

## Metodologia para classificação subpixel de imagens MODIS com base em classificação de imagem de maior resolução

Noeli A. P. Moreira<sup>1</sup>, Thales S. Körting<sup>1</sup>, Luciano V. Dutra<sup>1</sup>, Emiliano Castejon<sup>1</sup>, Egidio Arai<sup>2</sup>

<sup>1</sup>Divisão de Processamento de Imagens – Instituto Nacional de Pesquisas Espaciais  
Caixa Postal 12227-010 – São José dos Campos – SP – Brazil

<sup>2</sup>Divisão de Sensoriamento Remoto – Instituto Nacional de Pesquisas Espaciais  
Caixa Postal 12227-010 – São José dos Campos – SP – Brazil

noeli.geo@gmail.com, thales.korting@inpe.br, dutra@dpi.inpe.br,  
emiliano.castejon@inpe.br, egidio@dsr.inpe.br

**Abstract.** *This paper presents preliminary results of a subpixel classification methodology, applied to a MODIS scene, for land cover classification of extended areas. Class proportions are calculated inside cells determined by the MODIS pixel grid placed over a much higher resolution image, which is initially classified with the desired number of land classes. Clustering is applied to the class proportions synthetic image to estimate typical proportions of classes. The typical proportions map areas are used as region of interest (ROI's) over the MODIS image and then classified by minimum euclidean distance and maximum likelihood rule. The resulting large area map of typical proportions showed consistent result and good agreement with test areas.*

**Resumo.** *Este trabalho apresenta resultados preliminares de uma metodologia de classificação subpixel, aplicada a uma cena MODIS, para classificação de cobertura vegetal em áreas estendidas. As proporções de classe são calculadas dentro de células determinadas pela grade de pixels do MODIS, colocada sobre uma imagem de resolução muito maior, que é inicialmente classificada com classes básicas de interesse. Clustering é aplicado à imagem sintética de proporções para estimar algumas proporções típicas. O resultante mapa de proporções típicas é, então, usado como um conjunto de regiões de interesse (ROI) sobre a imagem MODIS que é classificada pelas regras de mínima distância euclidiana e máxima verossimilhança. O mapa de grandes áreas obtido com essas proporções típicas mostrou consistência e boa concordância com áreas de teste.*

### 1. Introdução

Mudanças da cobertura do solo vêm ocorrendo de forma cada vez mais acelerada e nem sempre de forma planejada. Monitorar tais alterações, em nível regional e em grandes áreas, vem sendo um desafio na área do sensoriamento remoto.

O sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*), a bordo das plataformas TERRA e AQUA, faz parte do Sistema de Observação Terrestre (EOS) da NASA e tem como finalidade contribuir com monitoramento global [Justice et al. 2002]. Os produtos são disponibilizados gratuitamente, com alta resolução temporal

(revisita diária), entretanto a sua moderada resolução espacial faz com que a mistura espectral de diferentes classes de cobertura dentro de um mesmo pixel dificulte o monitoramento. Técnicas de classificações de subpixel são consideradas apropriadas para estimar proporções de área de cada classe de cobertura [Foody e Cox 1994; Zhang e Foody 1998] e tem sido cada vez mais aplicadas em dados de moderada resolução espacial por representar com maior precisão a mistura dentro de um pixel [Lu, Moran e Hetrick 2011]. Neste sentido, o objetivo desta pesquisa vem sendo desenvolver processos metodológicos para mapeamento subpixel, construindo-se uma imagem com proporções de classes de cobertura em quadrantes relativos à imagem de resolução moderada. O estudo pretende possibilitar a construção de mapas de cobertura com menores índices de incertezas resultantes da mistura espectral e contribuir diretamente, por exemplo, com a criação de mapas com maior detalhamento e frequência temporal para grandes regiões visando auxiliar no monitoramento ambiental.

## 2. Materiais e Métodos

### 2.1 Área de Estudo

A área de estudo está localizada entre os municípios de Belterra e Santarém, estado do Pará. Envolve parte da Unidade de Conservação Federal Floresta Nacional do Tapajós, nas proximidades do rio Tapajós, como pode ser visualizada na Figura 1.

