

Identificação de Áreas de Eucalipto a Partir de Segmentação Espacial e Temporal de Série Temporal Landsat

Identification of Eucalyptus Areas Based on Spatial and Temporal Segmentation of The Landsat Time Series

Debora da Paz Gomes Brandão Ferraziⁱ
Universidade Federal Fluminense
Niterói, Brasil

Raúl Sanchez Vicensⁱⁱ
Universidade Federal Fluminense
Niterói, Brasil

Resumo: A conversão de sistemas naturais em sistemas antropizados vem causando sobrecarga nos ecossistemas e alterações na paisagem. O Brasil é um dos maiores praticantes da silvicultura, mas as informações sobre o setor são bastante conflitantes. É necessário entender como essas mudanças ocorrem e o Sensoriamento Remoto multitemporal emerge como ferramenta de análise. O objetivo do presente trabalho é testar uma metodologia de detecção de áreas de eucalipto utilizando o algoritmo LandTrendr na plataforma Google Earth Engine combinado com análise orientada a objetos a partir da série temporal do satélite Landsat, entre 1985 e 2020, e identificar a idade dos segmentos encontrados utilizando o mesmo. A matriz de confusão mostrou uma acurácia global de 0.990 com o algoritmo Area² e um Kappa de 0.959, apresentando um resultado bastante satisfatório. Já a identificação da moda do primeiro ano de ganho de cada segmento obteve um Kappa de 0.643.

Palavras-chave: Série Temporal; Landsat; LandTrendr; Eucalipto, GEOBIA.

Abstract: The conversion of natural systems into anthropized systems has been causing an overload on ecosystems and changes in the landscape. Brazil is one of the biggest practitioners of forestry, but information about the sector is quite conflicting. It is necessary to understand how these changes occur and multitemporal Remote Sensing emerges as an analysis tool. The objective of the present work is to test a methodology for detecting eucalyptus areas using the LandTrendr algorithm on the Google Earth Engine platform combined with Object Oriented Analysis from the Landsat satellite time series, between 1985 and 2020, and to identify the age of the segments. found using the same. The con-

ⁱ Mestre em Geografia. debora.ferraz93@gmail.com. <https://orcid.org/0000-0003-2826-1715>

ⁱⁱ Professor Associado do Departamento de Geografia. rsvicens@gmail.com.
<https://orcid.org/0000-0002-4429-806X>

fusion matrix showed an overall accuracy of 0.990 with the Area² algorithm and a Kappa of 0.959, presenting a very satisfactory result. The identification of the mode of the first year of gain of each segment obtained a Kappa of 0.643.

Keywords: Time-series; Landsat; Landtrendr; Eucalyptus; GEOBIA.

Introdução

A conversão de ecossistemas naturais em sistemas antropizados de uso da terra, como, por exemplo, a agricultura e áreas urbanas, vem comprometendo os aspectos funcionais dos remanescentes florestais e causando preocupações na agenda global com relação às mudanças climáticas, perda de ecossistemas, insegurança alimentar e outros (ANDRADE et al., 2015; MAUS et al., 2016).

Toda essa sobrecarga nos ecossistemas devido ao aumento de produção e consumo causado pelo nosso sistema econômico tem feito os países e indústrias buscarem alternativas para suprir a demanda por matéria-prima. O Brasil é um dos maiores praticantes da silvicultura, estima-se que a área ocupada por florestas plantadas no Brasil seja de 7,74 milhões de hectares, o que corresponde a 0,9% do território, e é responsável por 91% de toda a madeira produzida para fins industriais no país, com destaque para os eucaliptos, que correspondem a 88% da cobertura nacional (IBA, 2017).

Apesar de o setor de florestas plantadas ser fortemente consolidado, ainda existem poucos dados estatísticos oficiais e as informações sobre o setor florestal são bastante conflitantes, demonstrando apenas de maneira macro a localização e distribuição dos cultivos florestais, havendo carência de informações primárias advindas de levantamentos diretos, principalmente relacionados a estudos que busquem compreender a alteração na paisagem e seus impactos devido à inserção dessas áreas de florestas plantadas.

No intuito de obter essas respostas, é necessário entender onde, como e por que elas ocorrem, fazendo com que o espaço e o tempo sejam aspectos fundamentais a serem considerados. Para responder a esses questionamentos, o Sensoriamento Remoto multi-temporal emerge como a mais importante ferramenta de análise.

Há uma grande disponibilidade de sensores que compõem o Sistema de Observação da Terra e que adquirem dados a diferentes escalas espaciais, espectrais e temporais. Esses dados demandam elevada capacidade de armazenamento e processamento, de análise e interpretação, trazendo não só desafios geotecnológicos como novos paradigmas para se estudar a paisagem.

A complexidade de se trabalhar com uma grande quantidade de informações de dados temporais e o dinamismo deles faz com que haja uma busca constante para melhorar o aproveitamento da grande quantidade de informação disponível. O acesso a este grande conjunto de dados atuais de observação da Terra, *Big Earth Observation Data*, e o desenvolvimento de algoritmos capazes de processá-los, oferecem melhores oportunidades de descrever e entender as mudanças na superfície do planeta, superando as limitações espaciais e temporais dos métodos tradicionais. Além do desafio metodológico, o outro é a reflexão intelectual que converge os aportes técnicos de algoritmo e a grande massa de processamento, a sua tradução, a dinâmica ambiental e a interpretação dos fenômenos existentes na superfície (CÂMARA et al., 2016).

