

# ESTRATÉGIA PARA CLASSIFICAÇÃO SUPERVISIONADA DE SÉRIES TEMPORAIS DE IMAGENS DE SENSORIAMENTO REMOTO QUANDO NÃO SE DISPÕE DE TREINAMENTO PARA TODAS AS DATAS

Noeli A. P. Moreira<sup>1</sup>, Thales S. Körting<sup>2</sup>, Luciano V. Dutra<sup>3</sup>, Emiliano Castejon<sup>4</sup>, Egídio Arai<sup>5</sup>

Instituto Nacional de Pesquisas Espaciais, noeli.geo@gmail.com; thales.korting@inpe.br, dutra@dpi.inpe.br, emiliano.castejon@inpe.br, egidio@dsr.inpe.br

## RESUMO

Este artigo apresenta uma metodologia para classificações subpixel em imagens de séries temporais MODIS usando apenas um ano base como referência. O ano de 2012 foi utilizado para determinar as regras de classificação e também utilizado como base para calibração relativa dos anos restantes, neste caso, de 2013 a 2017. O treinamento foi realizado utilizando uma imagem sintética com 11 proporções típicas de 4 classes de cobertura, de um mapeamento de resolução espacial dez vezes mais alto. Essas proporções típicas foram estimadas a partir de um procedimento de agrupamento ISODATA executado em uma estimativa de quadrantes de classe contínua em uma grade de 231m registrada para a grade de pixels MODIS. Uma calibração relativa das imagens MODIS remanescentes foi executada para permitir que as regras de classificação de 2012 fossem aplicadas a outras datas sem a necessidade de executar o treinamento. A avaliação de tal procedimento é desafiadora, mas a inspeção visual com vários casos em particular mostrou a validade e a solidez do método. A pesquisa continuará a testar a abordagem desenvolvida e a desenvolver novos métodos para validar o produto.

**Palavras-chave** — MODIS, sub-pixel, classificação supervisionada, séries temporais.

## ABSTRACT

This article presents a methodology for sub-pixel classifications in MODIS time series imagery using only one base year as reference. The year 2012 was used to determine the classification rules and also used as a base for relative calibration of the remaining years, in this case 2013 to 2017. The training was performed using an synthetic image with 11 typical proportions of 4 classes of coverage, coming from a ten times higher spatial resolution mapping. This typical proportions were estimated from an ISODATA clustering procedure executed in a continuous class quadrants estimates on a grid of 231m registered to the MODIS pixel grid. A relative calibration of the remaining MODIS imagery was executed to allow the 2012 classification rules to be

applied to other dates without necessity of executing training. Evaluation of such procedure is challenging, but visual inspection with several cases in particular showed the validity and soundness of the method. The research will continue to test the developed approach and devise new methods to validate the product.

**Key words** — MODIS, sub-pixel, supervised classification, time series.

## 1. INTRODUÇÃO

As grandes alterações que a Amazônia brasileira vem sofrendo relacionadas às atividades antrópicas nem sempre são planejadas e são necessárias técnicas que envolvem a identificação e o monitoramento destas mudanças [1].

Imagens de sensoriamento remoto, em função de sua frequência de captura, são imprescindíveis ao monitoramento sistemático e eficiente da cobertura do solo. Neste cenário, 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 e de grandes áreas, como Amazônia [2]. 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. Imagens de resolução padrão detectam melhor os alvos no solo comparadas às de moderada resolução, porém sua resolução temporal é menos frequente.


Visando integrar a vantagem de melhor detecção de alvos de imagens padrão e a alta resolução temporal de imagens de moderada resolução, o presente trabalho tem como objetivo explorar uma metodologia de classificação sub-pixel de séries temporais de imagens do sensor MODIS, sem dispor de amostras de treinamento para todos os anos, por meio da determinação de regras de classificação.

Pretende-se com o aprimoramento desta metodologia aumentar a elaboração de mapas de cobertura da terra com maior frequência temporal. Além disso, envolver o mapeamento sub-pixel poderá diminuir incertezas em misturas de alvos de imagens de moderada resolução espacial.

## 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 da área de estudo indicada pelo retângulo de cor amarela para área de treinamento do ano de referência e cor vermelha para área de classificação da série temporal.

