

DESENVOLVIMENTO DE MÁSCARA DE FLORESTA UTILIZANDO CLASSIFICAÇÃO ORIENTADA A OBJETO

J. V. Zebende¹, R. Weckmüller¹, R. S. Vicens¹

Universidade Federal Fluminense

Comissão IV - Sensoriamento Remoto, Fotogrametria e Interpretação de Imagens

RESUMO

A utilização conjunta de uma série temporal de imagens, também conhecido como um cubo multitemporal, aumenta consideravelmente a dimensionalidade dos dados de trajetórias evolutivas da cobertura vegetal. Nesse cenário, existem diversas técnicas de análise de séries multitemporais em escala regional da superfície terrestre. Neste trabalho, se configurou, por meio da utilização de imagens do satélite Landsat, associados a índices de vegetação como o NDVI e a Razão Simples referentes ao ano de 1984 e 2016. A classificação posteriormente foi submetida a processos de qualificação do mapeamento apresentando bons resultados

Palavras chave: Sensoriamento Remoto, Vegetação, GEOBIA.

ABSTRACT

The use of a time series of images, also known as a multitemporal cube, greatly increases the dimensionality of the evolutionary trajectory data of the vegetation cover. Concerning this, there are several techniques of analysis of multitemporal series on a regional scale of the land surface. In this paper, was used the *Landsat* satellite images associated with vegetation indexes such as NDVI and Simple Ratio for the years of 1984 and 2016. After this process, the classification was submitted to mapping qualification processes presenting good results.

Keywords: Remote Sensing, Vegetation, GEOBIA.

1- INTRODUÇÃO

A Mata Atlântica é um bioma de ampla diversidade, estendendo-se ao longo de 17 estados brasileiros. Entretanto, devido a uma pressão antrópica, hoje os remanescentes de vegetação nativa estão reduzidos a cerca de 22% de sua cobertura original e encontram-se em diferentes estágios de regeneração. Somente 8,5% estão bem conservados em fragmentos acima de 100 hectares (MMA, 1998). Dada a importância das áreas naturais florestadas para manutenção biológica, ecológica e econômica, já que concentra cerca de 70% da população brasileira (MMA, 2007), é fundamental ter um sistema de monitoramento acerca das áreas deste bioma.

Neste contexto, o sensoriamento remoto com o auxílio de Sistema de Informações Geográficas (SIG) tem sido utilizado para mapeamento de áreas florestadas no Brasil. Uma das formas de monitoramento em escala regional da superfície terrestre se dá por meio da utilização de imagens de satélite como o *Landsat*, e seus sensores TM e OLI, associados a índices de vegetação como o NDVI e a Razão Simples, para a construção de máscaras de

florestas. Estas servem como um recurso acessível e prático para o auxílio de estudos de detecção de mudanças em áreas florestadas.

Todavia, a exatidão de um mapa é de ampla relevância para o levantamento de tais dados, pois, indica a proximidade de uma determinada medida ao seu valor real, logo, a confiabilidade de um mapa está vinculada a sua exatidão. Neste contexto, é necessário realizar algum procedimento estatístico no produto de uma classificação de imagens digitais, para determinar a acurácia ou exatidão desta classificação como o índice *Kappa*, por exemplo (BERNARDES 2006). Weckmüller e Vicens (2016) acrescentam que o índice *kappa* é mais efetivo quando associado à análise da matriz da confusão, pois permite identificar a principal fonte de erros da classificação, se é proveniente do classificador e/ou do pesquisador.

Este trabalho teve como objetivo mapear as áreas remanescentes de florestas ombrófilas do Estado do Rio de Janeiro entre os anos de 1984 e 2016, com o objetivo de construir uma máscara de floresta na escala 1:100.000, utilizando imagens *Landsat* associados ao uso de softwares de sensoriamento remoto e

geoprocessamento. Objetiva-se também aplicar um índice de confiabilidade a este mapeamento, para que assim possa ser desenvolvido um estudo sobre as áreas de crescimento, estagnação e supressão do principal bioma fluminense.

