

MAPEAMENTO DE ÁREAS DE EUCALIPTO COM USO DO ALGORITMO LANDTRENDR E DA SEGMENTAÇÃO MULTITEMPORAL DA SÉRIE LANDSAT

Debora da Paz Gomes Brandão Ferraz^{1 2},
Eduardo Ribeiro Larcerda^{1 3},
Raúl Sanchez Vicens¹

1 - Universidade Federal Fluminense – UFF - Posgeo - Campus Praia Vermelha - Instituto de Geociências - Rua Gal. Milton Tavares, s/n, Sala 508, Boa Viagem- Niterói – Rio de Janeiro, Brasil.

2 - debora.ferraz93@gmail.com

3 - eduardolacerdageo@gmail.com

4 - rsvicens@gmail.com

ABSTRACT

The growth of the eucalyptus crop area in Brazil has been verified by census data, and the use of remote sensing data helps to understand where, when and how this process happens. The work aims to map eucalyptus areas through the combination of spatial segmentation of multitemporal images and classification of products from the change detection based on trajectories, from the time series of the Landsat collection. For this, the synthetic results of the LandTrendr algorithm implemented in Google Earth Engine were used together with the object-based classification (GEOBIA). The confusion matrix using validation points showed a total accuracy of 51.9% and a kappa index of 0.57. It is necessary to improve the classification models, adjusting the thresholds and combining with other results obtained in the LT-GEE to achieve a more desirable index and decrease the manual work of editing. Which leaves new challenges in modeling the detection of changes in vegetation cover through time series.

Keywords: GEOBIA, LandtTrendr, Eucalyptus.

INTRODUÇÃO

As paisagens terrestres vêm sendo alteradas com o objetivo de atender as demandas das atividades humanas. Dentro deste contexto, as plantações de Eucalipto vêm sendo bastante utilizadas para a obtenção de matérias primas. Mas é necessário entender os padrões de distribuição espacial das mudanças no uso e as relações de causalidade com os diferentes vetores de transformação (DeFries, R. 2013; MAUS *et al.*, 2016).

Diversos estudos que buscam compreender como, onde e quando esse processo acontece vem crescendo. Diferentes abordagens metodológicas vêm sendo utilizada para atingir uma detecção e classificação mais precisa das áreas de cultivo de Eucaliptos, a partir das imagens de satélite. O Sensoriamento Remoto se apresenta como um grande auxílio principalmente nas análises multitemporais, que buscam entender a dinâmica e evolução da cobertura vegetal e o uso da terra. (JACKSON e JENSEN, 2005; ZHOU *et al.*, 2012).

Dentre as diversas técnicas de classificação há a “Análise de Imagens de Objetos Geográficos” (GEOBIA), que não analisa os pixels de forma isolados, mas sim regiões

de pixels (segmentos). Com isso, obtém-se um significativo aumento no número de variáveis consideradas na classificação, já que, além das informações espectrais, torna-se possível descrever cada região usando parâmetros em relação à forma do objeto, sua textura, relações entre objetos vizinhos e outros (BLASCHKE, 2010)

Porém, o tempo passa a ser uma componente importante, o que faz com que o número de dados aumente consideravelmente e passa a ser preciso automatizar o processo de classificação. Sendo assim, o algoritmo de detecção de mudanças com base em trajetória, desenvolvido por Kennedy et al. (2010), *LandTrendr (Landsat-based detection of Trends in Disturbance and Recovery)* e implementado no *Google Earth Engine (LT-GEE)* possibilita analisar de forma mais ampla do que o estado atual da imagem e mais rápida (KENNEDY, et al. 2018).

Portanto, o presente trabalho tem por objetivo mapear áreas de eucalipto através da combinação de segmentação espacial de imagens multitemporais e de classificação de produtos provenientes da detecção de mudanças com base em trajetórias, da série temporal de todo o acervo Landsat. Para isso, foi escolhida uma área teste de 3.500 km² com áreas representativas de eucalipto, de aproximadamente 200 km², no estado do Rio de Janeiro (Figura 1).