### 2.2 Materiais

Foram adquiridas imagens para cada um dos anos de 2012 a 2017 do sensor MODIS (MOD09GQ e MOD09GA). As imagens são referenciadas pelo tile h12v09 e baixadas gratuitamente do site NASA's Land Processes Distributed. O produto MOD09GQ disponibiliza as bandas Red e Nir com 231m, enquanto o MOD09GA as bandas Blue e Mir com 462m. Estas duas bandas foram reamostradas para 231m de resolução espacial, a mesma das bandas Red e Nir para todos os anos da série temporal.

Para utilização da imagem base de referência do sensor MODIS, foi adquirida uma imagem para a data de 04 de agosto de 2012. Para a data 01 de agosto de 2012, foi adquirida uma imagem do sensor ResourceSat-1/LISS, com 23m de resolução espacial no catálogo de imagens gratuito CDRS do INPE. Esta imagem foi ajustada posicionalmente sobre a imagem base MODIS por meio do registro fino. Isso foi necessário para que diminuíssem erros posicionais resultantes dos planos multi-escala.

Foram utilizados 3 programas construídos na biblioteca TerraLib [3]: *spat\_classproportions*, *spat\_rastercalibration* e *ed\_classifier*. O primeiro programa é utilizado para cálculo de proporções de sub-pixel. Para isso o 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 desta grade é feita a sobreposição da classificação resultante da imagem de maior resolução para inserir proporções em porcentagem 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 de melhor resolução. O segundo programa realiza o processo de calibração relativa em um conjunto de imagens de séries temporais. Ele permite realizar uma calibração ao comparar amostras puras das classes de cobertura indicadas como referências para um ano base com as amostras puras indicadas para o processo de calibração (ajuste). O terceiro programa realiza classificações supervisionadas utilizando algoritmo de mínima distância euclidiana. A vantagem deste programa é que ele utiliza como base apenas um ano como treinamento para os demais anos a serem classificados. Além dos 3 programas da plataforma TerraLib, o programa ENVI 4.7 foi utilizado para os processos de classificações não supervisionadas.

### 2.3 Métodos

A metodologia deste estudo envolve 4 etapas principais: A construção de uma imagem de proporções, aquisição de parâmetros estatísticos para o modelo de classificação, calibração relativa e classificações de séries temporais MODIS. A Figura 3 contém as 4 etapas assinaladas.

Na etapa 1 foi realizada a construção de uma imagem sintética contendo proporções (em porcentagem) de classes de cobertura em quadrantes de 231m de resolução espacial, a mesma da imagem MODIS. As proporções utilizadas neste processo foram provenientes de um mapa classificado da imagem ResourceSat-1/LISS, contendo 4 classes de cobertura: floresta, água, solo exposto e pasto e/ou agricultura. A classificação foi obtida pela aplicação do algoritmo máxima verossimilhança, no software ENVI 4.7, e as regiões de treinamento foram delimitadas com base em visitas realizadas em campo. A Figura 1 indica a área classificada pelo retângulo cor amarela para treinamento.

A etapa 2 envolveu a determinação das regras de classificação por meio da aquisição de parâmetros estatísticos para o modelo de classificação. Para a construção deste modelo foi necessário utilizar inicialmente algoritmos de clusterização, sobre a imagem de proporções, pois relacionar tais proporções diretamente com os canais espectrais MODIS não foi estatisticamente possível. Portanto, foi preciso agrupar as proporções típicas em  $n$  clusters, para posteriormente relacionar com os canais espectrais da imagem MODIS. Neste processo de agrupamento foram utilizados os algoritmos de classificações não supervisionadas, K-médias e o Isodata - *Iterative Self Organizing Data Analysis* [4]. Testes envolvendo variações dos parâmetros de entrada (número mínimo e máximo de clusters e número de iterações) foram introduzidos para obtenção de diferentes resultados sobre a mesma imagem de proporções. Dentre nove métodos testados, foi escolhido como melhor resultado de agrupamento, o método 9, resultante da aplicação do algoritmo Isodata, devido ao fato de separar o maior número de clusters, 11 no total, e também

por separar grupos com proporções acima de 90% para as 4 classes de cobertura. A classificação resultante deste processo pode ser visualizada pela Figura 2.




