

ANÁLISE COMPARATIVA ENTRE AS CORREÇÕES ATMOSFÉRICAS EM CLASSIFICAÇÕES PARAMÉTRICA E NÃO-PARAMÉTRICA

Higor Conde Coutinho¹
Cristiane Nunes Francisco²

1. Universidade Federal Fluminenses - Departamento de Análise Geoambiental – Laboratório de Sensoriamento Remoto (LASERE). higorccoutinho@gmail.com.
2. Universidade Federal Fluminenses - Departamento de Análise Geoambiental – Laboratório de Sensoriamento Remoto (LASERE). cristianenf@id.uff.br

ABSTRACT

This article performed a comparative analysis between atmospheric corrections in the vegetation classification using a parametric and a nonparametric classifier. The 5 bands of the RapidEye System were used. The atmospheric corrections used were: Dark Object Subtraction (DOS) and Moderate Spectral Resolution Atmospheric (MODTRAN). Supervised automatic classifications were made using two types of classifiers: Support Vector Machine-SVM and Maximum Likelihood-MAXVER, a nonparametric and a parametric, respectively. The comparative analyzes showed that there is no difference between the classifications generated by both classifiers between the TOA and DOS images, however, the difference between the classified images of MODTRAN and TOA, in both classifiers, varies between 10% for SVM and 20% for MAXVER. In addition to the noise present in the MAXVER classification, the classes that showed less difference correspond to those in which the spectral curves are distinct from the other classes, which may influence between the two classifiers. Thus, it was observed that, regarding the TOA classification, the correction by DOS did not show a significant difference on the classified image. Comparing the classifiers overlapping the classifications, a very high difference degree on pixel classified relationships was obtained. Analyzing the area charts, it was noticed that the values of the spectral curves are close in classes with close areas.

Keywords: Classification, atmospheric correction, MAXVER, SVM.

INTRODUÇÃO

As origens do sensoriamento remoto estão intrinsecamente ligadas ao processo de evolução do monitoramento da Terra, seja por objetivos de defesa ou por conhecimento dos recursos terrestres. Logo, a aquisição de imagens por sensores remotos tem se difundido desde a sua criação, com a obtenção, cada vez maior, de informações extraídas a partir delas.

Segundo Jensen (2009), para a produção das imagens, os sensores remotos orbitais aproveitam-se da energia da Radiação Eletromagnética, para isso, o ideal seria que os valores dessa energia fossem o mesmo desde o nível da superfície terrestre, quando ela é refletida pelos alvos ou objetos, quanto ao que chega ao sensor. Mas sabemos que a atmosfera possui matérias que interagem com o fluxo eletromagnético podendo absorver, refletir ou refratar tal fluxo, assim, interferindo diretamente no valor da energia que é registrado pelo sensor. Com isso, torna-se fundamental a minimização ou remoção dessas interferências.

Associado aos fatores tecnológicos, o estudo da vegetação se faz cada vez mais presente. A necessidade de monitorar apresenta-se necessária, seja por questões relacionadas à conservação e preservação ou para o monitoramento estrutural e de tipologias.

As técnicas de Processamento Digital de Informação nos permitem uma avaliação rápida e eficiente da modificação do espaço com o tempo. Tal processo tecnológico vem sendo usado de forma intensa no mapeamento da vegetação, com isso a técnica de classificação tem mostrado grande eficiência na identificação automática de alvos.

A classificação de imagens consiste, basicamente, na identificação de elementos nela presente a partir da associação dos pixels a uma determinada classe temática, sendo comparada em pelo menos duas bandas a fim de se verificar o mesmo pixel em diferentes respostas (FITZ, 2008)

Os métodos de classificação podem ser agrupados em função de uma fase de treinamento ou não onde há interação do observado, ou seja, podem ser divididos em função do tipo de treinamento, podendo ser: supervisionados, onde se fundamenta a coleta de amostras das regiões onde o usuário define como determinada classe, sendo chamadas de amostras de treinamento; e não – supervisionadas, onde a classificação se baseia em métodos estatísticos de análises de agrupamentos, demarcando as classes na cena sem a intervenção direta do usuário.