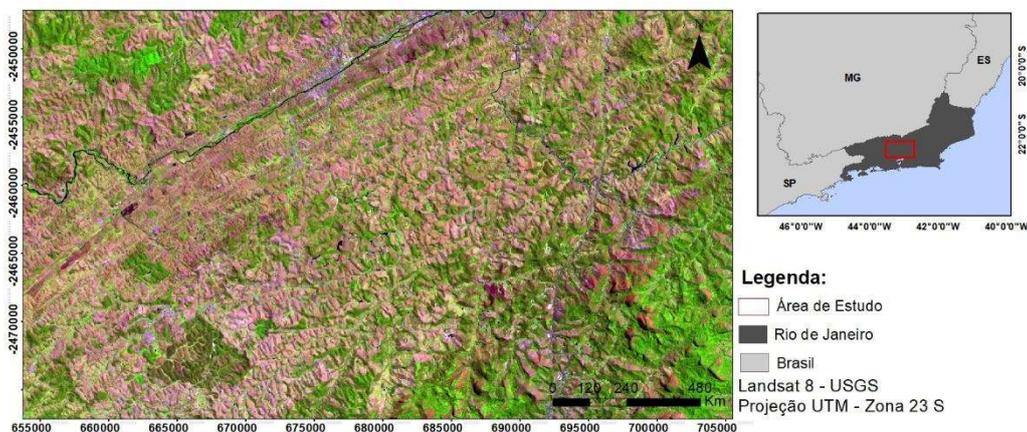


Figura 1. Mapa de localização da área de estudo

METODOLOGIA

As imagens utilizadas são do satélite *Landsat*, que fornece uma imageamento praticamente contínuo de toda a superfície terrestre desde 1984, disponibilizadas para download de forma gratuita pelo USGS (<http://earthexplorer.usgs.gov>), já com pré-processamento necessário realizados. Para a segmentação dos geo-objetos foram utilizadas quatro imagens Landsat desse acervo, anos escolhidos foram: 1986, 1995, 2005 e 2015. O critério utilizado foi o mínimo de nuvens e uma imagem por década. Já

para a geração das imagens sínteses do algoritmo *LandTrendr* foi utilizado todo o acervo disponível, acessível no Google Earth Engine.

Outro resultado obtido a partir de toda série temporal das imagens Landsat disponíveis no Google Earth Engine foi um *composite* de valores máximos de NDVI (Índice de Vegetação por Diferença Normalizada) de cada pixel em toda a série temporal do acervo Landsat. Para a elaboração dessa imagem de máximo valor de NDVI foram utilizadas aproximadamente 5300 imagens da coleção Surface Reflectance Tier 1 por possuírem correção atmosférica.

Através da filtragem inicial indicando o tipo da coleção, a área de interesse e o período de tempo, uma função percorreu cada uma das imagens e gerou uma banda NDVI correspondente para cada uma delas. Além disso, uma outra função retirou todas os pixels que haviam presença de nuvens e sombras utilizando a banda de qualidade disponibilizada pela própria USGS.

Utilizando então a banda do NDVI foi possível agregar para cada pixel o valor da mediana considerando todas as imagens disponíveis para cada ano analisado, para aí sim, extrair os valores máximos considerando todos os anos da série. Ou seja, o *layer* final representa o valor máximo das medianas.

A escolha da mediana como um passo intermediário é crucial para a eliminação de ruídos e valores inválidos presentes na série temporal. O cálculo baseado apenas na aplicação da função de extração dos valores máximos acaba gerando uma camada final com valores ruidosos espalhados por toda a imagem, o que impossibilita seu uso. Todos os códigos necessários para gerar esta camada estão disponíveis de forma aberta (https://github.com/sacridini/max_ndvi).

Para a obtenção dos resultados do LT-GEE foi necessário definir os melhores parâmetros de controle que ajustam como a segmentação temporal é feita, e somar a isso a utilização da série temporal de imagens. As configurações desses parâmetros garantem a qualidade da detecção de mudança (XIAO, Wu *et al* 2020).

Na interface de usuário "*LandTrendr Change Mapper*" do *Google Earth Engine* foram definidos os atributos de mudança (perda ou ganho de vegetação), incluindo: a magnitude da mudança, a duração do evento de mudança e o valor espectral pré-mudança. O índice escolhido foi o NDVI, para ganho e perda, foi selecionada toda a série temporal (1986 – 2019). A magnitude da perda foi definida para filtrar valores maiores que 250 com uma duração menor que dois anos, e para o ganho foi utilizado a magnitude maior que 200 com duração de crescimento superior a dois anos. Os valores correspondem à 1000 vezes a razão e índices espectrais de diferença normalizados (KENNEDY, *et al.* 2018).