Figura 2. Mapa contendo 11 classes de típicos de proporções para determinação das regras de classificação.

O mapa contendo 11 clusters típicos foi sobreposto sobre a imagem base MODIS do ano de referência (2012), para possibilitar o cálculo dos parâmetros média e matriz de covariância para cada um dos 11 clusters e para cada banda da imagem (Red, Nir, Blue e Mir). A identificação destes parâmetros para o ano de 2012 foram necessários para serem utilizados como regras de treinamento do modelo para a classificação supervisionada da série temporal de 2013 a 2017.

A etapa 3 compreendeu o processo de calibração relativa de imagens MODIS, dos anos de 2013 a 2017, tendo como referência o ano de 2012. Esta correção foi feita por uma tabela (*look up table*) gerada por uma reta obtida por regressão linear simples a partir de pontos de, pelo menos, médias de 3 (três) classes correspondentes em ambas as imagens. Neste processo uma imagem foi mantida como referência para calibrar mais de uma imagem no tempo, banda por banda.

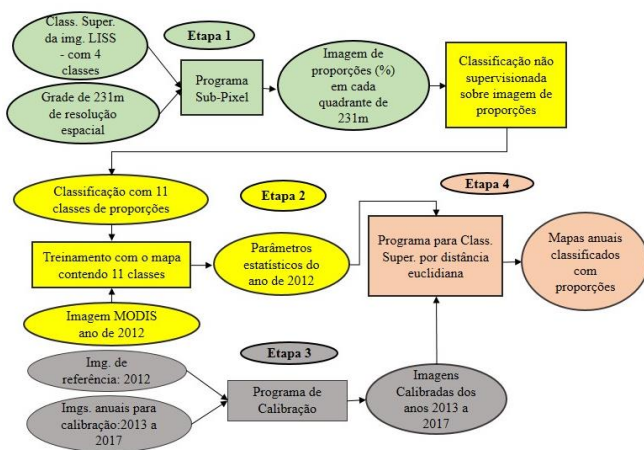


Figura 3. Fluxograma metodológico com as 4 etapas assinaladas.

A classificação da série temporal de imagens MODIS foi realizada pela etapa 4, para os anos de 2012 a 2017. Foi utilizado o classificador supervisionado contendo o algoritmo mínima distância Euclidiana, construído na plataforma TerraLib. Este programa permitiu classificar um conjunto de

imagens anuais utilizando as regras de classificações obtidas para o ano de 2012. A Figura 3 indica as 4 etapas realizadas na metodologia desta pesquisa.

### 3. RESULTADOS E DISCUSSÃO

Os resultados demonstrados na Figura 4 são mapas classificados referente aos anos de 2012 a 2017 utilizando regras de classificação extraídas do ano de 2012. Este ano não passou pelo processo de calibração, pois ela foi utilizada como referência para calibrar as demais imagens.




Figura 4. Série temporal classificada referente aos anos de 2012 a 2017 com 11 classes de proporções.

No processo de classificação da série temporal foi observado que os anos de 2012, 2016 e 2017 obtiveram maiores detecções das diferentes classes de clusters. Já para o ano de 2013 e 2014 houve menor detecção. Isso pode estar relacionado com erros no comportamento espectral para determinadas proporções ao longo da série temporal. É preciso identificar e analisar tal comportamento para determinadas classes e assim aprimorar o processo de calibração para níveis de proporções.

É interessante observar que do ano de 2015 para 2016 houve uma grande mudança da classe 5 para 9, evidenciando processo de degradação na área de estudo. Esta alteração na cobertura foi confirmada pelo boletim do desmatamento da Amazônia Legal - SAD, em que foi constatado um grande incêndio florestal no Pará (7.350 km<sup>2</sup>) entre Dezembro de 2015 a Junho de 2016 [5].

A classe 7, referente ao ano de 2012, foi utilizada como máscara para os demais anos de 2013 a 2017 devido à grande quantidade de pixels com no-data na série temporal. Sendo assim, a classe 7 da classificação do ano de 2012, sem no-data, foi sobreposta às demais classificações.