O algoritmo de detecção de mudanças com base em trajetória, LandTrendr (*Landsat-based detection of Trends in Disturbance and Recovery*), desenvolvido por Kennedy et al. (2010) fornece estimativas tanto sobre desvios bruscos da trajetória (sua magnitude e a data da perturbação) quanto de processos contínuos e lentos. O método baseia-se no melhor ajuste da curva temporal de cada pixel em relação a trajetórias reconhecidas numa área de floresta a partir de séries temporais Landsat. Posteriormente o algoritmo foi implementado na plataforma Google Earth Engine (LT-GEE), o que otimizou o seu processamento (KENNEDY et al., 2018).

Além da gratuidade e da disponibilidade a todos, Griffiths et al. (2012) afirmam que o LandTrendr possui vantagens frente a outros algoritmos de detecção de mudanças: gera trajetórias espectro-temporais para expressar os eventos ocorridos no pixel no decorrer do tempo; é desenvolvido para imagens Landsat dos sensores TM e ETM+; e tem sido aplicado com sucesso em diversos estudos sobre mudança e regeneração da cobertura florestal.

Esses resultados podem ser potencializados quando são aliados a outras técnicas de sensoriamento remoto. Entre as mais promissoras abordagens está a Geographic Object-Based Image Analysis (GEOBIA), por ponderar, além da informação espectral pura, informações referentes à forma, à textura e ao contexto para analisar paisagens heterogêneas (HAY; CASTILLA, 2008; BLASCHKE, 2010).

Devido ao manejo realizado pela plantação de eucalipto, é possível determinar o período de corte e crescimento, que ocorre em média entre 5 e 7 anos, o que a diferencia de outras culturas e de florestas. Isso permite a sua identificação e mapeamento mediante a utilização de uma abordagem com base em trajetória, através de série temporal anual. Neste contexto, o objetivo do presente trabalho é testar uma metodologia de detecção de áreas de eucalipto utilizando o algoritmo LT-GEE combinado com GEOBIA a partir da série temporal do satélite Landsat, entre 1985 e 2020, e identificar a idade dos segmentos encontrados utilizando o mesmo algoritmo.

Para isso, foi escolhida como área de estudo um recorte do estado do Rio de Janeiro (-43,99W e -21,88S; -43,99W e -22,67S; -42,46W e -21,89S; -42,46W e -22,68S). Essa região compreende os municípios com as maiores áreas e quantidades de propriedades produtoras de eucalipto do estado (Figura 1) (FERRAZ e VICENS, 2019), servindo como área de teste para o desenvolvimento da metodologia.



Figura 1 – Área de estudo.

Metodologia

Neste trabalho, as imagens utilizadas para o mapeamento pertencem à série temporal do satélite Landsat, elas são fornecidas de forma gratuita na plataforma Google Earth Engine e para cobrir a área de estudo utilizou-se duas cenas (217-75 e 217-76). Através do algoritmo é selecionada uma cena por ano e elas já vêm georreferenciadas e com a superfície de reflectância corrigida, por isso não é necessário fazer um pré-processamento para esse tipo de mapeamento. Foi utilizada a combinação de dois processos: o primeiro, a classificação utilizando o algoritmo Landtrendr no Google Earth Engine (LT-GEE), que depois foi levada para o software eCognition; para a segunda parte, a realização da Classificação Orientada a Objeto (GEOBIA) para a identificação das áreas de eucalipto. Posteriormente, foi identificado o ano inicial médio do crescimento dos segmentos com o objetivo de ter a ideia média dos mesmos (Figura 2).

O Google Earth Engine (GEE) é uma plataforma de geoprocessamento baseada em nuvem projetada para fornecer acesso computacional a vastos conjuntos de dados geoespaciais. Ela condensa muitas etapas anteriormente onerosas a algumas linhas de código, principalmente em relação ao pré-processamento, e contém um vasto catálogo de imagens pronto para análise, incluindo toda a série temporal do satélite Landsat (GO-RELICK et al., 2017).

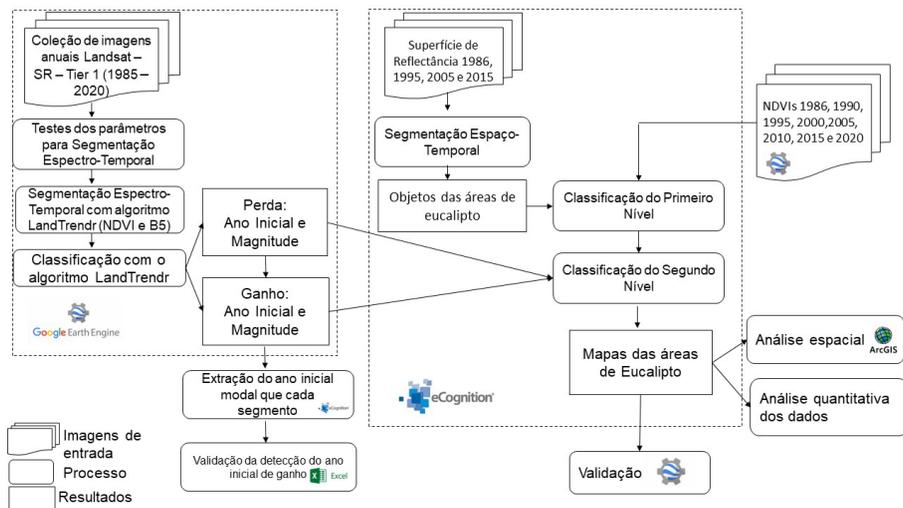


Figura 2 – Fluxograma metodológico.