O tipo supervisionado ainda pode ser dividido em: paramétrico, onde se estima por meio de amostras os valores dos parâmetros populacionais, e não paramétricos, onde são empregados com distribuições não obedientes aos parâmetros da curva normal (SILVA, 2012; EASTMAN, 2006).

O objetivo do presente trabalho é fazer uma análise comparativa entre as correções atmosféricas na classificação da vegetação utilizando um classificador paramétrico e um não paramétrico.

A área de estudo corresponde a um recorte da cena RapidEye e possui 9,3 mil hectares. Está localizada nos limites dos municípios de Bom Jardim, Trajano de Moraes, Macaé e Nova Friburgo na Região Serrana do Estado do Rio de Janeiro. Possui diversidade de classes de vegetação, além da presença de outras classes de uso e cobertura da terra. Além disso, está localizada em relevo montanhoso com encostas íngremes. (Figura 1).

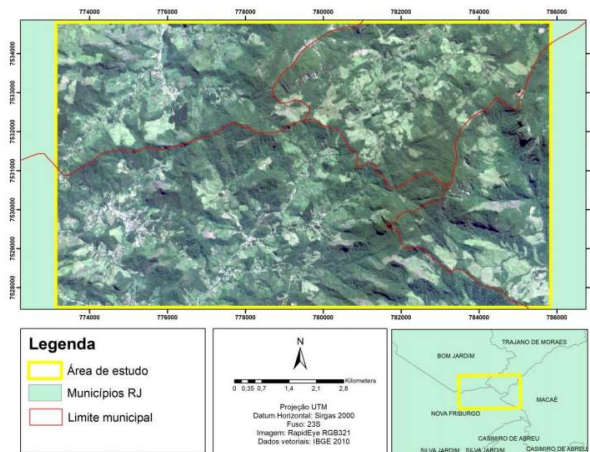


Figura 1 - Mapa de localização da área de estudo, Região Serrana Fluminense.

METODOLOGIA

Foram utilizadas as cinco bandas do sistema RapidEye que consiste em uma constelação de cinco satélites imageadores. A imagem utilizada no presente trabalho foi obtida no dia 04 de junho de 2014, que corresponde à aquisição na o período de estiagem adequado para estudos de vegetação. O mesmo apresenta resolução temporal de 5,5 e resolução espacial de 6,5 metros ambos no nadir (podendo passar para 5m quando ortorretificado). As imagens possuem, ainda, resolução radiométrica de 12 bits.

A primeira etapa do trabalho consistiu na correção atmosférica de todas as bandas RapidEye da área de estudo, feita por Gonçalves e Francisco (2017), a partir a aplicação do modelo empírico DOS e um modelo físico de transferência radiativa, MODTRAN. Para correção das imagens, é necessária a conversão de números digitais (ND) para radiância e, posteriormente, para os de reflectância do topo da atmosfera (TOA). Esta última imagem foi utilizada para realizar a comparação entre as imagens corrigidas.

A correção por DOS consiste em um método de correção atmosférica proposta por Chavez (1988) e denominado como correção atmosférica pelo pixel mais escuro. Tal método corresponde a modelo empírico de correção atmosférica, pois utiliza dados determinados pelas características da imagem, sendo, assim, simples de ser aplicado, o que o torna em um dos métodos mais comumente usados na correção das imagens de satélite (SONG et al., 2001).

O MODTRAN, diferente dos modelos de transformações empíricas, se apresenta como um modelo de transferência radiativa, ou seja, a entrada de dados é proveniente das características atmosféricas em relação a parâmetros como vapor d'água, ozônio,

profundidade óptica, tipo e margem de concentração de aerossóis. Ainda é possível informar parâmetros de referência de valores de reflectância de objetos vizinhos àqueles que se pretende gerar a correção (PONZONI et al., 2012). Portanto, modelos de transferência radiativa, como o MODTRAN, têm como base a simulação das características da atmosfera no momento da aquisição da imagem.

