresenta áreas escuras enquanto a região D variações dentro de áreas claras. As regiões B e C representam as transições entre áreas claras e áreas escuras.

Se na matriz de co-ocorrência encontram-se armazenadas as frequências relativas de diferentes combinações de valores digitais, os valores próximos à diagonal principal resultam de áreas uniformes, dentre as quais estão as sombras. A idéia é então procurar por regiões, que são escuras e uniformes.

Uma medida derivada da matriz de co-ocorrência para a estimativa da uniformidade é dada pelo parâmetro de contraste, proposto por Haralick (1979). Este parâmetro calcula o contraste (Con) em toda a imagem, incluindo áreas uniformes e fronteiras, segundo a equação 9

$$\text{Con} = \sum_{i=1}^{NV-1} (i-j) * P_{\phi,d}(a,b) \quad (9)$$

Onde:

NV= valor digital máximo da imagem, dado pela resolução radiométrica.

Para determinar o limite entre áreas claras e escuras usando os valores da matriz de co-ocorrência $C(i,j)$, Mokji e Bakar (2007) propõem usar a equação 10:

$$T = \frac{1}{\eta} \sum_{b=0}^{t-p} \sum_{a=b+p}^t \frac{a+b}{2} P_{\phi,d}(a,b) \quad (10)$$

Com:

$$\eta = \sum_{b=0}^{t-p} \sum_{a=b+p}^t P_{\phi,d}(a,b)$$

Onde

a,b representam os elementos da matriz de co-ocorrência $P_{\phi,d}(a,b)$, calculada para uma distância d na direção ϕ ;

p é um limiar de uniformidade escolhido pelo usuário e

t é o maior valor digitado na imagem.

4. MÉTODO

O objetivo do algoritmo proposto é a extração e classificação das sombras em imagens de sensoriamento remoto. O método aplicado é do tipo adaptativo, pois não é utilizado um limiar global, como no caso da binarização por limiar (Otsu, 1979), mas o valor do limiar depende da vizinhança e do pixel central. Para a determinação deste limiar local é analisada a matriz de co-ocorrência. A proposta aqui é estabelecer uma maneira diferente de dividir a matriz.

Na Figura 2b, a matriz é dividida em quatro regiões, sendo duas delas, A e D, associadas a regiões uniformes. Na análise proposta por Mokji e Bakar (2007), a matriz pode ser dividida em regiões de alto e baixo contraste usando um limiar (mb). Assim, uma região de alto contraste satisfaz:

$$SE \ j > i + mb \quad (11)$$

Por outro lado, um pixel dentro de uma região uniforme satisfaz:

$$j < i + mb \text{ e } j > i - mb \quad (12)$$


Esta definição condiz com o fato de que regiões uniformes se encontram perto da diagonal principal (Figura 2a), a uma distância mb da mesma. Logo, Mokji e Bakar (2007) propõem definir uma região dentro da matriz de co-ocorrência em função do limiar proposto pelo usuário (mb), que pré-estabelece a uniformidade das

regiões. “Se: $j < i + mb$ e $j > i - mb$ ”, então se trata de uma região uniforme, conforme o parâmetro de contraste de Haralick.

O limiar calculado T é usado para binarizar a imagem. Aplicar este limiar apenas aos valores da imagem equivale a dividir a matriz de co-ocorrência usando apenas a linha vertical da Figura 2b. Já se a vizinhança também é analisada, usando o mesmo limiar, a região quadrada A é caracterizada como sombra. O cálculo do Limiar T, porém apresenta uma deficiência, pois a dispersão de regiões claras (quadrado D), especialmente, não é simétrica.


As Figuras 3 e 4 mostram os valores da matriz de co-ocorrência em uma escala de cores e o histograma ao longo da diagonal principal da matriz de co-ocorrência da imagem de 11 bits mostrada na Figura 6. É visível que os valores mais altos ao longo da diagonal principal encontram-se mais dispersos e sua distribuição é assimétrica. A consequência da distribuição irregular dos valores na matriz é que o cálculo do limiar, como proposto por Mokji e Bakar (2007), tende a produzir valores muito altos.

Figura 3 – Exemplo de matriz de co-ocorrência. Variação em escala de cores: Vermelho representa maior frequência, azul menor frequência e branco representa elementos nulos.



O ponto de corte ideal para o caso mostrado na Figura 4 estaria localizado no vale entre os dois agrupamentos, em torno de 250. Para encontrar esse vale, a variação das frequências ao longo da diagonal principal pode ser analisada. Desta forma, o problema se torna unidimensional, sendo possível aplicar os diferentes métodos de segmentação por limiarização.