2- MATERIAIS E MÉTODOS

2.1 - Materiais

Para o presente trabalho foram utilizadas imagens *Landsat*, dos sensores TM e OLI. Estas foram adquiridas gratuitamente junto ao portal do USGS (portal: <http://earthexplorer.usgs.gov/>), na forma do produto *Landsat Surface Reflectance Climate Data Record* (CDR), corrigidas quanto à atmosfera. A correção atmosférica é realizada por meio do modelo 6S para gerar imagens em reflectância de superfície. Além disso, as bases vetoriais utilizadas (limites políticos estaduais e municipais) são do IBGE.

Para o desenvolvimento e avaliação das máscaras foram utilizados os softwares *ArcGis* e *eCognition Developer*, que compõe a estrutura do LAGEF/UFF (Laboratório de Geografia Física).

2.2 - Mapeamento da cobertura florestal

Foi realizada uma classificação de floresta para o ano inicial e o ano final de cada cena. A junção destas duas classificações resulta na máscara de floresta, que além de contemplar todas que ficaram invariantes, abrange as florestas que só existiam no ano inicial e foram removidas, e aquelas que surgiram no ano final e possivelmente foram regeneradas.

A classificação foi realizada no software *eCognition*, com ênfase na modelagem *fuzzy* e análise orientada a objetos. De acordo com Cruz *et al.* (2009), a análise *fuzzy* fornece o grau de pertinência de um objeto para todas as classes definidas na legenda, numa lógica de probabilidades, cujos valores podem ser inseridos em novos contextos de classificação. O processo de classificação orientada a objeto utiliza os polígonos gerados na segmentação para definição dos objetos. As características espectrais de forma e relações de vizinhança são as informações utilizadas na descrição destes objetos. A partir destes descritores os objetos podem ser agrupados em categorias com significado ou em classes temáticas (DEFINIENS, 2010). Cruz *et al.* (2007) acrescentam que a classificação orientada a objeto busca simular técnicas de interpretação visual através da modelagem do conhecimento para identificação de feições, baseada na descrição de padrões identificadores, tais como textura, cor, métrica, contexto.

A fase de coleta de amostras é considerada fundamental para o conjunto de respostas espectrais para cada classe. Procurou-se coletar amostras que representassem toda a heterogeneidade da cobertura florestal em cada cena para assim fornecer suporte adequado para a obtenção de um limiar de separação entre floresta e não floresta.

Foram utilizados dois algoritmos para a segmentação. Primeiramente o algoritmo *multiresolution segmentation*, com parâmetro de escala 30 e os critérios 0.1 de forma (ou seja, 0.9 para o fator cor) e 0.5 de compacidade (resultando em 0.5 para suavidade). Esse segmentador multirresolução possui um algoritmo que leva em consideração múltiplas características da imagem (BAATZ e SCHAPE, 1999). O limiar de similaridade e escala é formada pelos parâmetros de cor e forma, onde a cor é formada pela soma ponderada dos valores dos desvios padrões de cada objeto, e a forma é a união dos parâmetros de compacidade e suavidade. A suavidade procura separar objetos que possuem as bordas lineares e bem definidas, enquanto a compacidade extrai objetos compactos, mas que se distinguem de outros por um pequeno contraste (ARAÚJO, 2006; PRADO *et al.*, 2010). Por fim, foi utilizado o algoritmo *spectral difference segmentation* com o valor espectral máximo de diferença igual a 120, ou seja, segmentos produzidos pelo algoritmo anterior com valores inferiores a 120 são unidos em um único segmento.

Para definir um limiar que separasse a cobertura florestal do resto das classes foram construídos dois índices de vegetação, o NDVI (Índice de Vegetação por Diferença Normalizada, traduzido) e a Razão Simples (Equações 1 e 2, respectivamente).

$$NDVI = \rho_{NIR} - \rho_{red} / \rho_{NIR} + \rho_{red} \quad (1)$$

$$Razão\ Simples = \rho_{NIR} / \rho_{red} \quad (2)$$

Onde: ρ_{NIR} , ρ_{red} = reflectância de superfície nas regiões espectrais do infravermelho próximo (banda 4) e vermelho (banda 3), respectivamente.