Todas as imagens corrigidas foram classificadas a partir dos classificadores supervisionados pixel-a-pixel, MAXVER (paramétrico) e SVM (não-paramétrico). A Máxima Verossimilhança (MAXVER) é uma classificação supervisionada paramétrica pixel a pixel muito utilizada em classificação de imagens devido a sua robustez, onde a exatidão gerada não é muito sensível a quebras moderadas e severas da pressuposição de multinormalidade das amostras de treinamento (COSTA, 98). O Support Vector Machine é um classificador que se baseia na teoria de aprendizado de máquinas proposto por Vapnik (1995) e Burges (1998). Tais técnicas utilizam o princípio de inferência chamado de indução, que se utilizam conclusões difundidas a partir de conjuntos de exemplos, e podem ser divididas em: supervisionadas e não supervisionadas.

Através da interpretação visual, foram identificadas nove classes de fitofisionomias para a realização das classificações: arbórea iluminada, arbórea não iluminada, arbustiva, herbácea clara, herbácea escura, eucalipto antigo, eucalipto recente, campo claro e campo escuro; além de mais três classes: afloramento rochoso, sombra, e solo exposto. Para as doze classes definidas foram coletados, no total, 118 amostras somando 23.292 pixels

Ao final foram geradas seis classificações, sendo três derivadas de cada classificador, MAXVER e SVM, correspondendo às três imagens corrigidas, TOA, DOS e MODTRAN. Por fim, a análise comparativa foi feita através da sobreposição entre as classificações, objetivando identificar se a correção das imagens gera diferentes resultados. Para isto, foram comparadas as classificações entre TOA e DOS e TOA e MODTRAN para cada classificador. A seguir, foram comparadas as classificações com a mesma correção, no entanto com classificadores diferentes, visando avaliar se correção as atinge.

RESULTADOS

Ao analisar os as curvas espectrais das classes isoladamente, verifica-se que nas amostras das imagens TOA, as respostas na região do visível são mais elevadas, pois ambas as correções atmosféricas consideram o espalhamento atmosférico, logo

subtraem das imagens a contribuição adicionada pela atmosfera nesta faixa espectral. Na região do infravermelho e vermelho de borda, a imagem MODTRAN apresentou valores mais altos de refletância, pois como considera a absorção da atmosfera, o modelo de transferência valor que foi absorvido pela atmosfera em função das condições da atmosfera no momento da obtenção da imagem. Por outro lado, como a correção do DOS considera apenas o espalhamento em todas as bandas, os valores das imagens corrigidas por este algoritmo ficam com valores menores (Figura 10).

Também é possível observar pela análise dos gráficos, que as bandas do infravermelho e vermelho de borda são as que discriminam as classes de vegetação, mostrando a sua importância nos estudos da vegetação.

