

MÉTODO ADAPTATIVO PARA DETECÇÃO SUPERVISIONADA DE NUVENS E SOMBRAS EM IMAGENS DE CENAS NATURAIS

Adaptive Supervised Method for Detection of Clouds and Shadows in Images of Natural Scenes

**Letícia Figueiredo Sartorio¹, Fabiano Soares Dias²
& Daniel Capella Zanotta¹**

¹ Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Sul – IFRS
Curso de Geoprocessamento – Laboratório de Geotecnologias na Gestão Municipal

Rua Eng. Alfredo Huch, 471 Rio Grande - RS, Brasil
leticia.sartorio@outlook.com, daniel.zanotta@riogrande.ifrs.edu.br

² Universidade Federal do Rio Grande, Campus Carreiros – FURG

Curso de Engenharia da Computação
Av. Itália, KM 8, Rio Grande – RS, Brasil
fabianodias020@gmail.com

*Recebido em 10 de Junho, 2017/ Aceito em 20 de Julho, 2017
Received on June 10, 2017/ Accepted on July 20, 2017*

RESUMO

O objetivo deste trabalho é apresentar um método supervisionado para detectar a presença de nuvens e sombras em imagens da série de satélites *Landsat*. A presença de condições meteorológicas desfavoráveis é um dos fatores que impossibilitam ou dificultam a utilização de imagens no sensoriamento remoto de reflectância. Além de provocar a cobertura de algumas regiões da cena, o sombreamento projetado pelas nuvens também resulta na diminuição significativa do potencial de utilização dos dados. Em aplicações onde as áreas atingidas se distribuem irregularmente pela cena, o processo de separação das áreas úteis pode se transformar, quando realizado manualmente, em uma tarefa complexa e subjetiva. No entanto, processos puramente automáticos dificilmente produzem resultados satisfatórios em todas as situações. A abordagem sugerida neste trabalho consiste na identificação semi-automática das regiões atingidas por nuvens e sombras na cena, preparando e otimizando a utilização desta para etapas posteriores do processamento. A técnica proposta inclui a seleção de amostras de diferentes tipos de nuvens e sombra na imagem. Pressupondo distribuição de probabilidade normal dessas três classes, os parâmetros estatísticos que descrevem as distribuições de cada amostra são utilizados para definir intervalos multiespectrais de aceitação, em termos de desvio-padrão, em torno das **médias**. Experimentos realizados em três imagens da Amazônia com presença de nuvens (densas e finas), e sombra indicam a adequação da abordagem proposta quando comparada com produtos gerados automaticamente.

Palavras-chave: Sensoriamento Remoto, Processamento de Imagens, Detecção de Nuvens.

ABSTRACT

The aim of this work is to introduce a supervised method to detect the presence of clouds and shadows in satellite images of the Landsat series. The presence of harmful weather conditions is one of the factors that make it impossible or difficult to use remote sensing reflectance images. Besides causing coverage of some regions of the scene, shading resulted by dense clouds also results in significant reduction of the scene usage. In applications where the affected

areas are distributed irregularly by the scene, the process of separating the useful areas can represent, when visually made, in a complex and subjective task. However, purely automated processes rarely produce satisfactory results over every situation. The approach suggested in this work consists of semi-automatic identification of the regions affected by clouds and shadows on the scene, followed by preparing and optimizing the use of the image data for subsequent processing stages. The proposed technique includes selecting different types of clouds and shade samples in the image. Assuming normal probability distribution of these three classes, statistical parameters describing the distributions of each sample are used to define multispectral acceptance intervals, in terms of standard deviation, around averages. Experiments conducted in three images of the Amazon with the presence of dense and thin clouds, and shade indicate the adequacy of the proposed approach when compared with automatically generated products.

Keywords: Remote Sensing, Image Processing, Cloud Detection.