A partir da modelagem e ajustes dos parâmetros no código, é fornecida uma imagem de perda ou de ganho com as seguintes bandas: 1- Ano de detecção de evento de mudança, 2- Magnitude do evento de mudança, 3 - Duração do evento de mudança, 4 - Valor espectral do evento anterior à mudança, 5 - Taxa de mudança espectral para o evento (magnitude / duração), e 6 – DSNR (Distúrbio de sinal-ruído).

Os dados foram carregados num sistema de classificação orientado a objetos, para segmentação espacial e classificação supervisionada, através de amostragem e modelos probabilísticos de pertencimento às diferentes classes.

A segmentação espacial e a classificação das áreas, foram realizadas no software *eCognition 9.0*. Foi utilizado o segmentador desenvolvido por Baatz & Schape (1999), *multiresolution segmentation*, utilizando os parâmetros de escala 70, forma 0.3 e 0.2 de compacidade, aplicados a todas as bandas das imagens Landsat dos anos de 1986, 1995, 2005 e 2015. A escolha dos parâmetros foi definida com base nos resultados da pesquisa Yin, He *et al* (2018), onde conclui-se com base na autocorrelação do índice Global Moran I e da variância local ponderada por área que não há diferença substancial quando é adotada a escala maior que 70.

A rede semântica de classificação foi dividida em dois níveis hierárquicos: um primeiro superior de classificação das coberturas de vegetação florestal de porte arbóreo e um nível inferior de classificação das áreas de cobertura de eucalipto. No primeiro nível foi utilizada a máscara do *composite* de valores máximos de NDVI para separar tudo aquilo que é vegetação que em algum momento na série temporal, apresentou um valor de NDVI superior a 0.7. No segundo nível hierárquico, herdando as informações do nível anterior, foi classificado as áreas de eucalipto através dos resultados das bandas 5 - *Taxa de mudança espectral para o evento (magnitude / duração)* do ganho e da perda da vegetação obtidos no LT-GEE. Sendo considerado como eucalipto o intervalo 10 e 20 na perda e entre 65 e 140 no ganho.

No presente trabalho foi utilizada a matriz de confusão ou erro para auxiliar na validação. Como uma tabulação cruzada simples, ela constitui a base que descreve a precisão da classificação e caracteriza os erros, podendo ajudar a refinar a classificação (CONGALTON et al., 1993). Para verificar a acurácia da classificação, foi realizada uma avaliação através do índice Kappa, utilizando como verdade terrestre 140 pontos coletados no *Google Earth* com imagens de maior escala de detalhes. Segundo Antunes & Lingnau (2004) o coeficiente de acurácia Kappa para classes individuais, parece ser o mais indicado na avaliação da classificação de imagens de sensoriamento remoto, por levar em conta os erros comissão e omissão (Figura 2).