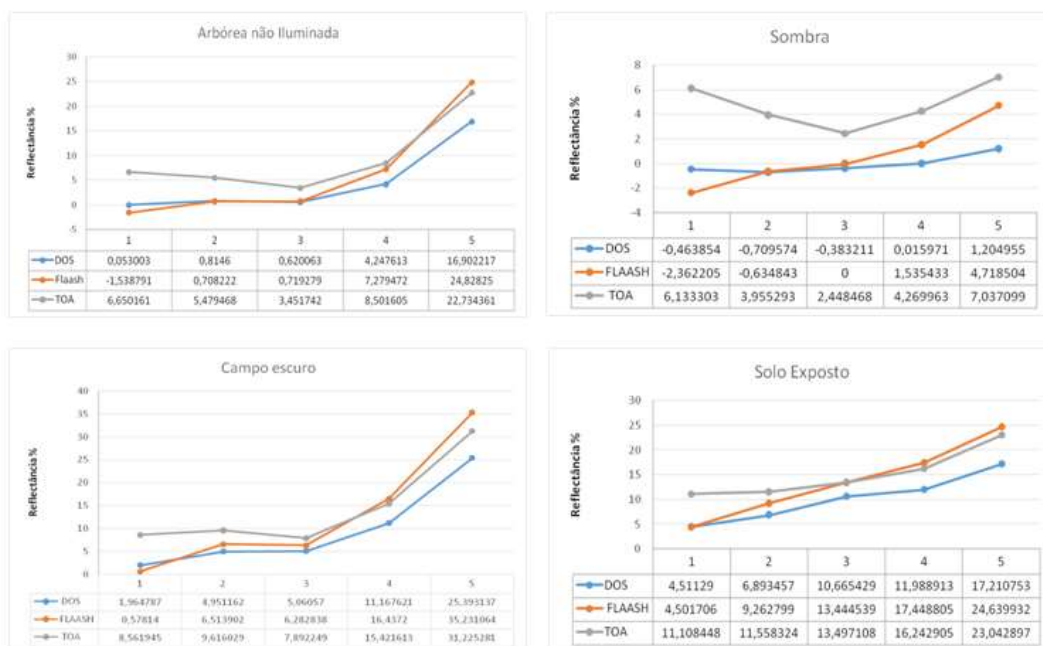


Figura 2– Curvas espectrais das amostras de treinamento das imagens corrigidas.

Ao observar os produtos das classificações verifica-se que visualmente há poucas diferenças. No entanto, a classificação do SVM apresenta menos ruído do que a classificação MAXVER, que apresenta o efeito Salt and Pepper espalhado por toda a imagem.

A sobreposição, feita entre as classificações do MAXVER, mostra que não há diferença de classificação entre as imagens corrigidas pelo DOS e à TOA (Figura 3). No entanto, a sobreposição entre a classificação com imagem TOA e MODTRAN apresenta 18% da área pertencem a classes diferentes (Figura 4).

A sobreposição, feita entre as classificações do SVM, mostra também que não há diferença entre classificação das imagens corrigidas pelo DOS e a TOA, pois apenas 0,04% da área entre as imagens classificadas são diferentes (Figura 5). No entanto, a

sobreposição entre a classificação com imagem TOA e MODTRAN apresenta 9% da área em classes diferentes (Figura 6).

Como foi verificado que não há diferença nos resultados das imagens corrigidas do TOA e DOS classificadas pelo MAXVER e SVM, no entanto, ha diferença é detectada entre as classificações do TOA e MODTRAN, as imagens classificadas por ambos classificadores e corrigidas por este último algoritmo pelo modelo de transferência foram comparadas. Verificou-se, assim, que há uma diferença entre as classificações de 22% da área (Figura 7).




Figura 3- Sobreposição entre a classificação das imagens TOA e DOS pelo MAXVER.

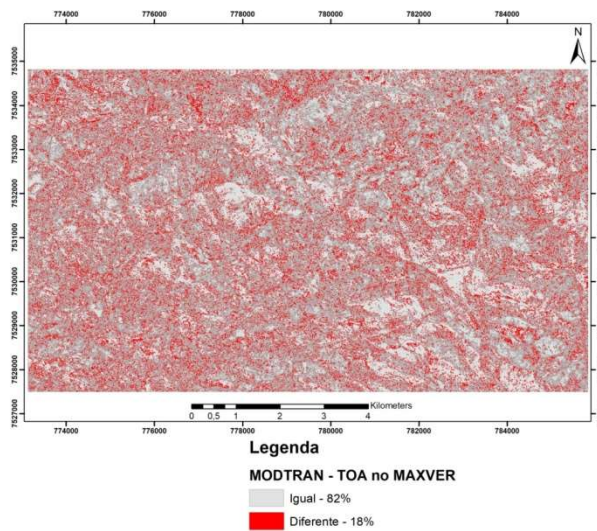


Figura 4 - Sobreposição entre a classificação das imagens TOA e MODTRAN pelo MAXVER.