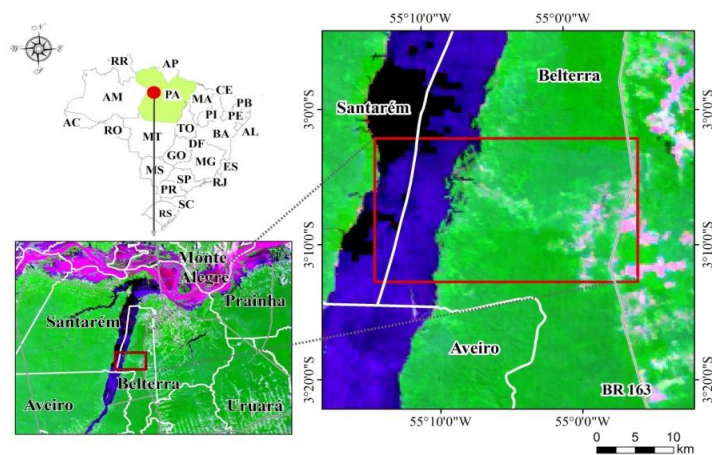


Figura 1. Mapa de localização da área de estudo.

### 2.2 Base de dados

Foi adquirida para a data 01 de agosto de 2012, uma imagem do sensor ResourceSat-1/LISS, com 23m de resolução espacial no catálogo de imagens gratuito CDRS do INPE. Foi adquirida também, uma imagem para a data 04 de agosto de 2012, do sensor MODIS (MOD09GQ e MOD09GA), com 231m e 462m de resolução espacial respectivamente, ambas do site *NASA's Land Processes Distributed*, referenciadas pelo tile h12v09. O produto MOD09GQ disponibiliza as bandas Red e Nir, enquanto o produto MOD09GA as bandas Blue e Mir. Estas duas bandas foram reamostradas para 231m de resolução espacial, a mesma das bandas Red e Nir.

### **2.3 Classificação supervisionada sobre imagem de maior resolução**

A primeira etapa envolveu o ajuste posicional da imagem ResourceSat-1/LISS sobre a imagem MODIS e sua posterior classificação supervisionada, indicada no fluxograma metodológico na Figura 2. Neste processo foi utilizado o algoritmo de máxima verossimilhança no software ENVI 4.7. Na classificação foram definidas 4 classes de cobertura: floresta, água, solo exposto e pasto e/ou agricultura. As regiões de treinamento foram delimitadas com base em visitas realizadas em campo.

## **3. Metodologia**

### **3.1 Aplicação do Programa Subpixel para construção da imagem de proporções**

Para a construção da imagem de proporções foi elaborado o programa Subpixel, construído na biblioteca TerraLib [Câmara 2000]. Este programa constrói uma grade ao utilizar os parâmetros de resolução espacial e posicional referentes à imagem de menor resolução, neste caso MODIS. Após a construção da grade, é feita a sobreposição da classificação supervisionada feita sobre a imagem de maior resolução, neste caso ResourceSat-1/LISS, para inserir tais proporções de cobertura dentro de cada quadrante de 231m. Este programa permitiu intersectar as duas imagens e criar uma imagem sintética contendo resolução espacial da imagem de menor resolução e porcentagens de cobertura do mapa classificado descrito no tópico 2.3. Esta etapa metodológica está ilustrada na Figura 2.

### **3.2 Classificação não supervisionada sobre imagem de proporções**

Estudos iniciais desta pesquisa demonstraram que a análise direta entre proporções de cobertura e valores espectrais da imagem MODIS, relacionadas por modelo de regressão linear múltipla, não são eficientes. Sendo assim, buscou-se aplicar métodos de agrupamento de classes típicas de proporções para relacionar novamente aos valores espectrais. A maioria dos softwares realizam a classificação não-supervisionada baseada em métodos de agrupamentos, como o K-médias e o Isodata - *Iterative Self Organizing Data Analysis* [Ball and Hall 1967]. Foram realizadas 9 testes envolvendo classificações não supervisionadas, sobre a mesma imagem de proporções, utilizando os dois algoritmos, no software ENVI 4.7. As 9 classificações foram executadas com parâmetros de entrada diferenciados (número mínimo e máximo de clusters e número de iterações distintos) para testar qual dos mapas resultantes representava mais corretamente a área de estudo. Outros testes aumentando tais parâmetros foram aplicados, porém a detecção de clusters típicos foi estabilizada em 11 agrupamentos. Os testes de 1 a 3 foram processados utilizando o algoritmo K-médias e de 4 a 9, utilizou-se o Isodata. Dentre os nove mapas classificados foi escolhido o mapa resultante do teste nº 9 (executado pelo algoritmo Isodata com parâmetros de entrada: 10 a 20 clusters e 10 iterações), por apresentar melhores resultados comparados à realidade da área de estudo. Além disso, separou proporções acima de 90% para as 4 classes de cobertura e englobou diferentes combinações de proporções. Portanto criou o maior nº de clusters (11 no total) caracterizando melhor a heterogeneidade do local. Desta forma, se optou em escolher o mapa resultante do método nº 9, para definição de atributos estatísticos explicados na seção 3.3.