1. INTRODUÇÃO

Imagens fornecidas por satélites permitem monitorar a Terra subsidiando dados para mapeamento da cobertura do solo e mudanças ocorridas ao longo do tempo (BENZ *et al.*, 2004). Os produtos resultantes podem ser aplicados em diversas áreas, como análises ambientais, controle do crescimento urbano, monitoramento de cultivos agrícolas, caracterização do uso e cobertura do solo, previsões meteorológicas e planejamento militar (SCHOWENGERDT, 2007).

As faixas espectrais geralmente empregadas para o imageamento orbital óptico (sensoriamento remoto de refletância) partem do visível e costumam atingir comprimentos de onda próximos ao infravermelho médio (JENSEN, 2005). Em imagens adquiridas nessas faixas do espectro, é comum o registro de nuvens e suas respectivas sombras, principalmente em zonas tropicais que apresentam taxas elevadas de umidade (TSENG *et al.*, 2008), comprometendo estudos realizados através dessas imagens. Segundo Zhang e Xiao (2014), a superfície terrestre permanece coberta por nuvens em média 50 % do tempo, variando com a região do globo e tipo de cobertura do solo. Assim, a prévia detecção de nuvens e sombreamentos causados por estas se apresenta como etapa fundamental no pré-processamento de imagens a serem posteriormente utilizadas em estudos de sensoriamento remoto (AN, SHI, 2015).

O conjunto de nuvens que está presente na atmosfera se chama nebulosidade, e a mesma é responsável por barrar a radiação solar que adentra e deixa a superfície terrestre. A definição dos tipos de nuvens encontradas na atmosfera e registradas pelas imagens de sensoriamento remoto pode ser classificada usando a aparência

e a altura em relação à superfície (MENDONÇA & DANNI-OLIVEIRA, 2007). Em termos de aparência, distinguem-se três tipos: cirrus, cumulus e stratus. Cirrus são nuvens fibrosas, altas, brancas e finas. Stratus são camadas estratificadas que cobrem grande parte da atmosfera. Cumulus são massas individuais globulares de nuvens. Uma categorização mais detalhada reflete uma destas formas básicas ou é combinação delas. Em relação à altura da base em relação ao solo, as nuvens mais comuns são agrupadas em três famílias: nuvens altas (acima de 7 km) (entre 2 km e 7 km), e baixas (até 2 km). Neste trabalho nós assumiremos a seguinte categorização para as nuvens encontradas nas cenas, levando em consideração apenas a aparência e o grau de comprometimento da cena: stratus e cumulus (nuvens densas) e cirrus (nuvens finas).

Mesmo reconhecida a sua importância, a identificação de nuvens e sombras se torna difícil pelo fato desses elementos apresentarem características espectrais semelhantes a alguns alvos frequentemente encontrados na superfície terrestre, como certos tipos de solo e corpos d'água (IMAI *et al.*, 2007). Isso ocorre pelo fato de corpos d'água apresentarem maiores índices de absorção da energia eletromagnética e, desse modo, apresentam tonalidades escuras que podem ser facilmente confundidas com sombras geradas pelas nuvens. De forma similar, as nuvens possuem tendência a serem confundidas com determinados tipos de solo que apresentam alta refletância (SILVA *et al.*, 2007). Diversos métodos foram sugeridos ao longo do tempo para a detecção de nuvens e sombras. A limiarização de histogramas (*thresholding*), por exemplo, foi proposta por Simon (2103) com o objetivo de discriminar pixels correspondentes