Figura 4 – Histograma da frequência de valores ao longo da diagonal da matriz de co-ocorrência a figura 3.



Nesta pesquisa, o método proposto por Rosenfeld e de la Torre (1983) é empregado, embora qualquer outro método seja viável. O método de segmentação proposto por Rosenfeld e de la Torre (1983) consiste em calcular a diferença entre o envoltório do histograma e o próprio histograma. As regiões com maior diferença correspondem a vales. Assim sendo, a tarefa consiste em identificar os máximos locais desta diferença para encontrar o limiar. Para facilitar a análise, é recomendado aplicar uma transformação logarítmica aos valores do histograma, a fim de contornar o problema da diferença de altura dos picos, bem como suavizar sua variação usando um filtro do tipo passa baixas unidimensional.

O limiar assim encontrado pode ser usado para a segmentação das sombras. Na Figura 3, é considerado mais razoável traçar o limite entre sombra e não-sombra com uma única reta, perpendicular à diagonal principal da matriz de co-ocorrência, como mostra a Figura 5, passando pelo vale. Com o intuito de selecionar apenas áreas uniformes, a matriz de co-ocorrência pode ser dividida em função da distância à diagonal principal. Assim, a matriz apresenta regiões com três características na Figura 5b. Regiões uniformes de sombras (A), caracterizadas por valores baixos e alta correlação entre pixels vizinhos. A segunda região (B) agrupa pixels claros em regiões uniformes. Finalmente os pixels em (C) são pixels em regiões pouco uniformes. Porém, quando o valor do limiar é muito baixo, o uso das duas linhas paralelas para demarcar áreas uniformes escuras não é necessário, visto que para valores baixos de limiar apenas pequenos afastamentos da diagonal principal são possíveis.

Figura 5 – Divisão da matriz de co-ocorrência com base na análise do histograma ao longo de sua diagonal principal.




5. EXPERIMENTOS

Nesta seção são apresentados experimentos com duas imagens em nível de cinza. A primeira é uma fotografia aérea digital em preto e branco. A segunda é uma imagem Quickbird, pancromática de uma região urbana em Curitiba, Paraná. O primeiro exemplo é ilustrado nas Figuras 6 e 7. Na Figura 6 é mostrada a fotografia digital aérea em níveis de cinza (8 bits), com alta resolução espacial. A presença de um estádio, prédios e árvores altas cria grandes áreas de sombra projetadas nas ruas e outros objetos. Na Figura 7 é mostrado o resultado da aplicação da metodologia proposta a esta imagem.

Figura 6 – recorte de fotografia aérea.



Figura 7 – Áreas de sombra (vermelho) da fotografia aérea.




As Figuras 8 e 9 ilustram o segundo exemplo com uma imagem Quickbird-PAN, sendo a Figura 8 a imagem original e a 9 o resultado. Tipicamente, o sol incide desde o norte, criando sombras ao sul dos objetos mais elevados, como prédios e árvores. Essa imagem tem menor resolução espacial e menor contraste. A imagem apresenta dois desafios: as imagens Quickbird-PAN têm resolução radiométrica maior e são mais afetadas pelo espalhamento atmosférico.

A primeira limitação é facilmente contornada pelo uso de uma abordagem adaptativa, pois o desempenho do método não depende da resolução radiométrica da imagem. Esta é uma vantagem em relação a filtros com pesos pré-definidos.

Figura 8 – Recorte de imagem pancromática Quickbird de Curitiba.



Figura 9 – áreas de sombra na imagem Quickbird.




A segunda limitação se refere ao espalhamento atmosférico. A Figura 3 mostra os valores da matriz de co-ocorrência da imagem Quickbird mostrada na Figura 8. Na Figura 2 não existem valores nulos ou próximos a zero. As áreas de sombra têm valores superiores a 150. Logo, o efeito da contribuição atmosférica deveria ser reduzido antes da aplicação de filtros, por exemplo, aplicando métodos de correção radiométrica. Já as abordagens adaptativas absorvem este problema, pois a detecção da região onde ocorre a separação da sombra de outros elementos ocorre de forma automática.

Um esquema das funções usadas para discriminar sombras, considerando a vizinhança, é mostrado na Figura 10. No eixo horizontal está representado o valor do pixel central (c). No eixo vertical o valor da vizinhança. Para fins desta representação, a média da vizinhança é usada como valor representativo (v). O limiar de Mokji e Bakar (2007) produz um valor muito alto, 229. A filtragem de Santos et al. (2006) considerando 11 bits produz uma reta com pouca diferença em relação à vertical. Assim sendo, o resultado é mais influenciado pelo valor do pixel central, passando a ser quase uma operação de thresholding. A divisão da matriz de ocorrência no sentido perpendicular à sua diagonal principal usando o parâmetro derivado da análise da variação das frequências ao longo da diagonal principal propicia uma melhor identificação das sombras.