O algoritmo LT-GEE tem por objetivo detectar as mudanças com base nas trajetórias de cada pixel. Ou seja, busca detectar trajetórias espectro-temporais que expressam os eventos ocorridos no pixel no decorrer do tempo (KENNEDY et al., 2010; FRAGAL et al., 2016; WECKMÜLLER e VICENS, 2019). Para a identificação das áreas de eucalipto é necessário levar consideração as suas características. Seu padrão de crescimento para a obtenção de celulose, por exemplo, varia de 5 a 7 anos (EMBRAPA, 2022).

Os testes para a segmentação espectro-temporal levaram em consideração essas características para definir 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. Foram escolhidos dois índices, o SWIR (B5) e o NDVI (Índice de Vegetação por Diferença Normalizada, pela sua sigla em inglês — ROUSE et al. 1973), tanto para ganho quanto para perda, utilizando toda a série temporal (1985-2020). Para ambos a magnitude da perda foi definida para filtrar valores maiores que 250 com uma duração menor que dois anos, já que o corte de uma árvore se caracteriza como uma perda abrupta. E com o ganho foi utilizada a magnitude maior que 200 com duração de crescimento superior a dois anos, com o objetivo de identificar a partir das áreas com baixo crescimento. Os valores correspondem a 1000 vezes a razão e aos índices espectrais de diferença normalizados (KENNEDY et al., 2018).

Para isso, foram realizados testes e análises por interpretação visual entre a curva original da série temporal e a curva ajustada pelo segmentador, com o objetivo de ficarem o mais próximo possível. Os parâmetros escolhidos são os apresentados na Tabela 1.

Tabela 1 – Parâmetros de Segmentação Temporal.

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

Elaborado pelos autores.

Ao observar a Figura 2 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 da B5, 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, os eucaliptos já se encontram com porte alto.

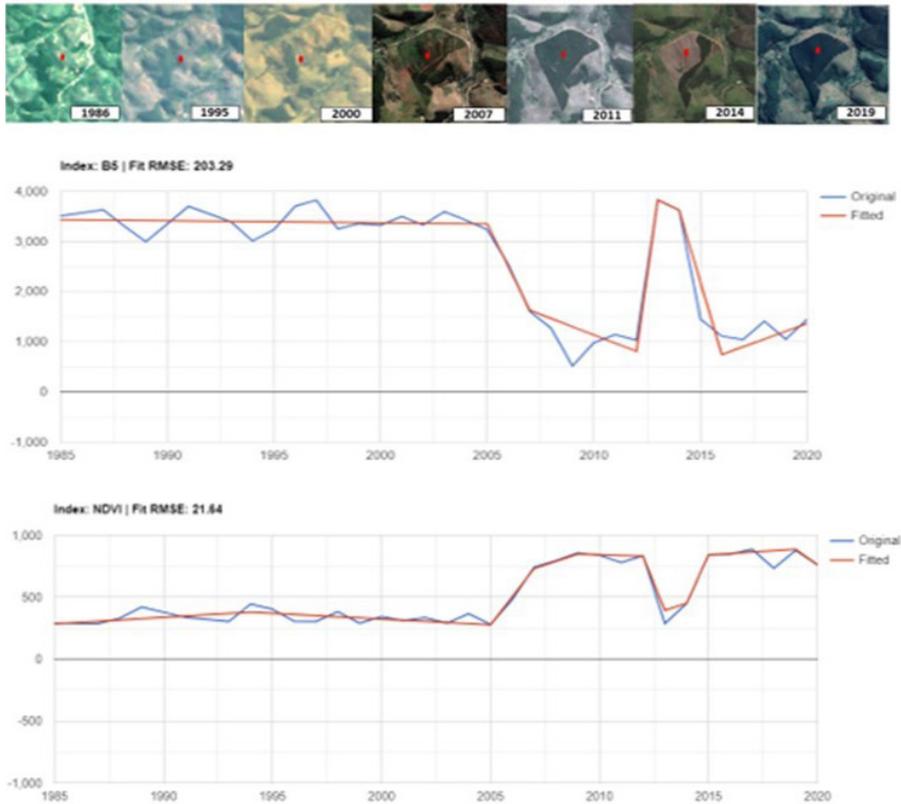


Figura 3 – Exemplo de trajetória espectral (Landsat) (linha azul) e trajetória ajustada pelo LandTrendr (linha vermelha) numa amostra de eucalipto. Os pontos vermelhos indicam a localização do pixel em várias imagens da série temporal.

A partir da modelagem e ajuste dos parâmetros no código, foram obtidas imagens de perda e de ganho para os dados processados (NDVI e B5), 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).

A banda 5 (B5) dos resultados do LT, que corresponde à taxa de mudança espectral, ou seja, que é o resultado da divisão da magnitude pela duração do evento, da perda e do ganho do NDVI e da banda SWIR foram levadas junto com outras imagens e índices para um sistema de classificação orientado a objetos.

O objetivo é buscar uma metodologia em que seja possível identificar as áreas de eucalipto a partir da detecção da sua mudança ao longo do tempo. E o GEOBIA permite que a análise seja feita por regiões de pixels (segmentos). Com isso, obtém-se um sig-

nificativo 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).