a nuvens na imagem. Wang *et al.* (1999), desenvolveram uma técnica de detecção de nuvens e sombras para imagens *Landsat TM* que utilizou as diferenças nos níveis de reflectância entre os alvos. Polidório (2005) propõe uma metodologia para detecção de nuvens que utiliza parâmetros radiométricos, de cor, e índices de NDVI e NDWI. Irish (2000) também apresenta um algoritmo para detecção de nuvens que faz uso de dados termais e de reflectância, nesse caso aproveitando o fato de as nuvens geralmente apresentarem uma temperatura inferior a dos alvos na superfície. Também é possível abordar o problema das nuvens através de mosaicos compostos por sequências temporais de imagens, comprometendo, no entanto, a representatividade temporal do resultado. Os métodos acima citados se apresentam em sua maioria como automáticos e não supervisionados. Característica que agrega no fator automatismo do processo, mas apresenta fortes limitações quanto à generalização e extensão para aplicações diversas. A confusão de alvos é um dos principais problemas encontrados em métodos automáticos (SCHOWENGERDT, 2007). Por outro lado, identificar manualmente por interpretação visual as áreas atingidas por condições de nebulosidade e sombreamento é uma tarefa bastante trabalhosa e demorada, que produz resultados subjetivos.

Por conta da necessidade da remoção rápida, mas ao mesmo tempo precisa, de nuvens e sombras, esse trabalho propõe uma metodologia paramétrica para detecção supervisionada de nuvens encontradas nas imagens (cirrus, cumulus e stratus), bem como o efeito de sombreamento causado por estes. Para fins de simplificação, os componentes mencionados serão denominados daqui para frente como classes de nebulosidade. A técnica é baseada na seleção de amostras para cada uma das classes de nuvem que serão detectadas em uma imagem. Parâmetros estatísticos são extraídos das amostras para caracterizar a distribuição estatística das mesmas, determinando intervalos em termos do desvio padrão em torno das médias multiespectrais de cada amostra para que seja possível delimitar a presença de pixels contaminados com nebulosidade dos demais alvos na cena. Diferente de um classificador simples por máxima verossimilhança gaussiana, a metodologia proposta se apresenta como

uma análise não exaustiva, ou seja, nem todos os elementos da cena serão rotulados como pertencendo a alguma das classes assumidas de nebulosidade.

2. APROXIMAÇÃO GAUSSIANA E METODOLOGIA DE DETECÇÃO

A metodologia proposta neste trabalho para detecção das classes de nebulosidade assume aproximação normal das distribuições de probabilidade. Por tratar-se de uma técnica supervisionada, amostras das três classes de nebulosidade: nuvens densas, nuvens finas e sombra devem ser coletadas e analisadas quanto à hipótese assumida de normalidade dos dados.

O vetor de médias (μ) e a matriz de covariâncias (Σ) extraídos das amostras foram utilizados para estimar a função densidade de probabilidade gaussiana para cada classe. Uma representação unidimensional dessa distribuição pode ser expressa a partir da média (μ) e desvio padrão (σ), representando, respectivamente, μ e Σ (BUSSAB, MORETTIN, 2004). A equação 1 (mostrada em sua forma padronizada na (Figura 1), descreve analiticamente a representação normal dos dados para cada elemento x .

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left[-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2\right], \quad (1)$$

$x \in (-\infty, \infty)$

onde $f(x)$ corresponde a densidade de probabilidade de x .




Fig. 1 - Distribuição Normal padronizada e os respectivos desvios padrão a partir da média.

2.1 Verificação de normalidade dos dados

Tendo como base a hipótese de normalidade dos dados para as amostras envolvidas, é necessário que essa suposição seja verificada quantitativamente para garantir a correta utilização da metodologia proposta. Testes

como Kolmogorov-Smirnov, Lilliefors, ou Qui-quadrado são adequados para confirmar a hipótese de que as amostras têm uma distribuição gaussiana (BUSSAB, MORETTIN, 2004). Uma saída comum desses testes é o *p-valor* (que atesta a probabilidade de acerto do teste). Neste trabalho o *p-valor* resultante do teste Qui-quadrado (Equação 2) será usado indiretamente para medir o ajuste de cada amostra a uma distribuição normal de probabilidade.