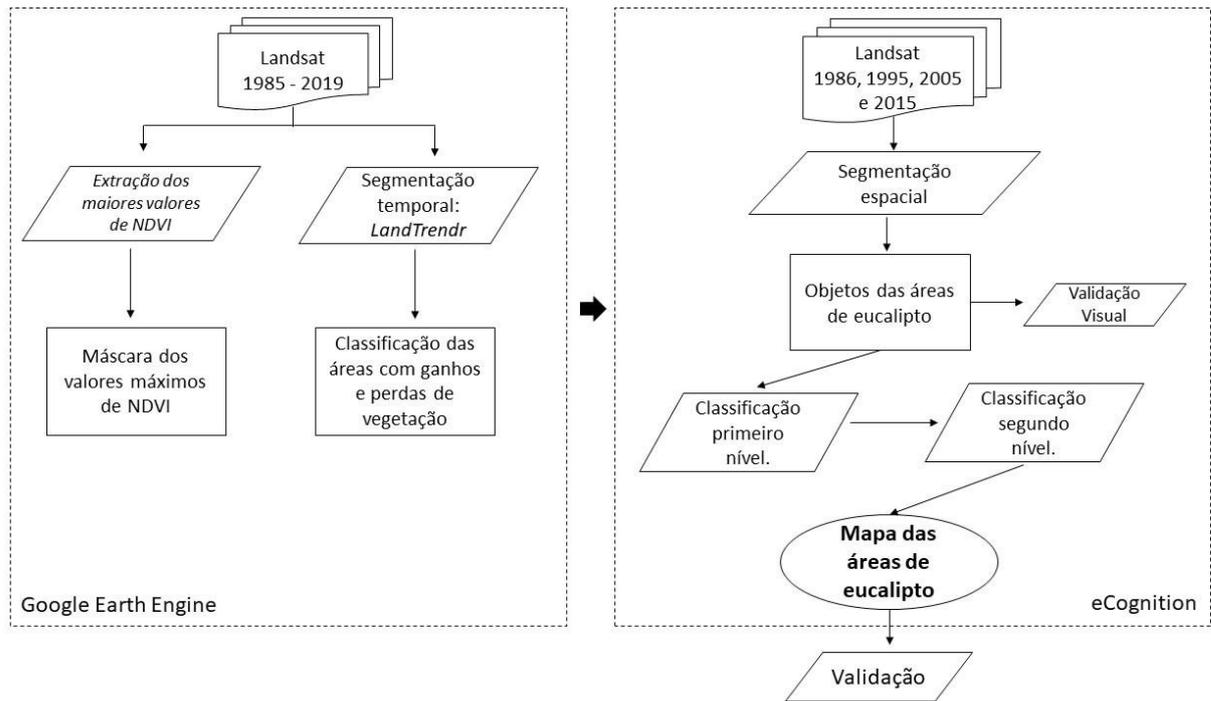


Figura 2: Fluxograma metodológico.

RESULTADOS

A segmentação espacial conseguiu detectar bem as bordas das áreas de eucalipto, respeitando as variações ao longo das quadros de imagens Landsat utilizadas (1986, 1995, 2005 e 2015). Uma comparação visual da segmentação multi-resolução (Figura 3) permite concluir que os objetos capturaram bem áreas grandes com características homogêneas, tanto quanto em áreas de características heterogêneas (Figura 3 -1 e 2).

Para melhor validar este resultado, foram delimitados manualmente por interpretação visual em imagens de alta resolução no *Google Earth*, 30 polígonos de áreas de eucalipto presentes na cena Landsat. A diferença de área total, entre os segmentos considerados como referência e os gerados pelo segmentador foi de 1 ha. Portanto, apesar de alguns erros de borda, principalmente em áreas que são plantadas próximas a áreas de floresta, o que dificulta determinar onde termina um e começa o outro (Figura 3 – 3 – fragmento azul).