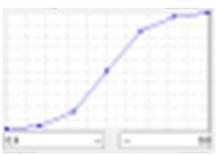
No software eCognition foi realizada a segmentação multitemporal e a classificação supervisionada, através de amostragem e modelos probabilísticos de pertencimento às diferentes classes. Para isso, foi necessário fazer o download das cenas da área de estudo no GEE.

A segmentação multitemporal foi feita a partir do segmentador desenvolvido por Baatz e 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 de 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. Para classificação do primeiro nível, foram utilizados NDVIs da área de estudo com um intervalo de 5 em 5 anos dentro da janela temporal trabalhada (1985, 1990, 1995, 2000, 2005, 2010, 2015, 2020). Os critérios utilizados para a escolha das datas estão relacionados à qualidade das imagens, presença de nuvens, e, principalmente, para capturar todas as mudanças passadas pelas áreas de eucalipto com relação ao manejo: corte e crescimento.

As áreas foram classificadas em duas classes: vegetação densa e outros. Foram considerados como pertencentes à classe “vegetação densa” todos os segmentos que em pelo menos um desses anos apresentou um NDVI dentro do intervalo determinado. O modelo escolhido para a classificação foi *fuzzy* do tipo “ou” (“or”), com a função “maior que”, e os valores estabelecidos foram: 0.4 a 0.8 (Tabela 2). Já para a classe “outros”, foi classificado todo o resto que não pertencia à classe anterior.

Tabela 2 – Modelo utilizado na classificação primeiro nível.

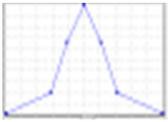
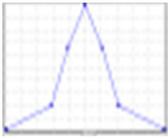
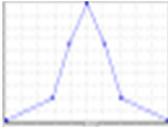
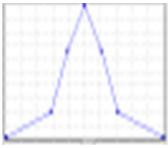
Descritores da classe Vegetação Densa	Limiar (intervalo)	Modelo fuzzy
NDV	Entre 0.4 e 0.8	

Já para o segundo nível, o objetivo era separar, dentro da classe de vegetação densa, quais segmentos eram de eucalipto. Para isso utilizou-se os resultados da banda 5 – Taxa

de mudança espectral para o evento (*magnitude / duração*) — do ganho e da perda da vegetação obtidos no LT-GEE tanto para o SWIR quanto para o NDVI. A escolha dessa banda se justifica pelo fato de mostrar a magnitude do evento dividida pela sua duração, fatores importantes para a determinação das áreas de eucalipto que possuem manejo. Pois espera-se que o objeto irá apresentar uma magnitude grande com uma queda rápida na perda (corte), seguido de um crescimento também rápido se comparado ao de floresta.

A classificação automática do segundo nível também foi feita utilizando os parâmetros citados em modelos probabilísticos (*fuzzy*), porém, do tipo “e” (“and”), com função Gaussiana aproximada. Foram classificadas como áreas de eucalipto trajetórias de perda com taxas entre 170 e 450, e trajetórias de ganho com taxas entre 115 e 210 no NDVI. E, para a B5, foram consideradas as trajetórias de perda entre 100 e 300 e de ganho entre 450 e 700 (Tabela 3).

Tabela 3 – Modelo utilizado na classificação segundo nível.

Índice	Descritores da classe	Limiar	Modelo fuzzy
NDVI	Banda 5 (magnitude / duração) ganho	Entre 115 e 210	
	Banda 5 (magnitude / duração) perda	Entre 170 e 450	
SWIR	Banda 5 (magnitude / duração) ganho	Entre 450 e 750	
	Banda 5 (magnitude / duração) perda	Entre 100 e 300	

Para a validação foi utilizada a estimativa de área e avaliação de precisão (Area²), desenvolvida por Olofsson et al. (2014) e aplicada no Google Earth Engine, que gera uma amostragem aleatória estratificada para avaliar as classes levando em consideração o tamanho da área. O algoritmo sugeriu a utilização de 240 pontos que foram distribuídos de maneira aleatória da seguinte forma: 40 pontos para a classe eucalipto e 200 para a classe outros.

Os pontos gerados foram extraídos e avaliados visualmente utilizando as séries temporais Landsat, Sentinel, imagens do Google Earth e séries temporais de índices (NDVI, Índice de Solo Exposto (BSI), Tasseled-Cap Brightness, Greenness e Wetness) em um visualizador de série temporal do GEE (YIN et al., 2020).

Ao final, foi criada uma matriz de confusão e calculadas as precisões do produtor e do usuário para a classificação. Com a aplicação do código de “Estimativa da Área Estratificada” no GEE, que estabelece a comparação entre os dados de referência (os pontos verificados anteriormente) e o mapa classificado, com o objetivo de gerar a estimativa de área e a avaliação de precisão do mapa (STEHMAN e FOODY, 2009; STEHMAN, 2013; OLOFSSON et al. 2014).

Com o objetivo de contribuir para a validação da classificação e corroborar com os resultados, também foi realizado o cálculo do índice Kappa a partir da mesma matriz de confusão. Segundo Antunes e 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 de comissão e omissão.

Outro resultado gerado foi a identificação do ano inicial do ganho com o objetivo de testar o algoritmo LT-GEE para a identificação da idade de cada segmento de eucalipto identificado. Para isso, foi utilizado o valor mais frequente (moda) da banda 1 do resultado de ganho do LT, que fornece o “ano de detecção de eventos de mudança”. Essa banda também foi levada ao eCognition e segmentada a partir dos resultados da classificação anterior, com o objetivo de preservar os geo-objetos já identificados. Após isso, foi extraído o valor de moda para cada segmento, ou seja, foi visto qual o ano que mais ocorria dentro dos pixels daquele segmento de eucalipto e assim foi estabelecido o primeiro ano de ganho.