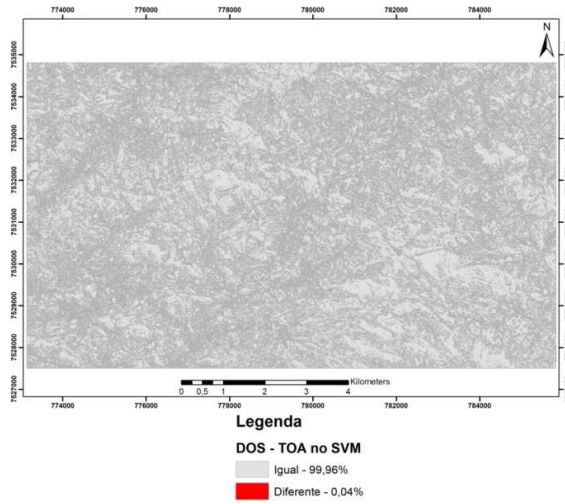


Figura 5- Sobreposição entre a classificação das imagens TOA e DOS pelo SVM.

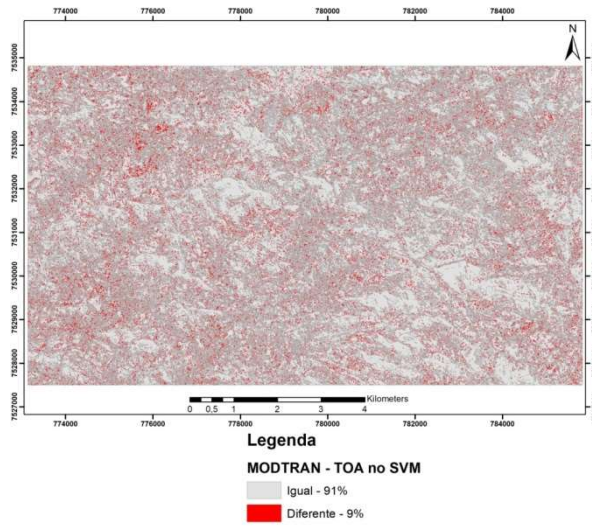


Figura 6 - Sobreposição entre a classificação das imagens TOA e MODTRAN pelo SVM.




Figura 5 - Sobreposição entre a classificação MAXVER e SVM das imagens MODTRAN.

Quando comparamos a área entre eles percebemos que as diferenças continuam, mas em valores diferentes em cada classe. Observa-se que nem todas as classes apresentam disparidade de área com diferenças iguais. Atenta-se que as classes com áreas mais parecidas figuram com maior mistura na sobreposição (Tabela 1).

Tabela 1: Quadro comparativo entre os valores obtidos utilizando-se os classificadores MAXVER e SVM.

Classe	Classe	Área MAXVER (ha)	Área MAXVER (%)	Área SVM (ha)	área SVM(%)
1	Afloramento	459	4,9	534	5,7
2	Arbustiva	1695	18,3	859	9,2
3	Arbórea Iluminada	1.828	19,7	2.835	30,5
4	Arbórea não iluminada	2.494	26,9	2.733	29,4
5	Campo claro	103	1,1	111	1,2
6	Campo escuro	761	8,2	65	7,1
7	Eucalipto novo	212	2,3	103	1,1
8	Eucalipto velho	258	2,8	103	1,1
9	Herbácea clara	251	2,7	292	3,1
10	Herbácea escura	1.024	11,0	924	9,9
11	Solo exposto	143	1,5	86	0,9
12	Sombra	556	0,6	46	0,5

CONCLUSÕES

A análise das classes de cobertura da terra aponta que a correção MODTRAN corrige as curvas espectrais de acordo com o esperado pela interação entre radiação eletromagnética e atmosfera, ou seja, a reflectância aumenta na faixa do visível, efeito da absorção atmosférica, e diminui a partir do infravermelho de borda.

Quando comparamos os classificadores e equiparando as classificações, constatamos que se obteve um grau de diferença nas relações de pixels classificados muito alto, mostrando que o tipo de classificador tem extrema importância quando o objetivo é a geração de uma classificação. Assim, percebemos que o SVM é o classificador que apresentou mais clareza nas definições das classes e o MAXVER apresentou um maior número de misturas de pixels classificados com o efeito Salt and Pepper.