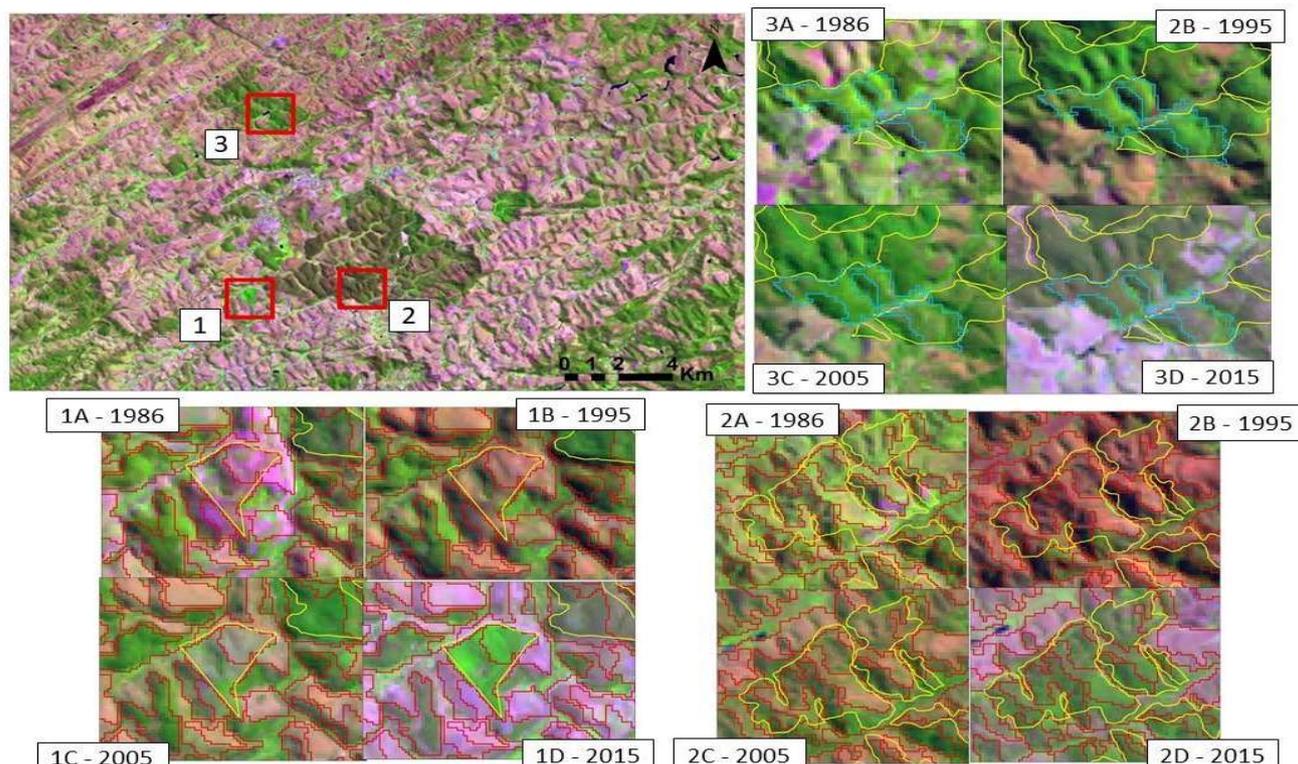


Figura 3 - Comparação das segmentações: a verdade (amarela) e a feita pelo segmentador (vermelha).

Os parâmetros de segmentação da curva original da série temporal foram obtidos por validação visual com a curva ajustada, no módulo “LandTrendr Time Serie Plots”, da interface de usuário do LT-GEE. Os parâmetros escolhidos são os apresentados na Tabela 1.

TABELA 1: PARÂMETROS DE SEGMENTAÇÃO

Parâmetros	Valores
Max Segments	15
Spike Threshold	0.2
Vertex Count Overshoot:	16
Prevent One Year Recovery:	False
Recovery Threshold:	0.75
p-value Threshold:	0.05
Best Model Proportion:	0.25
Min Observations Needed:	6

Fonte: Elaborado pelos Autores

Ao observar a figura 4, é possível ver que os parâmetros citados capturaram bem as mudanças nas trajetórias dos pixels de eucalipto na série temporal. o gráfico compara a curva original dos valores anuais de NDVI, e a curva ajustada pelos parâmetros

escolhidos. Nas imagens de anos diferentes incorporadas na figura, nota-se que até os anos 2000 a área não era utilizada para a plantação de eucalipto, só passando a ser por volta de 2007, sofrendo um corte por volta de 2014 e replantando logo em seguida, em 2019 já se encontra com porte alto.