Foram gerados 60 pontos aleatórios dentro dos fragmentos e extraída do Arcgis, através da ferramenta *extract value to point*, a idade média referente a eles. Depois disso, utilizou-se o mesmo código de série temporal no GEE (YIN et al., 2020) para observar a curva de comportamento do ponto ao longo da janela temporal, identificando visualmente o ano do primeiro ganho e comparando-os entre si.

Resultados

O mapeamento (Figura 4) realizado apresentou uma acurácia global de 0.990 com o algoritmo Area² e um Kappa de 0.959, apresentando um resultado bastante satisfatório, identificando cerca de 188 segmentos de eucalipto na área de estudo.

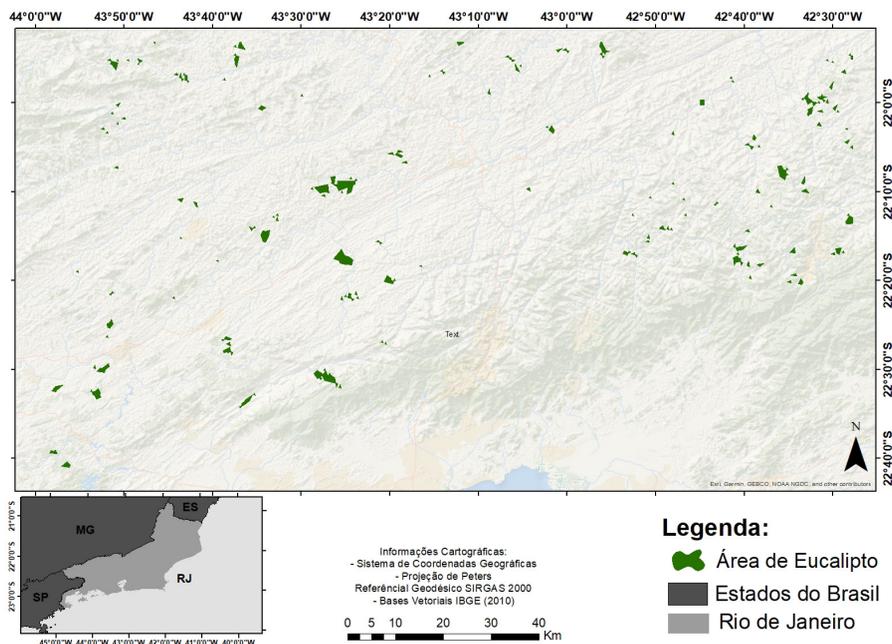


Figura 4 – Mapeamento das áreas de eucalipto.

Tema recorrente sobre detecção de mudanças, a avaliação da precisão da técnica é fundamental. Com o surgimento de dados gratuitos e plataformas de computação poderosas, a criação de mapas nunca foi tão fácil, o que torna a sua acurácia fundamental. A acurácia é definida como o grau em que o mapa produzido concorda com a referência estabelecida como verdade e existem diversas maneiras de estabelecer essa validação (MCROBERTS e RONALD, 2011).

Porém, para os mapas que analisam mudanças temporais, recomenda-se que tenham uma avaliação de precisão que inclua uma descrição clara das amostragens, contendo o tamanho das amostras, sua relevância, estratificação, uma matriz de erro, a área ou proporção da área de cada categoria de acordo com o mapa, e medidas de precisão descritivas como usuário, produtor e precisão geral (OLOFSSON et al., 2013).

O Area² utilizado no presente trabalho gera uma amostragem aleatória estratificada para avaliar classes, levando em consideração a proporção do tamanho das classes em relação à área de estudo (BULLOCL et al., 2020). Ao analisar os erros por classes (Tabela 4) percebe-se que, com relação às áreas de eucalipto, a acurácia do produtor (AP) teve um resultado bem abaixo do esperado, de 0.398, enquanto a acurácia do usuário (AU) demonstrou um resultado muito mais satisfatório, de 0.975.

Tabela 4 – Acurácia do Produtor (AP) e Acurácia do Usuário (AU).

	Eucalipto	Outros
Proporção da área	0.017	0.983
Erro padrão (proporcional a área)	0.007	0.007
Área (ha)	23.139.521	1.378.180.736
Acurácia do Produtor	0.398	0.989
Acurácia do Usuário	0.975	0.99

Ao analisar a Matriz de Acurácia (Tabela 5), é possível perceber que, dos 40 pontos de eucalipto, 1 na verdade pertencia à classe outros, configurando o erro de omissão. E dos 200 pontos totais da classe outros, 2 pontos, na verdade, eram áreas de eucalipto, demonstrando o erro de comissão. Ou seja, ao analisar os pontos gerados percebe-se que os erros não foram tão grandes para gerar uma acurácia do produtor mais baixa, e ao analisar visualmente também é possível perceber isso. Mas é importante destacar que, neste tipo de análise, a proporção das áreas de cada classe em relação à área total do mapeamento vai determinar o peso da classe na análise (OLOFSSON et al., 2014). Pelo fato de as áreas de eucalipto serem menores em comparação ao restante da área de estudo, que se configurou em uma única classe, os dois fragmentos que eram eucaliptos, mas que foram classificados como outros, influenciaram na estimativa da acurácia.