$$\chi^2 = \sum_{i=1}^n (O_i - E_i)^2 / E_i \quad (2)$$

onde n representa a resolução radiométrica da imagem, O_i as contagens observadas no histograma resultante das amostras e E_i as contagens esperadas, baseando-se na distribuição de probabilidade descrita pela equação 1. Ainda que represente o ajuste dos dados a uma dada distribuição com precisão, os *p-valores* resultantes da aplicação do teste são bastante sensíveis à pequenas variações na distribuição dos dados amostrados. Para contornar esse problema e aumentar a representatividade do indicador do teste para a aplicação deste trabalho, um fator foi sugerido para atenuar as variações apresentadas pelo *p-valor* de saída do teste Qui-quadrado. Utilizando um decaimento logarítmico, os valores foram inseridos na expressão da equação (3) para determinar um fator de aceitação $I_c \{0,1\}$ indicativo de normalidade de cada amostrada coletada.

$$I_c = \left[\log(pvalor^{-1}) \right]^{-1} \quad (3)$$

Testes realizados com amostras sintéticas demonstraram uma suavização suficiente de *p-valor*, sem que este perca a sua propriedade discriminante. Baseado em experimentos realizados com os dados deste trabalho e em diversas outras aplicações em que a metodologia de detecção de classes de nebulosidade vem sendo empregada, sugere-se que valores de I_c acima de 0,5 são indicadores aceitáveis de normalidade da amostra colhida.

2.2 Identificação das classes de nebulosidade

A Figura 1 representa um exemplo da aproximação gaussiana padronizada, onde no

centro está localizada a média (zero) e a cada distância a partir da média, contabilizadas em unidades de desvio padrão para a direita e para a esquerda, representa uma proporção conhecida da distribuição de probabilidade (WEBB, 2002). A representação em termos de desvio padrão foi utilizada na presente metodologia para definir as regiões ocupadas por classes de nebulosidade em imagens multiespectrais. Um fator de multiplicação $f_c \{0,+\infty\}$ em termos do desvio padrão σ é atribuído para definir se o *pixel* em questão corresponde a alguma das classes de nebulosidade.

No caso, se o *pixel* analisado não estiver incluído em nenhuma das regiões de aceitação definida pelos limiares, o mesmo não será relacionado a alguma das três classes de nebulosidade. Para cada classe $c \{1,3\}$, o limiar de aceitação lim_c pode ser calculado a partir da equação 4:

$$lim_c = f_c \sqrt{\sum_{b=1}^k (\sigma_{c,b})^2} \quad (4)$$

Onde f_c é o fator de multiplicação escolhido para cada classe. Como proposto nesse trabalho, esse fator definirá, no espaço multidimensional, o número de desvios padrão a partir da média da classe amostrada onde se encontra a fronteira de decisão entre a inclusão ou não do elemento à classe. k indica o número de bandas espectrais da imagem de entrada e $\sigma_{c,b}$ é o desvio padrão da amostra da classe c na banda b .

Para cada elemento i da imagem de entrada, será calculado a sua distância espectral euclidiana (d_{ic}) em relação a média de cada classe c , como mostra a equação 5:

$$d_{ic} = \sqrt{\sum_{b=1}^k (i_{c,b} - \mu_{c,b})^2} \quad (5)$$

Onde $i_{c,b}$ é o elemento da classe c na banda b , $\mu_{c,b}$ é a média das amostras da classe c calculadas sobre a banda b ao longo do número total de bandas k .

A regra de decisão que definirá se cada elemento i será ou não atribuído a alguma das classes c de nuvem é definido pela equação 6.

$$\begin{cases} \text{Se } d_{ic} \leq \text{lim}_c \rightarrow d_{ic} \in c \\ \text{Se } d_{ic} > \text{lim}_c \rightarrow d_{ic} \notin c \end{cases} \quad (6)$$