### 3.3 Definições de parâmetros estatísticos como treinamento para classificador

O mapa contendo 11 clusters típicos de proporções foi sobreposto à imagem MODIS para possibilitar o cálculo dos parâmetros média e matriz de covariância para cada um dos clusters e para cada banda da imagem (Red, Nir, Blue e Mir). A identificação destes parâmetros foram necessários para serem utilizados como indicadores de treinamento para a reclassificação supervisionada de uma região de maior abrangência.

### 3.4 Reclassificação supervisionada sobre imagem MODIS

Foram construídos dois programas para classificação supervisionada, um utilizando o algoritmo mínima Distância Euclidiana e outro Máxima Verossimilhança, ambos na biblioteca TerraLib. A construção destes programas permitiu realizar o processo de reclassificação supervisionada sobre a imagem MODIS utilizando como treinamento os parâmetros estatísticos definidos anteriormente para cada um dos 11 clusters. Neste processo foram gerados dois mapas reclassificados sobre uma área de maior abrangência, contendo em cada um deles 11 classes de cobertura. Os mapas reclassificados podem visualizados na Figura 4.

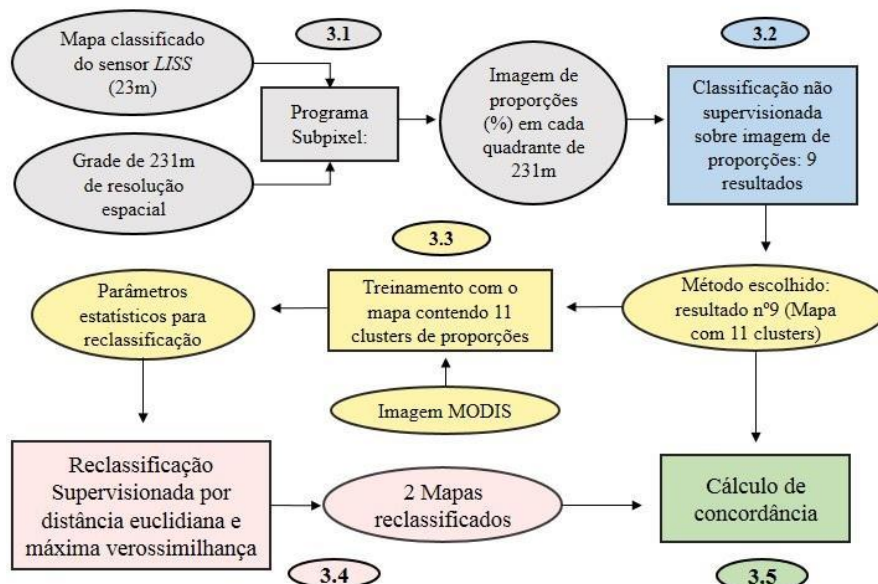


Figura 2. Fluxograma metodológico com as subseções assinaladas.

### 3.5 Cálculo de Concordância

Para estimar a concordância dos resultados foi utilizado como referência o mapa resultante da classificação não supervisionada para comparação dos mapas reclassificados. Para este processo foi utilizado álgebra de mapas, para realizar a subtração numérica entre cada pixel (valores de 1 a 11) entre os mapas. Este processo permitiu a contagem do total de pixels com valor zero, que representa que os dois pixels eram de clusters do mesmo número (iguais). Os processos metodológicos estão sintetizados pelo fluxograma de execução na Figura 2.

## 4. Resultados e discussão

#### 4.1 Mapa resultante da classificação não supervisionada

O mapa resultante do teste nº 9 identificou 11 clusters típicos presentes sobre a imagem de proporções e podem ser identificados pela Figura 3. Destes 11 clusters, 4 tiveram proporções acima de 90% (clusters nº 5, 7, 8 e 10) que compreendem respectivamente as classes floresta, água, solo exposto e pasto e/ou agricultura. Além destas 4 classes, foram gerados 7 clusters típicos de proporções (nº 4, 9, 6, 3, 11, 1 e 2) correspondendo à misturas de mais de uma classe em pixels de 231m. A ordem numérica dos 11 clusters foram classificados em ordem decrescente para classe Floresta.