Tabela 5 – Matriz de Acurácia Área².

Matriz de Acurácia por amostra				Matriz de Acurácia proporcional				
		<i>Classificação</i>					<i>Classificação</i>	
		Eucalipto	Outros	Total			Eucalipto	Outros
<i>Verdade</i>	Eucalipto	39	1	40	<i>Verdade</i>	Eucalipto	0.007	0.001
	Outros	2	198	200		Outros	0.01	0.983
Total		41	199	240				

Para corroborar com a validação foi gerado um índice Kappa a partir dos mesmos pontos e da matriz de confusão citada anteriormente. O Kappa encontrado foi de 0.959 e uma exatidão total de 0.987. De acordo com Congalton e Green (2009) o resultado obtido é excelente. A matriz de confusão (Tabela 6) também apresenta os erros de omissão para a classe eucalipto (4,87%) e os erros de comissão para a mesma classe (2,5%).

Tabela 6: Matriz de confusão.

	Classificação			Erro de Comissão	Exatidão Total	Kappa	
	Eucalipto	Outros	TOTAL				
Verdade	Eucalipto	39	1	40	2,50%	98,75% (0,987)	95,91% (0,959)
	Outros	2	198	200	1,00%		
	TOTAL	41	199	240			
Erro de Omissão		4,87%	0,50%				

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, dificultados pelo sombreamento, e nas áreas plantadas próximas às florestas que não sofreram manejo ao longo do tempo, isto é, que não foram cortadas.

Outro resultado importante obtido foi a possibilidade de identificar a idade de cada fragmento de eucalipto a partir da Banda-1 do LT de ganho (MUGIRANEZA et al., 2020). Ao identificar o ano foi possível ver qual a idade modal de cada fragmento, vendo há quanto tempo aquela área estava sendo utilizada para a plantação (Figura 4).

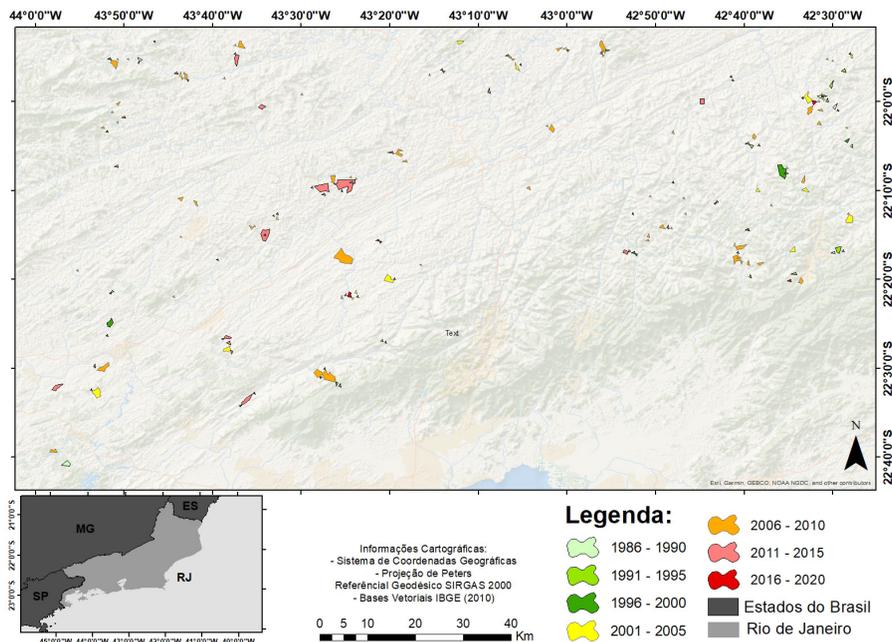


Figura 5 – Mapa das áreas de eucalipto classificadas por intervalo do ano inicial do ganho.

O índice Kappa obtido da comparação dos valores gerados pelo LT-GEE e validados visualmente foi de 0.643, com uma exatidão total de 0.754 (Tabela 7). Ao observar os erros de omissão e comissão, concluiu-se que as classes de 2006-2010 e 2011-2019 apresentaram os menores erros e correspondem às mais amostradas.

Tabela 7 – Matriz de Confusão da Identificação do ano do ganho.

Classes	Verdade						Total	Erro de Comissão	Exatidão Total	Índice Kappa
	1986-1991	1992-1995	1996-2000	2001-2005	2006-2010	2011-2019				
1986-1991	2	2	0	0	3	0	7	71,42%	0.754 (74,5%)	0.643 (643%)
1992-1995	1	1	0	0	0	0	2	50,00%		
1996-2000	0	0	3	1	0	1	5	40,00%		
2001-2005	0	0	1	1	0	0	2	50,00%		
2006-2010	0	0	1	0	22	3	26	15,38%		
2011-2019	0	0	0	0	2	17	19	10,52%		
Total	3	3	5	2	27	21	61			
Erro de Omissão	33,33%	66,66%	40,00%	50,00%	18,51%	19,04%				

Ao observar a Figura 6, é possível perceber que a maioria das áreas surgiu entre 2007 e 2012, com destaque para o ano de 2009, ou seja, são áreas de plantação com uma idade média de 15 anos. Mas em outros momentos também apresentaram grandes crescimentos, como nos anos de 2004 e 1993. E que algumas áreas apresentaram o primeiro ganho no ano de 1986 ou próximo a ele, ano em que se iniciou esse monitoramento, sendo assim, algumas dessas áreas já poderiam estar sendo usadas para a plantação de eucalipto antes disso.