3. EXPERIMENTOS E ANÁLISE

Para fins de teste da metodologia sugerida de detecção supervisionada de nuvens densas, nuvens finas e sombras, foram realizados três experimentos com recortes de imagens comprometidas pela presença de nebulosidade. Dentre as imagens utilizadas, duas foram adquiridas pelo sensor TM *Landsat 5* (órbita: 232, ponto: 67), adquirida em 6 de junho de 1989, outra (órbita: 232, ponto: 67) adquirida em 6 de abril de 1990, e uma pela sensor *OLI Landsat 8* (órbita: 221, ponto: 82), adquirida em 27 de janeiro de 2016. Todas apresentam 30 metros de resolução espacial para as bandas espectrais utilizadas nos experimentos (bandas 3,4 e 5, TM, e 4,5 e 6, OLI). A Figura 2 mostra as respectivas composições coloridas destas cenas escolhidas

.Para todos os experimentos, amostras multiespectrais de nuvem densa, nuvem fina e sombra foram coletadas e submetidas à avaliação de normalidade. Os resultados do teste preliminar são apresentados na Tabela 1.

Todas as amostras apresentaram valores acima de 0,5, assim, segundo este estudo, com boa representação gaussiana.


Na Figura 3 são apresentados os histogramas de cada experimento coletados para cada uma das amostras. Juntamente com os histogramas, a representação teórica da função densidade de probabilidade gaussiana esta representada para cada um (linha pontilhada) com o objetivo de auxiliar visualmente na análise de semelhança das distribuições. Ao inspecionar a figura, é possível verificar a semelhança do padrão gaussiano dos histogramas. Ainda assim, para a classe de nuvem (azul), alguns pixels correspondentes à saturação para o branco (255) dessa classe se apresentam como um pico no extremo esquerdo. Essa ocorrência é bastante comum em pixels de nuvem, mas, ainda assim, não foi capaz de provocar a reprovação dessas amostras nas avaliações de normalidade. Esse resultado se deve ao ajuste feito no *p-valor* proposto nesse trabalho com o objetivo de suavizar os resultados de saída do teste Qui-Quadrado, livrando os dados amostrados da interferência acentuada de ruídos como esse.



(a)



(b)



(c)

Fig. 2 – Imagens multiespectrais utilizadas no estudo. (a) *Landsat8-OLI* cobrindo região município brasileiro de Rio Grande/RS na composição RGB 6-5-4, (b) e (c) TM *Landsat 5* cobrindo regiões de desmatamento na Amazônia na composição RGB 5-4-3.

Tabela 1: Avaliação da normalidade das amostras de cada classe de nebulosidade pelo indicador i_c

	<i>Lansata</i> 8	<i>Landsat</i> 5-1	<i>Landsat</i> 5-2
Nuvem densa	0,7	0,68	0,66
Nuvem fina	0,74	0,86	0,66
Sombra	0,65	0,53	0,63

Com a aprovação das suposições de normalidade dos dados das amostras coletadas para os experimentos, o prosseguimento da metodologia prevê a definição dos limiares para as classes de nebulosidade. De maneira empírica, o fator de multiplicação para a classe nuvem densa foi definido como $f_{nuv} = 2$ unidades de desvio padrão, nuvem fina $f_{nev} = 1,5$ unidades de desvio de padrão e para sombra $f_{som} = 2$ unidades de desvio padrão. Estes valores se comportam bem para uma grande variedade de sensores e condições de nebulosidade encontradas, podendo sofrer pequenas variações

dependendo do sensor utilizado. Os valores para lim_c foram calculados a partir de cada um dos fatores juntamente com os dados das amostras de cada classe e experimento.

A Figura 4 apresenta os resultados da detecção de nuvem densa, nuvem fina e sombra para as imagens escolhidas.

Visualmente os resultados mostram que a detecção foi bem sucedida principalmente em regiões que os métodos automáticos costumam falhar: regiões de nuvens finas e sombras.