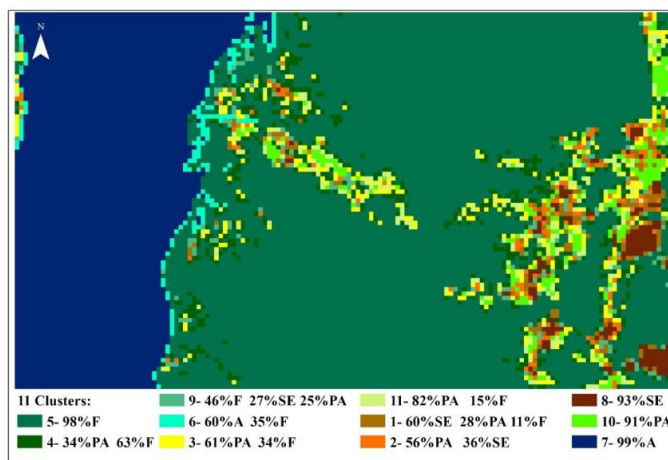


Figura 3. Mapa resultantes do método 9 contendo 11 clusters típicos, sendo 4 clusters de uma única classe e 7 clusters com proporções de mais de uma classe em pixels de 231m. Legenda: A: Água, F: Floresta, SE: Solo exposto, PA: Pasto e/ou Agricultura.

#### 4.2 Reclassificação da imagem MODIS

Após a geração de parâmetros estatísticos resultantes da sobreposição do mapa de classificação não supervisionada do método 9 sobre a imagem MODIS, foi possível reclassificar a imagem identificando as 11 classes de proporções. Os mapas reclassificados e de área com maior abrangência podem ser observados na Figura 4.




Figura 4. Mapas reclassificados em área de maior abrangência utilizando classificador por distância euclidiana (esquerda) e máxima verossimilhança (direita). Para interpretação das classes de proporções utilizar legenda da Figura 3.

No processo de análise da confiabilidade dos resultados foi calculada a porcentagem relativa de concordância entre o mapa resultante da classificação não supervisionada e os dois mapas reclassificados. Foi estimado um total de 73 % de concordância para o mapa da classificação por distância euclidiana e 72 % para o da classificação por máxima verossimilhança. Os mapas utilizados para cálculo de concordância podem ser visualizados pelas Figuras 3 e 4.

## 5. Conclusões

O modelo de classificação proposto nesta pesquisa possibilitou reclassificar a área de estudo com proporções subpixel com mapas contendo 4 classes de pixels puros e 7 classes de proporções de cobertura em um mesmo pixel. Os resultados de concordância comparativa entre os mapas demonstram bom desempenho da metodologia, porém, é preciso analisar as regiões de concordância e não concordância.

A metodologia desenvolvida permite classificar grandes áreas, com pixels em resolução moderada e com maior resolução temporal, em porcentagens de ocupação de classes, no lugar do método padrão que classifica apenas uma classe por pixel. A metodologia ainda continuará a ser avaliada e depois usada para detecção de mudanças em pequenos intervalos de tempo.

## Referências

- Ball, G. and Hall, D. (1967) “A Clustering Technique for Summarizing Multivariate Data”, *Behavior Science*, v. 12, p. 153-155.
- Câmara, G., De Souza, R.C.M., Pedrosa, B. M., Vinhas, L., Monteiro, A.M.V., Paiva, J.A., De Carvalho, M.T. and Gattass, M. (2000) Terralib: Technology in Support of GIS Innovation. In.: Proceedings of the II Brazilian Symposium on GeoInformatics, GeoInfo, São Paulo, Brazil.
- Foody G.M., Cox D.P. (1994) - Sub-pixel Land Cover Composition Estimation Using a Linear Mixture Model and Fuzzy Membership Functions. *International Journal of Remote Sensing*, 15: 619-631. doi: <http://dx.doi.org/10.1080/01431169408954100>.
- Justice, C. O.; Townshend, J.R.G.; Vermote, E.F., Masuoka, E., Wolfe, R.E., Saleous, N., Roy, D.P., Morisette, J.T. (2002) “An overview of MODIS Land data processing and product status. *Remote Sensing of Environment*”, v. 83, n.1-2, Nov. p 3 –15.
- Lu, D., Moran, E. and Hetrick, S. (2011) “Detection of Impervious Surface Change with Multitemporal Landsat Images in an Urban-Rural Frontier.” *ISPRS Journal of Photogrammetry and Remote Sensing : Official Publication of the International Society for Photogrammetry and Remote Sensing (ISPRS)* 66 (3): 298–306. doi:10.1016/j.isprsjprs.2010.10.010.
- Zhang J., Foody G.M. (1998) - A Fuzzy Classification of Sub-urban Land Cover from Remotely Sensed Imagery. *International Journal of Remote Sensing*, 19: 2721-2738. doi: <http://dx.doi.org/10.1080/014311698214479>.