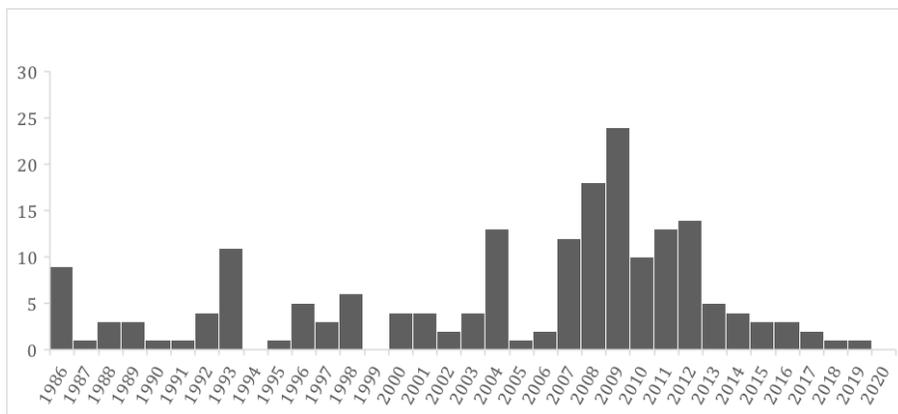


Figura 6 – Gráfico de frequência do surgimento das áreas de eucalipto por ano.

Também foi realizado o Teste de Qualidade do Ajuste (WANG, 1998), que é um procedimento simples que compara a distribuição observada com a frequência (Tabela 8) de ocorrência de cada classe, com o objetivo de identificar se as distribuições são similares.

Tabela 8 – A frequência observada em cada classe do LT-GEE (O_j) com a frequência esperada para cada classe na amostra (E_j).

	Observado	Esperado
<i>Intervalo</i>	O_j	E_j
1986-1991	6	4
1992-1995	2	3
1996-2000	5	4
2001-2005	3	2
2006-2010	25	27
2011-2019	20	21

Tendo como hipótese nula (Equação 01) e hipótese alternativa (Equação 02), utiliza-se a estatística Qui-Quadrado (Equação 03) com base no quadrado das diferenças entre as frequências observadas e esperadas (Tabela 9):

$$H_0: O_j = E_j \tag{Eq. 01}$$

$$H_a: O_j \neq E_j \tag{Eq. 02}$$

$$X^2 = \sum_{j=1}^k \frac{(O_j - E_j)^2}{E_j} \tag{Eq. 03}$$

O_j : frequência observada na classe j ;
 E_j : frequência esperada na classe j
 k : número de classes

Tabela 9: Cálculo do Qui-Quadrado.

Intervalo	O_j	E_j	$O_j - E_j$	$(O_j - E_j)^2$	$\frac{(O_j - E_j)^2}{E_j}$
1986-1991	6	4	2	4	1.00
1992-1995	2	3	-1	1	0.33
1996-2000	5	4	1	1	0.25
2001-2005	3	2	1	1	0.50
2006-2010	25	27	-2	4	0.15
2011-2019	20	21	-1	1	0.05
					2.279

Para a definição da região de rejeição é considerada a Equação 04.

$$X^2_{crit} \geq [X^2, p = 1 - \alpha, GLIB = k - m - 1] \tag{Eq. 04}$$

$$X^2_{crit} \geq [X^2, p = 1 - 0,05, GLIB = 6 - 0 - 1]$$

$$X^2_{crit} \geq [X^2, p = 0,95, GLIB = 5]$$

$$X^2_{crit} = 11,070$$

Portanto, como $X^2_{calc} < X^2_{crit}$, não pode rejeitar H_0 . Logo, não há diferenças significativas entre a frequência observada e a frequência esperada. Significa que a distribuição da idade do plantio identificada pelo LandTrendr é similar à distribuição real.

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. Obtendo uma resposta muito satisfatória, com uma acurácia total de 0.990 com o algoritmo Area², e um Kappa de 0.959. 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.

Com relação à utilização de banda de identificação do ano do primeiro ganho pelo LT-GEE associada aos geo-objetos, os resultados também foram satisfatórios, com Kappa de 0.643 e um teste de qualidade de ajuste mostrando que não há grandes diferenças entre os anos observados na curva espectral e os determinados pelo algoritmo. Essa informação é importante pois permite entender há quanto tempo houve alteração na paisagem daquela área plantada com a inserção do eucalipto.

Portanto, ao se trabalhar a lógica de análise orientada a objeto, associada à classificação multitemporal, é possível estabelecer as trajetórias evolutivas das coberturas vegetais dos segmentos identificados. Podendo-se identificar, por exemplo, o tamanho das propriedades produtoras de eucalipto e relacionar essas informações, da área e da idade da cobertura, com outros tipos de dados, como os censitários ou da pesquisa extrativista.

Referências Bibliográfica

ANDRADE, P. R.; CÂMARA, G.; MARETTO, R. V.; MONTEIRO, A. M. V.; CARNEIRO, T. G. S.; FEITOSA, F. F. Experiences with a Socio-Environmental Modeling Course. *Modelling in Science Education and Learning*, v. 8, n. 1, p. 71-92, 2015.

ANTUNES, A. F. B.; LINGNAU, C.; QUINTAS, M. L. Análise de acuracia de mapa de uso do solo oriundo de classificação de imagem de alta resolução. *Boletim de Ciências Geodésicas (Impresso)*, v. 4, p. 101-113, 2004.