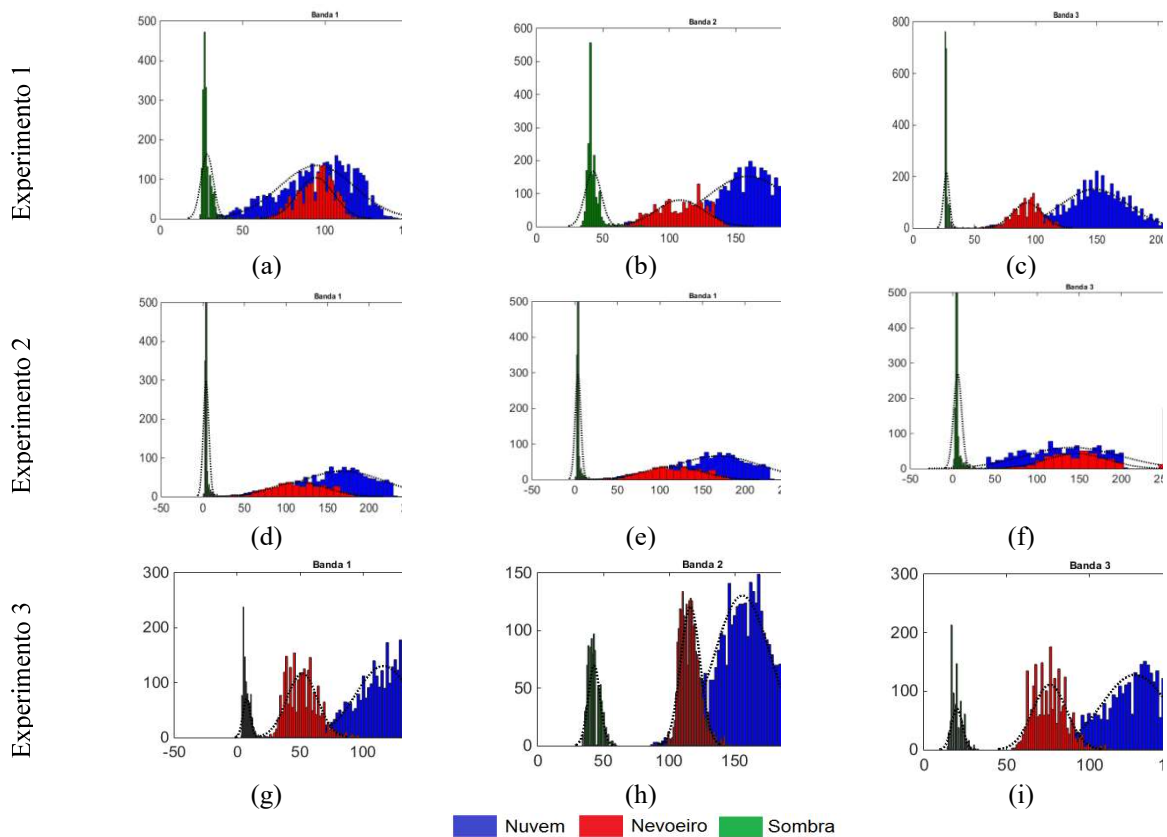


Fig 3 - Histogramas de cada amostra com aproximação gaussiana para as bandas envolvidas na análise (linhas pontilhadas adjacentes). Experimento 1: (a), (b) e (c). Experimento 2: (d), (e) e (f). Experimento 3: (g), (h) e (i).




Fig 4 - Resultados da detecção de nuvens densas, nuvens finas e sombras pela metodologia proposta. Experimentos 1, 2 e 3; (a), (b) e (c), respectivamente.

4. VALIDAÇÃO DOS RESULTADOS

Para a série de satélites *Landsat*, o serviço geológico americano (USGS) disponibiliza produtos gerados automaticamente que utilizam algoritmos avançados de reconhecimento de condições de nebulosidade. Esses produtos apresentam a cobertura de nuvens e sombras nas imagens e podem ser adquiridos juntamente com as mesmas no momento da solicitação. Os resultados alcançados pela metodologia proposta foram comparados diretamente com os mapas de nebulosidade produzidos pela USGS para as imagens em questão. Como parâmetro de validação, foram extraídos pequenos retângulos de cada uma das imagens testadas e realizada

interpretação visual das classes de nebulosidade (Figura 5). A tabela 2 mostra os resultados em termos de alarmes verdadeiros (acusação correta de alguma das classes).