Observou-se que, em relação a classificação do TOA, a correção pelo DOS não apresentou mudança significativa na imagem classificada. No entanto, em relação à correção MODTRAN, verificou-se que as imagens classificadas, por ambos algoritmos, apresentam diferença com a classificação da imagem TOA, na ordem de 10% da área em relação ao MAXVER e 20% em relação ao SVM.

Na comparação entre os classificadores, MAXVER e SVM, constata-se diferença entre os resultados na ordem de 20% da área de estudo nas imagens corrigidas pelo MODTRAN. Esta diferença pode estar relacionada ao efeito ruidoso derivado do classificador pixel a pixel. No entanto, este efeito é minimizado nas classificações SVM. Também se verifica que a maior diferença de área ocorre nas classes que apresentam curva espectral semelhante.

Quando analisamos os quadros de áreas, percebemos que os valores das curvas espectrais são próximos em classes com áreas próximas, como podemos perceber ao compararmos Arbustiva com Arbórea Iluminada. Uma das hipóteses que levantamos é de que algoritmos de classificação diferentes fazem com que nas classes semelhantes a decisão seja diferente, mas só poderemos concluir realizando a verdade de campo.

Dada a importância do assunto, foi identificada escassez de trabalhos que discutam o tema do. Assim, espera-se que tal estudo sirva de referência para trabalhos futuros e, ainda, seja utilizado na discussão acerca da necessidade de correção atmosférica na classificação de imagens.

REFERÊNCIAS BIBLIOGRÁFICAS

BURGES, C. J. C. A tutorial on support vector machines for pattern recognition. Knowledge. Discovery and Data Mining, 2(2):1-43, 1998.

CHAVEZ, J. P.S. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. Remote Sensing of Environment, v.24, p. 459-479, 1988.

COSTA, T. C. C.; JÚNIOR, P. M.; BRITES, R. S.; SOARES, V. P. O Classificador NPVIC Comparado ao Não Paramétrico de Skidmore/Turner e ao Classificador Maxver. In: Anais IX Simpósio Brasileiro de Sensoriamento Remoto, Santos, Brasil, 1998, p. 945-958.

EASTMAN, J. R. Idrisi Andes: Guide to GIS and Image Processing. Worcester, MA: Clark University, 2006. 327 p.

FITZ, P. R. Geoprocessamento sem complicação. São Paulo: Oficina de Textos, 2008. 160p.

GONÇALVES, J. T.; FRANCISCO, C. N. Comparação entre os métodos de correção atmosférica MODTRAN e DOS em imagens do RapidEye. Anais do XVIII Simpósio Brasileiro de Sensoriamento Remoto -sbsr, Santos - Sp, v. 21, n. 0, p.2307-2314, maio 2017.

JENSEN, J.R. Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres. São José dos Campos: Parêntese, 2009. 604 p. LATORRE, M.; et al. Correção Atmosférica: Conceitos e Fundamentos. Espaço & Geografia, v. 5, p. 153- 178, 2002.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. Sensoriamento Remoto da Vegetação. 2. ed. São Paulo: Oficina de Textos, 2012. 160 p.

SILVA, I. P. G. C. Noções de Inferência Estatística. Salvador. Apostila do Curso de Administração - Faculdade Hélio Rocha. Disponível em: <http://www.heliorocha.com.br/graduacao/adm/download/EST_II/NocoosInf_Est_II_Parte1.pdf>. Acessado em: 01/08/2012.

SONG, C.; WOODCOCK, C.E.; SETO, K.C.; PAX-LENNEY, M.; MACOMBER, S.A. Classification and change detection using Landsat TM data: when and how to correct atmospheric effects? Remote Sensing of Environment, v. 75, p. 230-244, 2001.

VAPNIK, V. N. The nature of Statistical learning theory. Springer-Verlag, New York, 1995.