BAATZ, M.; SCHAPE, A. Object-Oriented and Multi-Scale Image Analysis in Semantic Networks. In: *Proc. of the 2nd International Symposium on Operationalization of Remote Sensing*, August 16-20, Enschede: ITC, 1999.

BLASCHKE, T. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 65, p. 2-16, 2010.

BULLOCK, E. L.; WOODCOCK, C. E.; OLOFSSON, P. Monitoring tropical forest degradation using spectral unmixing and Landsat time series analysis. *Remote sensing of Environment*, v. 238, 110968, 2020.

CAMARA, G.; ASSIS, L. F.; RIBEIRO, G.; FERREIRA, K. R.; LLAPA, E.; VINHAS, L. Big earth observation data analytics: Matching requirements to system architectures.

Identificação de Áreas de Eucalipto a Partir de Segmentação Espacial e Temporal de Série Temporal Landsat

In: *Proceedings of the 5th ACM SIGSPATIAL international workshop on analytics for big geospatial data*, p. 1-6, 2016.

CONGALTON, R. G.; GREEN, K. Assessing the accuracy of remotely sensed data: principles and practices, Second Edition. Boca Raton: *CRC Press*, FL, 2009.

EMBRAPA – Embrapa Florestas – Eucalipto. Disponível em: <https://www.embrapa.br/florestas/transferencia-de-tecnologia/eucalipto>. Acesso em: jun. 2022.

FERRAZ, D. P. G. B.; VICENS, R. S. Desempenho do descritor máxima diferença na classificação de plantações de eucalipto no estado do Rio de Janeiro. *Revista Brasileira de Cartografia*, v. 71, n. 1, p. 99-121, 2019.

FRAGAL, E. H.; SILVA, T. S. F.; NOVO, E. M. L. M. Reconstructing historical forest cover change in the Lower Amazon floodplains using the LandTrendr algorithm. *Acta Amazonica*, v. 46, n. 1, p. 13-24, 2016.

GOERELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, n. 202, p. 18-27, 2017.

GRIFFITHS, P.; KUEMMERLE, T.; KENNEDY, R. E.; ABRUDAN, I. V.; KNORN, J.; HOSTERT, P. Using annual time-series of Landsat images to assess the effects of forest restitution in post-socialist Romania. *Remote Sensing of Environment*, n. 199, p. 199-214, 2012.

HAY, G. J.; CASTILLA, G. Geographic Object-Based Image Analysis (GEOBIA): a new name for a new discipline. In: *Object-based image analysis*. Berlim: Springer, 2008. p. 75-89.

INDÚSTRIA BRASILEIRA DE ÁRVORES. *Relatório Ibá*. 2017.

KENNEDY, R. E.; YANG, Z.; COHEN, W. B. Detecting trends in forest disturbance and recovery using yearly Landsat time series: 1. LandTrendr – Temporal segmentation algorithms. *Remote Sensing of Environment*, n. 114, p. 2897-2910, 2010.

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

MAUS, V.; CÂMARA, G.; CARTAXO, R.; SANCHEZ, A.; RAMOS, M.; QUEIROZ, G. R. A Time-Weighted Dynamic Time Warping Method for Land-Use and Land-Cover Mapping. *IEEE. Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 9, n. 8, p. 3729-3739, 2016.

MCROBERTS, R. E. Satellite image-based maps: Scientific inference or pretty pictures? *Remote Sensing of Environment*, v. 115, n. 2, p. 715-724, 2011.

OLOFSSON, P. et al. Making better use of accuracy data in land change studies: Estimating accuracy and area and quantifying uncertainty using stratified estimation. *Remote Sensing of Environment*, v. 129, p. 122-131, 2013.

_____; FOODY, G. M.; HEROLD, M.; STEHMAN, S. V.; WOODCOOK, C. E.; WULDER, M.A. Boas práticas para estimar a área e avaliar a precisão da mudança de terreno. *Remote Sensing of Environment*, n.148, p. 42-57, 2014.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. In: *Third ERTS Symposium, Proceedings*, NASA SP-351, NASA, Washington, v. 1, p. 309-317, 1973.

STEHMAN, S. V.; FOODY, G. M. Accuracy assessment. *The SAGE handbook of remote sensing*. Londres: Sage, 2009. p. 297-309.

_____. Estimating area from an accuracy assessment error matrix. *Remote Sensing of Environment*, n. 132, p. 202-211, 2013.

WANG, Q. J. Approximate goodness-of-fit test of fitted generalized extreme value distribution using LH moments. *Water Resources Research*, v. 34, n. 12, p. 3497-3502, 1998.

WECKMÜLLER, R.; VICENS, R.S. Detecção de mudanças florestais em séries temporais utilizando os algoritmos Landtrendr: estudo de caso no estado do Rio de Janeiro. *Revista do Departamento de Geografia*, v. 37, p. 44-57, 2019.

YIN, H.; PRISHCHEPOV, A. V.; KUEMMERLE, T.; BLEYHL, B.; BUCHNER, J.; RADELOFF, V. C. Mapping agricultural land abandonment from spatial and temporal segmentation of Landsat time series. *Remote Sensing of Environment*, n. 210, p. 12-24, 2018.

_____. et al. Monitoring cropland abandonment with Landsat time series. *Remote Sensing of Environment*, v. 246, p. 111873, 2020.

Recebido em: 09/11/2022. Aceito em: 09/01/2023.