O modelo *fuzzy* escolhido propõe um intervalo de probabilidades entre dois valores, onde o primeiro valor corresponde a 0% e o segundo a 100% de chances de ser a classe escolhida (Tabela 1). Como eram apenas duas, a classe floresta foi modelada, enquanto a classe não floresta foi utilizada a função *not*, ou seja, todos os objetos que não foram enquadrados em nenhum modelo. Por fim uma edição manual foi realizada, com o objetivo de corrigir os erros da classificação semiautomática.

TABELA 1 – MODELO UTILIZADO NA CLASSIFICAÇÃO DA CLASSE FLORESTA, COM SEU LIMIAR DE SEPARAÇÃO DA CLASSE NÃO FLORESTA

Descritores classe Floresta	Limiar (intervalo)	Modelo fuzzy
NDVI	Entres 0.62 e 0.82	
VI	Entre 5 e 9	

2.3 - Validação dos mapeamentos

Tema recorrente sobre detecção de mudanças, a avaliação da precisão da técnica é fundamental. Muitas são as possibilidades de avaliação. Neste trabalho optou-se por uma das mais comuns e efetivas, muito utilizadas na literatura: o índice *kappa*, associado à análise da matriz de confusão. Considera-se que a análise da matriz de confusão é tão importante quanto o índice *kappa*, pois permite identificar a principal fonte de erros da classificação, se é proveniente do algoritmo e/ou do pesquisador.

A diagonal principal da matriz de confusão é ocupada pelo número de pixels corretamente classificada para cada classe da legenda, já os elementos fora da diagonal principal correspondem a erros de classificação. Os elementos dentro da mesma linha pertencem a uma determinada classe, mas não foram classificados corretamente, chamado de erro de omissão. Os elementos fora da diagonal principal pertencentes a uma mesma coluna representam os pixels da amostra que, foram classificados dentro de uma determinada classe, mas realmente pertencem a outra, chamado de erro de comissão.

A seleção dos pontos amostrais para avaliação foi aleatória. No caso da análise de diferentes métodos numa mesma área de estudo, os pontos devem ser diferentes, evitando um efeito conhecido como pontos treinados, onde a localização dos mesmos pode

superestimar os resultados. Além disso, Congalton (1991) destaca que um número representativo de amostras coletadas para uma avaliação seria de 50, número este coletado para este trabalho, o que segundo o autor garante a relevância estatística dos dados.

2.4 Construção da máscara de floresta

A construção da máscara florestal foi finalizada em ambiente SIG. O mapeamento de cada data (1984 e 2016) foi submetido a filtros de generalização, de modo a garantir uma melhor representação dos objetos em um mapa temático, eliminando ruídos, suavizando contornos e garantindo a determinação do melhor detalhe para a escala, conforme recomendado por Cruz *et al.* (2009). No software *ArcGis* foi aplicado o filtro *majority* (3x3 pixels) e *eliminate* (5 hectares), para atender uma escala 1:100.000, de acordo com o conceito de área mínima mapeável.

A junção destas duas classificações foi realizada no *ArcGis* através da ferramenta *union* e resulta na máscara de floresta do estado do Rio de Janeiro. Esta, além de contemplar todas as coberturas florestais que ficaram invariantes, também abrange as que só existiam no ano inicial (1984) e foram removidas, e aquelas que surgiram no ano final (2016) e possivelmente foram regeneradas. A Figura 1 resume todas as etapas metodológicas realizadas.