A figura 10 serve para comparar as diferentes abordagens. Os métodos de filtragem atuam sem considerar as características radiométricas das imagens. A adoção de pesos diferentes pode alterar a inclinação da reta que caracteriza as sombras, porém sua posição é fixa, não considera as tonalidades da imagem. O método de Mokji e Bakar (2007) leva em consideração o contraste na imagem, porém não aperfeiçoa a localização do limiar. O método aqui proposto é adaptativo e se baseia na localização de um vale no histograma, com o que ele contorna a

difículdade de diferenças de tonalidade entre imagens. O limiar proposto é traçado perpendicular a diagonal [principal, onde se concentram as regiões uniformes.

Figura 10 – Comparação do efeito dos filtros de Santos et al (2006), Mokji e Bakar (2007) e o segmentação da diagonal da matriz de co-ocorrência (DMC) superposto à matriz de co-ocorrência.



6. CONCLUSÕES

Neste trabalho foi desenvolvido um método para a segmentação de sombras baseado na análise da diagonal da matriz de co-ocorrência.

Na primeira parte do texto é discutido um modelo conceitual para a identificação de sombras baseado nos princípios físicos de sensoriamento remoto, salientando o fato das sombras não apresentarem um valor igual em todas as bandas em função do espalhamento e às diferenças de iluminação.

Na discussão de diferentes métodos para identificação de sombras baseados na análise da vizinhança do pixel (métodos de contexto) foi proposta uma maneira de avaliar o efeito da vizinhança no filtro baseada na análise da reta que cada método produz no espaço 2D pixel central/vizinhança. Foi mostrado que em métodos com retas paralelas (ou próximas disso) ao eixo de vizinhança, os valores dos vizinhos pouco afetam o resultado e geram segmentações muito similares àquelas que consideram apenas o pixel central. Ao mesmo tempo, esta análise mostra a viabilidade do uso da matriz de co-ocorrência para a proposta de uma solução.

No artigo é proposto o uso de uma matriz de co-ocorrência modificada que permite identificar áreas uniformes escuras, que correspondem a sombras. Esta matriz calcula a co-ocorrência entre o valor do pixel central e da média de seus vizinhos dentro de uma janela móvel. Assim, a necessidade de fixar uma direção é contornada. Foi proposto um método que segmenta a diagonal principal da matriz de co-ocorrência e identifica nela os agrupamentos associados a valores digitais menores, que são as sombras. O método de segmentação do histograma resultante

pode ser variado, para o qual existem outras opções na literatura. A principal contribuição do trabalho aqui apresentado reside no fato do método buscar regiões uniformes e escuras na matriz de co-ocorrência. O uso de uma reta perpendicular à diagonal principal possibilita uma melhor discriminação das áreas de sombra.

O método proposto é do tipo adaptativo e pode ser usado tanto em imagens de 8 bits como também estendido à maiores resoluções radiométricas. Seu funcionamento não é afetado pela eventual contribuição atmosférica, que afeta principalmente as bandas do visível. O efeito do espalhamento é absorvido pela fixação de um limiar derivado do histograma da diagonal principal. As possíveis desvantagens do método encontram-se associadas à definição do vale do histograma da diagonal principal. Se este vale não for claro, então as sombras não serão caracterizadas.

Espera-se, no futuro desenvolvimento desta pesquisa, avaliar o uso de outras maneiras de segmentar a diagonal principal da matriz de co-ocorrência, de maneira a desenvolver variações que venham tornar o método mais eficiente. O mesmo método também será avaliado usando imagens terrestres, pois ele apresenta potencial para a detecção e modelagem de objetos na visão computacional.