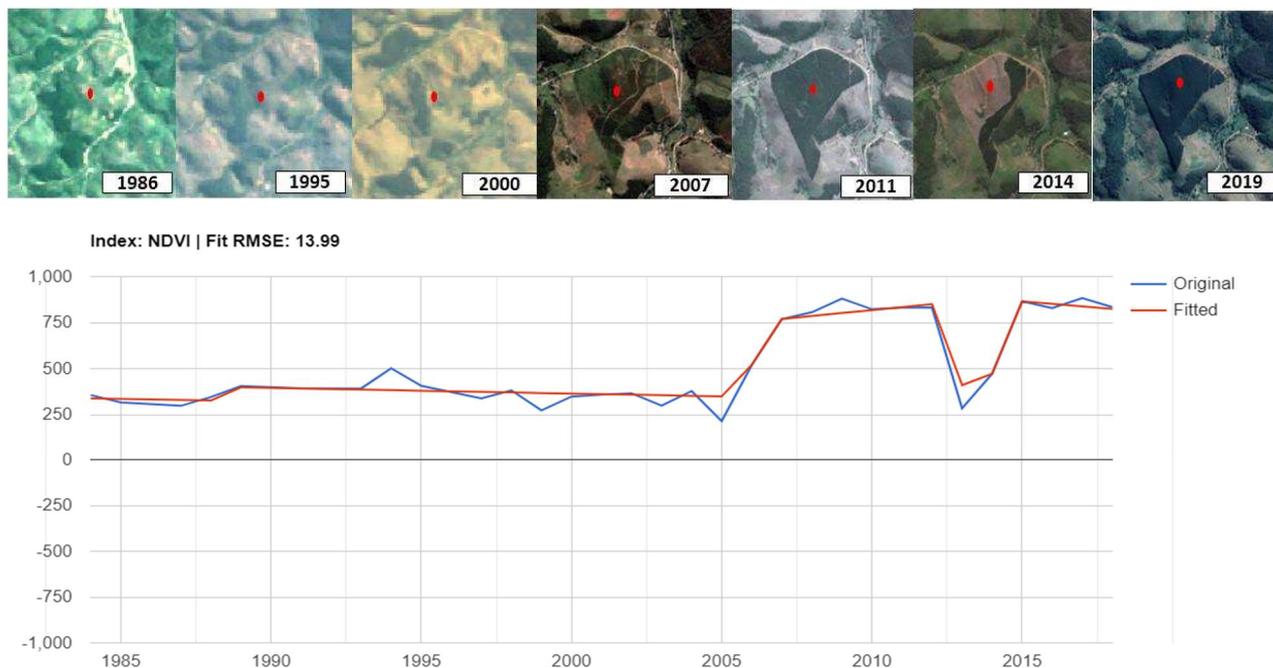


Figura 4: Exemplo de trajetória espectral (Landsat) (linha azul) e trajetória ajustada pelo LandTrendr (linha vermelha) numa amostra de eucalipto. Os pontos vermelhos indicam a localização do pixel em várias imagens da série temporal.

Para a classificação das áreas de eucalipto, foram consideradas as bandas *Taxa de mudança espectral*, que representa a razão entre a magnitude e a duração, para eventos de perda e de ganho, obtidas no LT-GEE. Foi classificado como áreas de eucalipto, trajetórias de perda com taxas entre 10 e 20, e trajetórias de ganho com taxas entre 65 e 140.

Com o objetivo de testar e melhor compreender seu comportamento, foram coletadas 10 amostras correspondentes à geo-objetos classificados como coberturas de Eucalipto e 10 amostras de outras coberturas vegetais. Apesar da cobertura florestal ter sido classificada no primeiro nível (cobertura vegetal e outros), com base no *composite* de valor máximo do NDVI e as áreas de eucalipto terem sido classificadas no segundo nível, a partir da herança da classificação das áreas de cobertura vegetal. Foram utilizados os valores médios da *Taxa de mudança espectral* das 20 amostras para melhor definir o limiar em que o eucalipto se encontra.

Constatou-se que o descritor consegue separar bem as duas classes, pois o eucalipto se concentra em valores de ganho de NDVI de 50 a 140 por ano e de perda de NDVI

entre 10 e 20 por ano. As amostras de floresta apresentaram ganhos entre 150 e 250 ao ano e de menos de 10 a 250 na perda (Gráfico 1 – A e B).