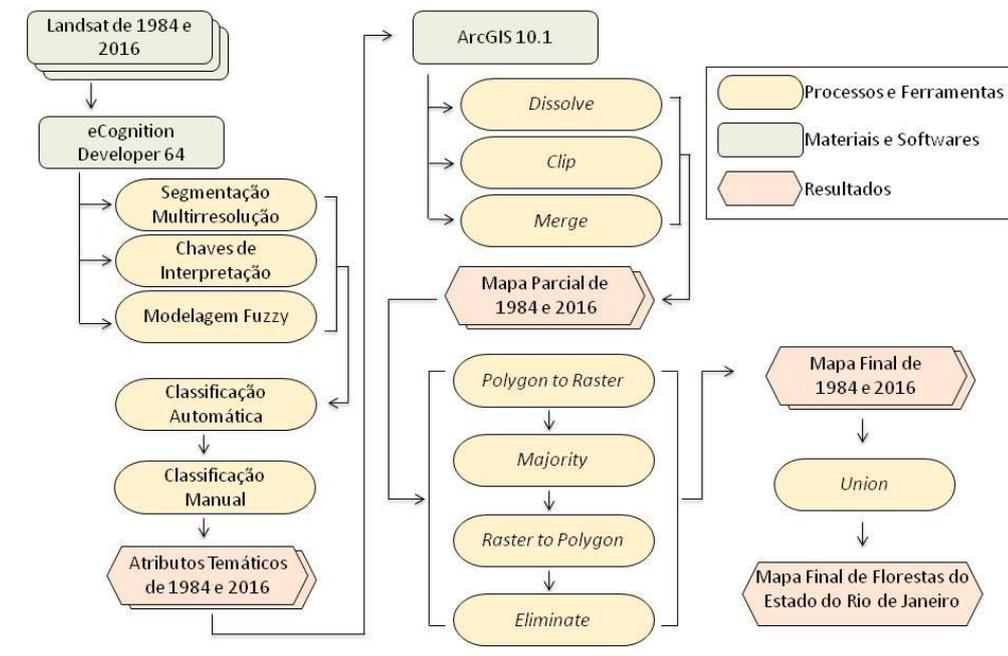


Figura 1 – Fluxograma metodológico da pesquisa

3- RESULTADOS E DISCUSSÕES

A máscara de florestas do estado do Rio de Janeiro pode ser utilizada como insumo para diferentes trabalhos, como detecção de mudanças na cobertura da

terra, evolução de legislações ambientais, unidades de paisagem, entre outros. Por se tratar de um mapeamento temporal, pode-se analisar ao longo dos

anos áreas de reflorestamento e supressão da vegetação no estado. Na Figura 2 pode-se observar a predominância desta cobertura no relevo montanhoso da serra do mar e também nos maciços costeiros, ao longo de todo o estado. Vale lembrar que a escala deste mapeamento é de 1:100.000, logo áreas florestais menores que 5 hectares foram generalizadas.

Dos mais de 43.700 km² do estado, aproximadamente 13.000 km² foram classificados como floresta em alguma das duas datas. Destes, mais de 7.000 km² de florestas foram classificados em 1984 e 2016, correspondendo a coberturas florestais invariantes. Florestas detectadas em apenas uma das datas, correspondem a áreas de onde pode se observados desmatamentos ou regenerações.

A classificação do ano de 1984 obteve uma exatidão global de 0,88, para um índice *kappa* de 0,76, enquanto que a classificação de 2016 obteve uma exatidão de 0,89 e um *kappa* de 0,78, ambas consideradas muito boas, de acordo com classificação propostas por Landis e Koch (1977).

Analisando a matriz de confusão, na Tabela 2, observa-se que o modelo de classificação de florestas, obteve-se índices *kappa* parecidos em ambas as datas. Demonstrando que a classificação se comportou de maneira semelhante em cada uma delas. No modelo da classificação de 1984 quanto na de 2016 não houve predominância significativa de erros de comissão, enquanto ou omissão. A maioria dos erros aconteceu nas áreas de borda entre a classe floresta e a classe

pastagem, em objetos que misturavam estas duas classes, indicando um erro derivado do processo de segmentação. Mas no geral, foram considerados bons resultados para a formação de uma máscara de cobertura florestal.

TABELA 2: MATRIZ DE CONFUSÃO DAS CLASSIFICAÇÕES DE FLORESTA DE 1984 E DE 2016.