Tabela 2: Análise de acurácia da metodologia proposta (alarmes verdadeiros) em comparação com o método automático da USGS

	<i>Landsat</i> 8	<i>Landsat</i> 5-1	<i>Landsat</i> 5-2
USGS	72%	57%	62%
Metodologia proposta	74%	76%	70,4%




Fig. 5 - Comparação entre os dados da USGS e a classificação manual para segmentos selecionados nas imagens dos experimentos: (a-c) recorte utilizado, (d-f) classificação manual por interpretação visual, (g-i) produto gerado pela USGS, respectivamente, (j-l) classificação pelo método proposto.

De acordo com a análise da tabela 2 e pela visualização dos resultados da Figura 5 é possível verificar que os produtos da USGS tendem a superestimar a presença de condições de nebulosidade nas imagens da série *Landsat*. Esse fato é confirmado pelo tamanho desses objetos nas imagens. Com relação ao método proposto, é possível verificar que existe melhor consistência espacial com os dados de referência. Uma possível explicação para o observado é que, uma vez que o método utilizado pela USGS é automático não adaptativo, é natural que seu funcionamento apresente falhas. No caso de nuvens, é preferível que seja feita uma superestimação dessa ocorrência do que permitir que algum estudo secundário assumira como livre de nebulosidade imagens filtradas pela máscara disponibilizada.

Por outro lado, os resultados apresentados pela metodologia proposta precisam de informações coletadas pelo usuário diretamente nas imagens. No entanto, os resultados se mostraram satisfatórios e apresentaram em média 10% e correspondência a mais do que os produtos da USGS nas áreas analisadas. Em algumas áreas que apresentam cobertura frequente de nuvens, a adequada identificação de áreas comprometidas é fundamental para a otimização dos dados em análises posteriores.

5. CONCLUSÕES

Neste trabalho, uma alternativa supervisionada para detecção de nuvens densas, nuvens finas e sombras em imagens de sensoriamento remoto foi estudada. Ao contrário de metodologias puramente automáticas e com pouca interferência do usuário, na abordagem aqui proposta o usuário deve colher amostras representativas de cada um desses componentes que costumam limitar a utilização de imagens em aplicações naturais. Para que os resultados do método sejam considerados confiáveis, é necessário que as amostras colhidas sejam submetidas a um teste de normalidade, que nesse estudo foi considerado a partir de uma adaptação do método Qui-quadrado. Com suposição gaussiana das classes envolvidas e fixando limiares de abrangência em termos de desvio padrão a partir das médias, foi possível identificar satisfatoriamente as regiões das imagens cobertas por nuvens densas, nuvens finas e sombras. A principal vantagem

desse método quando comparado com outros métodos supervisionados e não supervisionados é que as pequenas variações de imagem para imagem, presentes principalmente na classe de nuvem fina, são levadas em consideração pelo processo supervisionado. Assim, a associação dessa especificidade capturada em cada caso com a suposição de normalidade das classes, que é testada em cada experimento realizado, conferem ao método as condições para a otimização dos resultados utilizando uma aproximação Bayesiana. É importante ainda mencionar que essa metodologia não se aplica em cenas que não são naturais, uma vez que estas podem apresentar uma gama muito grande de alvos de tipos diferentes, eventualmente confundindo-se com as classes de nebulosidade. Além disso, ainda que o método não seja capaz de alcançar a plena precisão, a objetividade da técnica supervisionada quando comparada com a interpretação visual confere aos resultados um maior grau de isonomia ao longo da cena.