A mesma metodologia foi testada em imagens não calibradas e os resultados obtiveram menor desempenho comparados aos resultados obtidos de imagens calibradas.

Para análise da confiança do modelo de classificação foi realizado, o processo comparativo entre o mapa de referência (Figura 2), com o mapa classificado referente ao ano de 2012, e foi calculado valores em torno de 73 % de concordância. Para melhoria da confiança deste indicador outros métodos de avaliação deverão ser realizados, como por exemplo, a sobreposição de polígonos de desflorestamento validados pelo Projeto de Monitoramento do Desmatamento na

Amazônia por Satélites – Prodes [6]. Novas perspectivas envolvendo estudos de acurácia dos mapas anuais serão implementados.

A utilização do parâmetro adicional matriz de covariância junto às regras de classificação poderá contribuir com a redução de possíveis erros provenientes do classificador por distância euclidiana. Para isso, um novo programa vem sendo desenvolvido e novos testes serão realizados sobre o mesmo conjunto de imagens. Testes envolvendo outras técnicas de calibração relativa para proporções e normalização de imagens também poderão ser adicionados à metodologia.

A análise das condições climáticas antes à data de aquisição deverão ser analisadas, pois estas devem ser iguais às condições da imagem utilizada como referência. Condições diferenciadas podem resultar em comportamentos espectrais distintos para mesma classe de cobertura. Índices de qualidade e confiança das imagens trabalhadas serão adicionados nas análises.

#### 4. CONCLUSÕES

Este estudo permitiu construir um modelo de classificação de série temporal de imagens de sensoriamento remoto utilizando apenas um ano de treinamento como referência.

Esta metodologia permite classificar grandes áreas identificando classes em proporções sub-pixel em imagens de moderada resolução ao invés do método padrão que classifica apenas uma classe por pixel.

Os resultados mostraram-se condizentes com a realidade de cobertura da área porém, novos estudos para validação dos dados ano-a-ano se faz necessário, mesmo tendo um valor satisfatório de concordância entre o mapa de referência e o classificado.

A metodologia vem sendo desenvolvida e poderá ser aplicada em diferentes conjuntos de imagens de sensoriamento remoto com diferentes resoluções espaciais e temporais.

Perspectivas futuras desta pesquisa envolvem processos para detecção de mudanças de classes de proporções em pequenos intervalos de tempo. Isso permitirá, por exemplo, criar mapas contendo alertas de mudanças de classes de cobertura em menor intervalo de tempo.

#### 5. REFERÊNCIAS

- [1] Latorre, M.; Anderson, L. O., Shimabukuro, Y. E., & de Carvalho Júnior, O. A. Sensor MODIS: Características gerais e aplicações. Capítulo: Aplicações no meio ambiente, Monitoramento da paisagem de unidades de conservação - Maria Silvia Pardi Lacruz & João Roberto dos Santos. Revista Espaço e Geografia, v. 6, n. 1, 2003.
- [2] Justice, C. O.; Townshend, J.R.G.; Vermote, E.F., Masuoka, E., Wolfe, R.E., Saleous, N., Roy, D.P., Morisette, J.T. “An overview of MODIS Land data processing and product status. Remote Sensing of Environment”, v. 83, n.1-2, p 3 –15. 2002.
- [3] 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. Terralib: Technology in Support of GIS Innovation. In: Proceedings of the II Brazilian Symposium on GeoInformatics, GeoInfo, São Paulo, Brazil. 2000.
- [4] Ball, G. and Hall, D. “A Clustering Technique for Summarizing Multivariate Data”, *Behavior Science*, v. 12, p. 153-155. 1967.
- [5] Instituto do homem e Meio Ambiente da Amazônia. Boletim do desmatamento da Amazônia Legal-SAD. 2016. Disponível em: <[http://imazon.org.br/PDFimazon/Portugues/transparencia\\_floresta/IDegradacaoFlorestal\\_jul-15ajun16.pdf](http://imazon.org.br/PDFimazon/Portugues/transparencia_floresta/IDegradacaoFlorestal_jul-15ajun16.pdf)>
- [6] INPE, Prodes. Projeto Prodes Monitoramento da floresta Amazônica Brasileira por satélite. 2014.