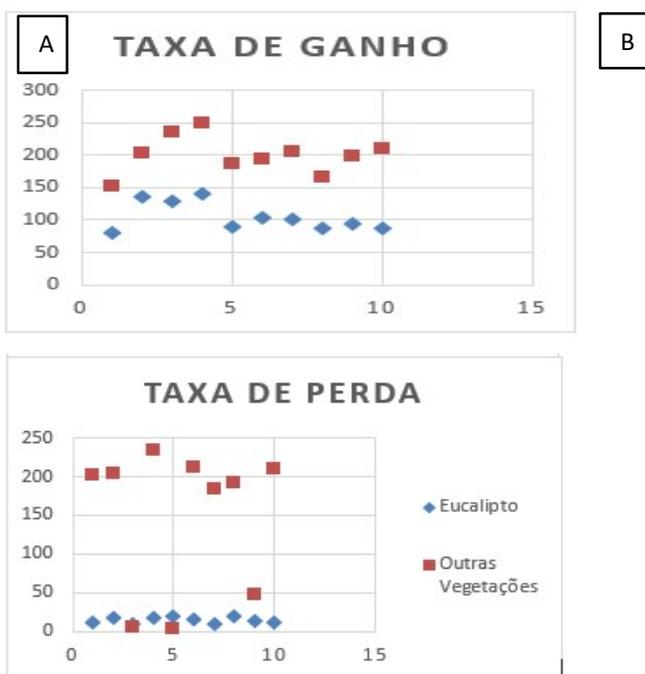


Gráfico 1: Comparação entre os valores das amostras de eucalipto e outros tipos de vegetação na Taxa de Ganho e na Taxa de Perda.

Em geral, a floresta apresenta maiores valores que o Eucalipto, porém há amostras com valores muito próximos o qual acontece em determinadas condições, como maior declividade das encostas ou o os eucaliptos de porte alto que se assemelham as áreas florestadas.

A classificação automática foi feita utilizando parâmetros citados em modelos probabilísticos (fuzzy) e os resultados submetidos à validação. A validação foi feita com 140 pontos, sendo 60 de eucalipto e 80 de não-eucalipto, que foram amostrados no Google Earth com imagens de alta resolução.

A matriz de confusão (Tabela 02) indicou uma exatidão total de 51,9% e um índice Kappa de 0,57. O resultado obtido é classificado como bom (Congalton e Green, 2009).

TABELA 2: MATRIZ DE CONFUSÃO DA CLASSIFICAÇÃO

		Classificação		Total	Erro de Comissão	Erro de Omissão	Exatidão Total	Kappa
		Eucalipto	Outros					
Referência	Eucalipto	41	19	60	31,6%	12,5%	51,9%	0,57
	Outros	10	70	80				
Total		51	89	140				

Fonte: Elaborado pelos autores

A tabela mostra também os erros de omissão (12,5%) e de comissão (31,6%). No mapeamento não há um padrão nos erros encontrados. Os erros de comissão correspondem às confusões entre as áreas de eucalipto e as áreas de florestas mais homogêneas. Já os erros de omissão predominaram nas áreas de encostas, dificultado pelo sombreamento, e nas áreas plantadas próximas as florestas que não sofreram manejo ao longo do tempo, isto é, que não foram cortados. Sendo assim, após as edições necessárias, foi produzido o mapa final das áreas eucalipto (Figura 5).

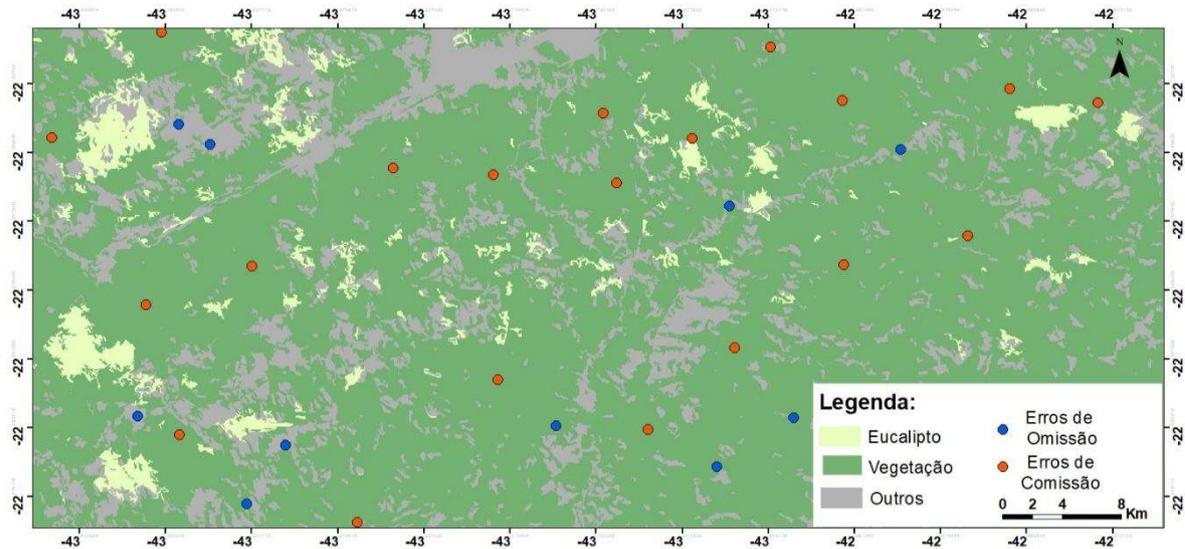


Figura 5: Mapa de classificação das áreas de eucalipto com os pontos de erro de omissão e comissão.