REFERÊNCIAS BIBLIOGRÁFICAS

- AN, Z.; SHI, Z. Scene Learning for Cloud Detection on Remote-Sensing Images. **IEEE Journal of selected topics in applied earth observations and remote sensing**, v. 8, n. 8, p. 4206–4222, 2015.
- BENZ, U. C ; HOFMANN, P. ; WILLHAUCK, G. ; LINGENFELDER, I. ; HEYNEN, M. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. *ISPRS Journal of photogrammetry and remote sensing* v. 58, p. 239–258, 2004.
- BUSSAB, W.; MORETTIN, P. A. Estatística básica. 5 ed. São Paulo, São Paulo Editora Saraiva, 2004. 548p.
- DURO, D. C.; FRANKLIN, S. E.; DUBÉ, M. G. A comparison of pixel-based and object-based image analysis with selected machine learning algorithms for the classification of agricultural landscapes using SPOT-5 HRG imagery. **Remote Sensing of Environment**, v. 118, p. 259–272, 2012.
- IRISH, R. Landsat 7 Automatic Cloud Cover Assessment. Algorithms for Multispectral, Hyperspectral, and Ultraspectral Imagery. **SPIE** Vol. 4049, pp. 348-355, 2000.

- JENSEN, J. R. **Introductory Digital Image Processing: A Remote Sensing Perspective**. New Jersey: Prentice Hall, 2005. 544p.
- MENDONÇA, F.; DANNI-OLIVEIRA, I. M. **Climatologia: noções básicas e climas do Brasil**. São Paulo: Oficina de textos, 2007, p. 65-70.
- POLIDORIO, A. M.; SILVA, W.A.; IMAI, N. N. Detecção de nuvens e sombras em imagens CCD/CBERS por correlação de pontos candidatos. **Anais XIII Simpósio Brasileiro de Sensoriamento Remoto (SBSR)**, Florianópolis, 2007, INPE, p. 6199-6206.
- POLIDORIO, A. M.; FLORES, F. C.; FRANCO, C.; IMAI, N. N.; TOMMASELLI, A. M. G. Detecção automática de sombras e nuvens em imagens CBERS e Landsat 7 ETM. **Anais XII Simpósio Brasileiro de Sensoriamento Remoto**, Goiânia, Brasil, n. 2002, p. 4233-4240, 2005.
- ZHANG, Q.; XIAO, C. “Cloud detection of RGB color aerial photographs by progressive refinement scheme,” **IEEE Transactions on Geoscience and Remote Sensing**, vol. 52, no. 11, pp. 7264-7275, Nov. 2014.
- SCHOWENGERDT, R. A. **Remote Sensing: Models and Methods for Image Processing**. 3. ed. San Diego, California: Elsevier, 2007. 515p.
- SILVA, W. A.; IMAI, N. N.; POLIDORIO, A. M. Detecção de nuvens e sombras em imagens CCD/CBERS por correlação de pontos candidatos. **Anais XIII Simpósio Brasileiro de Sensoriamento Remoto**, Florianópolis, Brasil, 21-26 abril 2007, *INPE*, p. 6199-6206, 2007.
- SIMON, P.; S.R., S. Automatic Cloud Detection Using Spectral Rationing and Fuzzy Clustering. **Advanced Computing, Networking and Security (ADCONS), 2013 2nd International Conference on**. **IEEE**, p. 90-95, 2013.
- TSENG, D.; TSENG, H.; CHIEN, C. Automatic cloud removal from multi-temporal SPOT images. **Applied Mathematics and Computation**, v. 205, n. 2, p. 584-600, 2008. Disponível em: <<http://dx.doi.org/10.1016/j.amc.2008.05.050>>.
- WANG, B.; ONO, A.; MURAMATSU, K. Automated Detection and Removal of Clouds and Their. **IEICE Transactions on information and systems**, v. 82, n. 2, p. 453-460, 1999.
- WEBB, A. R. **Statistical Pattern Recognition**. 2. ed. England: John Wiley & Sons, 2002. 514p.