Classificação de 1984		
	Floresta	Não Floresta
Floresta	46	4
Não Floresta	8	42

Classificação de 2016		
	Floresta	Não Floresta
Floresta	46	6
Não Floresta	7	43

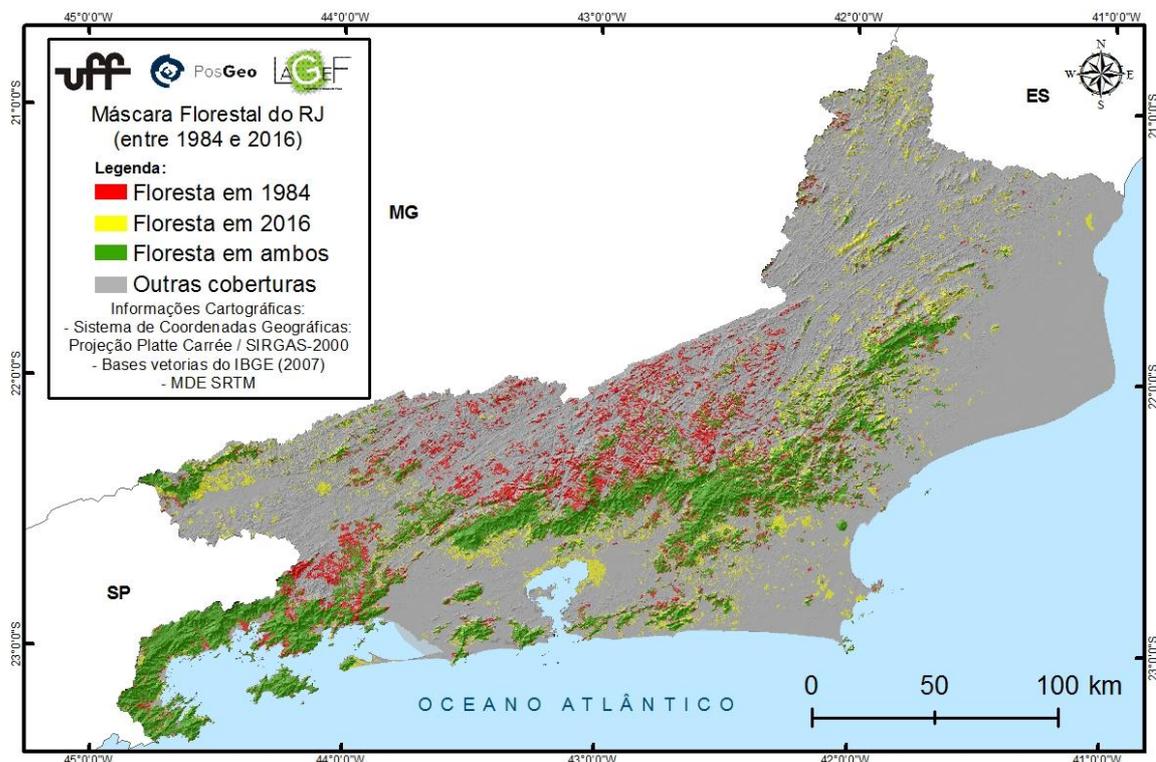


Figura 2 – Máscara de cobertura florestal do estado do Rio de Janeiro entre 1984 e 20

3 - CONSIDERAÇÕES FINAIS

Na etapa de mapeamento da cobertura florestal, o método de classificação no software eCognition 64 a partir da modelagem Fuzzy e da análise orientada a objetos mostrou-se eficiente, sendo a coleta de amostras fundamental para o desenvolvimento da classificação. Assim como a utilização dos algoritmos: multiresolution segmentation e spectral difference segmentation e os dois índices de vegetação para a descrição de classes: NDVI e a Razão Simples. Conclui-se, portanto, que todos os parâmetros utilizados na classificação representam um método prático e proficiente para a classificação semiautomática da vegetação.

A criação e utilização de máscara de florestas em escala regional representa uma possibilidade interessante e eficiente nesta temática. Contudo é necessário que o mapeamento seja submetido a processos de avaliação da precisão técnica do mapeamento. Para o mapeamento da vegetação, o índice kappa, associado à análise da matriz de confusão se mostrou interessante. Os resultados da avaliação neste trabalho foram positivas onde os erros encontrados foram atribuídos à segmentação.