CONCLUSÕES

O trabalho combinou técnicas de segmentação espacial multitemporal e classificação de parâmetros de mudanças na série temporal de todo o acervo de imagens Landsat, para mapeamento de áreas de eucalipto. Embora tenha obtido apenas um resultado satisfatório, com índice Kappa de 0,57, o resultado mostra que os parâmetros resultantes da aplicação do algoritmo LandTrendr junto com as possibilidades da análise orientada a objeto, constituem um método promissor para esse tipo de mapeamento. Ainda é necessário aprimorar os modelos de classificação, ajustando os limiares e combinando com outros resultados obtidos no LT-GEE para alcançar um índice mais desejável e diminuir o trabalho manual da edição. O que deixa novos desafios na modelagem da detecção de mudanças na cobertura vegetal através de séries temporais.

REFERÊNCIAS BIBLIOGRÁFICAS

ANTUNES, R. R. et al. Desenvolvimento de técnica para monitoramento do cadastro urbano baseado na classificação orientada a objetos. Estudo de caso: Município de Goianésia, Goiás. Revista Brasileira de Cartografia, 2014, 67/2, pp.357-372.

BAATZ, M.; SCHAPE, A. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. AGIT-Symposium Salzburg, Karlsruhe. International Journal of Remote Sensing, 1999, v.10, n.06, pp. 989-1003.

BIASCHKE, T. "Object based image analysis for remote sensing". ISPRS Journal of Photogrammetry and Remote Sensing, v. 65, pp. 2-16. 2010.

CONGALTON, R. G.; GREEN, K. "A practical look at the sources of confusion in error matrix generation." Photogrammetric Engineering & Remote Sensing, v. 59, n. 5, p. 641–644, 1993.

DeFRIES, R. Why forest monitoring matters for people and the planet. In: Global forest monitoring from earth observation. Boca Raton, FL: CRC Press/Taylor & Francis Group, 2013, p. 1–14

JACKSON e JENSEN, An Evolution of Remote Sensing derived Landscap Ecology Metrics for Reservoir Shoreline Enviromental Monitoring, Photogrammetric Engineering & Remote Sensing, 2005, 71 (12): 1387-1397.

KENNEDY, Robert E. et al. Implementation of the LandTrendr algorithm on google earth engine. Remote Sensing, v. 10, n. 5, p. 691, 2018.

KENNEDY, Robert E.; YANG, Zhiqiang; COHEN, Warren B. Detecting trends in forest disturbance and recovery using yearly Landsat time series: 1. LandTrendr—Temporal segmentation algorithms. Remote Sensing of Environment, 2010, 114.12: 2897-2910.

UNITED SERVICE GEOLOGICAL SURVEY (USGS). Earth Explorer. Disponível em: <<https://earthexplorer.usgs.gov/>> Acessado em: 16 de outubro de 2019.

YIN, He, et al. Mapping agricultural land abandonment from spatial and temporal segmentation of Landsat time series. Remote sensing of environment, 2018, 210: 12-24.

XIAO, W., DENG, X., HE, T., & CHEN, W. Mapping Annual Land Disturbance and Reclamation in a Surface Coal Mining Region Using Google Earth Engine and the LandTrendr Algorithm: A Case Study of the Shengli Coalfield in Inner Mongolia, China. Remote Sensing, 2020 12(10), 1612.

ZHOU, J., PROISY, C., DESCOMBES, X., LE MAIRE, G., NOUVELLON, Y., VIENNOIS, G., ZERUBIA, J., COUTERON, P. 2013. Mapping local density of young eucalyptus plantations by individual tree detection in high spatial resolution satellite images. Forest Ecology and Management 2013 301:129–141.