REFERENCIAS BIBLIOGRÁFICAS

- CHAVEZ, P. S., JR.. 1975. Atmospheric, solar, and MTF corrections for ERTS digital imagery. *Proc. Am. Soc. Photogrammetry*, Fall Technical Meeting, Phoenix, AZ, p. 69.
- CHAVEZ, P. S., JR.. 1988. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. *Remote Sens. Environ.*, 24: 459-479.
- DARE, P. M.. 2005. Shadow analysis in high-resolution satellite imagery of urban areas. *Photogrammetric Engineering and Remote Sensing*, 71:169-177.
- FRASER, R. S., FERRARE, R. A., KAUFMAN, Y. J., MARKHAM, B. L., MATTOO, S.. 1992. Algorithm for atmospheric corrections of aircraft and satellite imagery. *Int. J. Remote Sensing*, 13(3):541-557.
- FU, K.S., MUI, J.K.. 1981. A survey on image segmentation; *Pattern Recognition*. 13(1):3-16.
- GONÇALVES, J.. 2006a. Geometric and Radiometric Improvement of an Ikonos Panchromatic Image Using a Digital Surface Model. *Springer Lecture Notes in Computer Science*, 4142:742-751.
- GONÇALVES, G.A.. 2006b. *Deteção Automática de Alterações na Cartografia Cadastral com Base em Imagens de Câmaras Digitais*. Tese de Doutorado em Ciências Geodésicas, Universidade Federal do Paraná. 230 p.
- HARALICK R.M., SHANMUGAM K., DINSTEN I.. 1973. Textural Features for Image Classification, *IEEE Transactions on Systems, Man and Cybernetics*, SMC-3: 610-621.

- HARALICK, R. M.. 1979. Statistical and Structural Approaches to Texture, *Proceedings of the IEEE* 67(5): 786–804.
- HADDON, J.F., BOYCE, J.F.. 1989. Simultaneous image segmentation and edge detection, *Proceedings of the IEEE Third International Conference on Image Processing and its Applications*, University of Warwick, UK, p. 411–415.
- KAUFMAN, J. Y., SENDRA, C.. 1988. Algorithm for automatic atmospheric corrections to visible and near-IR satellite imagery, *Int. J. Remote Sensing*, 9(8): 1357 – 1381.
- MOKJI, M.M., BAKAR, S.A.R.. 2007. Adaptive Thresholding Based On Co-Occurrence Matrix Edge Information. *Journal of computers*, 2(8): 44-52.
- NAGAO, M., MATSUYAMA, T., IKEDA, Y.. 1979. Region extraction and shape analysis in aerial photographs. *Computer, Graphics and Image Processing*, 10(3): 195-223.
- OTSU, N.. 1979. A Threshold Selection Method from Gray-Level Histogram”, *IEEE Trans. on System Man Cybernetics, SMC*, 9(1): 62-66.
- ROSENFELD A, DE LA TORRE P.. 1983. Histogram concavity analysis as an aid in threshold selection. *IEEE Trans. on System Man Cybernetics, SMC*-13(3):231–235
- SAHOO, P.K. SOLTANI, S. WONG A.K.C. CHEN, Y.C.. 1988. A survey of thresholding techniques, *Computer Vision Graphics Image Processing* 41:233–260.
- SALVADOR E., CAVALLARO, A., EBRAHIMI, T.. 2001. Shadow identification and classification using invariant color models. *2001 IEEE International Conference on Acoustics, Speech, and Signal Processing Proceedings*, vol. 3, p. 1545-1548.
- SANTOS, D. R., DALMOLIN, Q., BASSO, M. A.. 2006. Detecção automática de sombras em imagens de alta resolução. *Boletim de Ciências Geodésicas*, 12(1): 10-19.
- SCHANDA, E. 1986. *Physical Fundamentals of remote sensing*. Ed. Springer, Berlin.187p.
- SHETTIGARA, V.K., SUMERLING, G.M.. 1998. Height determination of extended objects using shadows in SPOT images, *Photogrammetric Engineering & Remote Sensing*, 64(1):35–44.
- SONKA, M., HLAVAC, V., BOYLE, R. (1999) *Image Processing: Analysis and Machine Vision*. of Brooks and Cole Publishing, segunda edição. ISBN 0-534-95393-X, Londres.
- SWAIN H. P., DAVIS M. S.. (1978). *Remote Sensing: The Quantitative Approach*, McGraw-Hill Int. Book Co., New York.
- TSAI, V.J.D.. 2006. A comparative study on shadow compensation of color aerial images in invariant color models. *IEEE Transactions on Geosciences and Remote Sensing*, 44(6): 1661-1667.

- VU T. T., MATSUOKA M., YAMAZAKI F.. 2008. Shadow analysis in assisting damage detection due to earthquakes from Quickbird imagery. *International Journal of Remote Sensing*, 9(7): 1945-1963.
- WANG, Y, WANG, S.. 2008. Shadow detection of urban color aerial images based on partial differential equations . *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. Vol. XXXVII. Part B2. Beijing.
- ZHAN, Q., SHI, W., XIA, Y.. 2005. Quantitative analysis of shadow effects in high-resolution images of urban areas. In *International Archives of Photogrammetry and Remote Sensing*, Vol 36, (8/W27).

(Recebido em junho de 2010. Aceito em março de 2011)