Ressalta-se que a utilização de máscaras de florestas em escala regional apresenta-se como um ferramenta importante nos estudos de detecção de mudanças em séries temporais significativas. Entretanto esta é uma proposta pouco aplicada em relação a sua praticidade e eficiência adjunto a um custo não elevado. Portanto fica a necessidade de estudos mais aprofundados com relação a essa temática, que possam, a partir da contribuição do presente trabalho desenvolver futuras pesquisas, principalmente, aquelas ligadas a detecção de mudanças de coberturas florestais.

AGRADECIMENTOS

Os autores agradecem ao Laboratório de Geografia Física (LAGEF), da Universidade Federal Fluminense (UFF); à Fundação Carlos Chagas Filho de Amparo à Pesquisa do Estado do Rio de Janeiro (FAPERJ) e a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (Capes), pelo apoio a esta pesquisa.

REFERÊNCIAS BIBLIOGRÁFICAS

Araújo, E.H.G., 2006. Análise Multi-Temporal de cenas do satélite Quickbird usando um novo paradigma de classificação de Imagens e inferências espaciais: estudo de caso em Belo Horizonte, MG. Dissertação de Mestrado em Sensoriamento Remoto, Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, SP. 175 p.

Baatz, M. e A. SCchäpe, 1999. Multiresolution segmentation: an optimization approach for high

quality multi-scale image segmentation. AGIT-Symposium Salzburg, Karlsruhe.

Bernardes, T., 2006. Caracterização do ambiente agrícola do Complexo Serra Negra por meio de sensoriamento remoto e sistemas de informação geográfica. Dissertação (Mestrado). Universidade Federal de Lavras, Minas Gerais, 2006, 119p.

Congalton, R.G., 1991. A review of assessing the accuracy of classifications of remotely sensed data. Remote Sensing of Environment, Vol. 37, pp. 35-76.

Cruz, C.B.M.; R.S. Vicens; V.S. Seabra; R.B. Reis; O.A. Faber; P.K.E. Arnaut e M. Araújo, 2007. Classificação orientada a objetos no mapeamento dos remanescentes da cobertura vegetal do bioma Mata Atlântica, na escala 1:250.000, em Anais do XIII Simpósio Brasileiro de Sensoriamento Remoto. Florianópolis, SC.INPE, pp. 5691-5698.

Cruz, C.B.M.; R.S. Vicens; L.S. Rosário; M.B. Abreu; P.M.M. Almeida e F.M. Cronemberger, 2009. Classificação orientada a objetos na geração do mapa de uso e cobertura do estado do Rio de Janeiro, em Anais do XIV Simpósio Brasileiro de Sensoriamento Remoto. Natal, RN. INPE, pp. 7789-7796.

Definiens, 2010. The Principles of Definiens Cognition Network Technology. Disponível em: <http://earth.definiens.com/learn/technology>. Acessado em 15 de maio de 2017.

Landis, J.R. e G.G. Koch, 1977. The measurement of observer agreement for categorical data. International Biometric Society, Vol. 33, Nº 01 pp.159-174.

Ministério do Meio Ambiente, 1998. Diretrizes Para A Política de Conservação e Desenvolvimento Sustentável da Mata Atlântica. Brasília – DF, 26p.

Ministério do Meio Ambiente, 2007. Levantamento da Cobertura Vegetal Nativa do Bioma Mata Atlântica. Projeto de Conservação e Utilização Sustentável da Diversidade Biológica Brasileira - PROBIO. IESB, IGEO/UFRJ, UFF. Rio de Janeiro, 84p.

Prado, B.R.; V.A. Martins; E.H. Hayakawa; J.B. Tavares Júnior e Y.E. Shimabukuro, 2010. Identificação de Classes de Cobertura da Terra na Amazônia Utilizando Imagens Alos/Palsar e Classificação Orientada a Objeto. Revista Brasileira de Cartografia, Vol. 62, Nº 03, pp. 563-569.

Weckmüller, R.; R.S. Vicens, 2016. Método híbrido de detecção de mudanças: uma associação entre classificação baseada em objetos e baseada em pixels. Revista Brasileira de Cartografia, Vol. 68 Nº 05, pp. 883-899.