

Descritores dinâmicos espectrais e Classificação por abordagem híbrida para estudos de Detecção de Mudanças

Felipe Gonçalves Amaral^{1*}, Carla Bernadete Madureira Cruz², Amanda Beatriz Távora Cardoso³

¹Doutorando em Geografia, Universidade Federal do Rio de Janeiro, Brasil. (*Autor correspondente: f.g.amaral19@gmail.com)

²Professora Titular do Departamento de Geografia, Universidade Federal do Rio de Janeiro, Brasil.

³Graduanda em Ciências Matemáticas e da Terra - Universidade Federal do Rio de Janeiro, Brasil.

Histórico do Artigo: Submetido em: 26/02/2021 – Revisado em: 05/03/2021 – Aceito em: 12/03/2021

RESUMO

As paisagens como conhecemos e vemos estão em constante mudança devido a processos naturais e antrópicos de diferentes magnitudes espaciais e temporais. Para entendermos essas mudanças, elas necessariamente devem ser observáveis ou mensuráveis. Atualmente se coloca o Sensoriamento Remoto como uma das mais modernas formas de monitoramento da paisagem devido a métodos aplicáveis aos seus produtos que permitem análises qualitativas e quantitativas das alterações na paisagem, ocasionadas pelos complexos padrões de uso e ocupação da terra ao longo do tempo. Dentre os muitos métodos de detecção de mudanças há o de detecções automáticas a partir de algoritmos, que simplificam os processamentos e capturam as transformações de forma rápida e sistemática. Assim, o objetivo desse trabalho é entender como se comporta os algoritmos de detecção de mudanças em uma classificação híbrida integrada. Essa classificação será testada usando imagens de mesoresolução como as dos satélites LANDSAT num contexto temporal de 35 anos em 8 datas e espacial que encobre todo o estado do Rio de Janeiro e suas complexidades de cobertura. O trabalho está construído pensando em resolver os problemas metodológicos da construção desses algoritmos, na classificação das mudanças e na exploração desses algoritmos para entender suas vantagens e limitações. Ao fim tem-se que para o estado do rio de Janeiro os descritores do NDBI, SWIR 1 e SWIR 2 são o que melhor nos atendem para a identificação rápida de mudanças de diferentes tipologias na área, onde o melhor estatisticamente e visualmente foi o NDBI.

Palavras-Chaves: Mudanças da Paisagem, Descritores Espectrais, Algoritmos de Mudança, Sensoriamento Remoto.

Dynamic spectral descriptors and Classification by hybrid approach for Change Detection studies

ABSTRACT

The landscapes as we know and see them are constantly changing due to natural and anthropic processes of different spatial and temporal magnitudes. To understand these changes, they must necessarily be observable or measurable. Currently Remote Sensing is considered one of the most modern ways of monitoring the landscape due to methods applicable to its products that allow qualitative and quantitative analysis of changes in the landscape, caused by the complex patterns of land use and occupation over time. Among the many methods of detecting changes, there is automatic detection using algorithms, which simplify processing and capture transformations quickly and systematically. Thus, the objective of this work is to understand how the change detection algorithms behave in an integrated hybrid classification. This classification will be tested using mesoresolution images such as those of the LANDSAT satellites in a 35-year temporal context over 8 dates and a spatial one that covers the entire state of Rio de Janeiro and its coverage complexities. The work is built thinking about solving the methodological problems of the construction of these algorithms, in the classification of changes and in the exploration of these algorithms to understand their advantages and limitations. In the end we have that for the state of Rio de Janeiro the descriptors of NDBI, SWIR 1 and SWIR 2 are the ones that best serve us for the quick identification of changes of different types in the area, where the best statistically and visually was the NDBI.

Keywords: Landscape Changes, Spectral Descriptors, Landscape Change Algorithms, Remote Sensing.

Amaral, F.G., Cruz, C.B.M., Cardoso, A.B.T. (2021). Descritores dinâmicos espectrais e Classificação por abordagem híbrida para estudos de Detecção de Mudanças. Revista Brasileira de Sensoriamento Remoto, v.2, n.1. 026-041 (2021).



Direitos do Autor. A revista utiliza a licença *Creative Commons* - CC Atribuição Não Comercial 4.0 CC-BY-NC.

1. Introdução

As paisagens como conhecemos e vemos todos os dias não são estáticas, elas estão em constante processo de evolução. Essas mudanças são consequência de múltiplos fatores ligados a processos naturais e atividades humanas que exercem pressão sobre esse sistema. Essas transformações constantes podem ocorrer em diferentes escalas de análise, sejam elas espaciais ou temporais (Farina, 2000). Analisando essas mudanças observa-se que os processos naturais que modificam a paisagem estão ligados, em geral, às condições intrínsecas do ambiente em si, questões do equilíbrio ecológico. Já no caso das mudanças por processos antrópicos, as condições estão ligadas às necessidades humanas relacionadas ao seu sistema produtivo. Tendo-se consciência que tanto as condições ambientais como as necessidades humanas se alteram ao longo do tempo, as mudanças que ocorrem na paisagem são ligadas a variáveis complexas que por fim mudam a estrutura e o funcionamento da mesma para atender os condicionantes tanto ambientais, tanto humanos (Antrop 1998; Farina, 2000).

Para entendermos essas mudanças, elas necessariamente devem ser observáveis ou mensuráveis em magnitude, e isso depende do grau de detalhamento espacial e temporal que ocorre a observação (Antrop, 1998), que por fim, condiciona a escolha de recortes espaciais e temporais para estudos (Rhoads; Wilson, 2010). De modo geral, uma mudança pode ser identificada ao se fazer a comparação de pelo menos dois momentos diferentes de uma mesma área, sabendo-se que quanto maior o número de períodos a serem analisados e maior a faixa de tempo, maior e melhor a especificação das dinâmicas que estão ocorrendo nas paisagens.

De acordo com Menke et al. (2009), uma das mais modernas formas de monitoramento das paisagens são os produtos de sensoriamento remoto. Os métodos aplicáveis a produtos de sensores remotos permitem, por exemplo, as análises quantitativas das alterações na paisagem ocasionadas pelos diferentes padrões de uso e ocupação da terra ao longo do tempo, mais conhecidas como detecção de mudanças. Este tipo de análise é aplicado, principalmente, para a compreensão das relações e interações entre as atividades de origem antrópica e os fenômenos naturais que atuam sobre determinado ambiente.

Assim, detecção de mudanças é o processo de identificação de diferenças no estado de um objeto ou fenômeno, observando-o em momentos diferentes (Singh, 1989; Macleod & Congalton, 1998). Esse método é considerado uma forma precisa de identificação e compreensão das alterações das características da superfície terrestre. De acordo como Lu et al. (2004) a detecção de mudanças fornece diversas informações que são úteis para a análise espaço-temporal de uma área, sendo elas: (1) os quantitativos e as taxas de área modificada; (2) distribuição espacial das mudanças; (3) trajetórias das mudanças; e (4) precisão avaliativa da detecção de mudanças. Ainda de acordo com o mesmo autor, um projeto que visa detectar as mudanças possui três etapas: (1) o pré-processamento das imagens (2) seleção de procedimentos adequados para implementar análises de detecção de mudanças e; (3) avaliação de precisão da própria detecção.

Os diversos métodos de detecção de mudança são agrupados em sete categorias segundo Lu et al. (2004); são elas a Álgebra, a Transformação, a Classificação, os Modelos Avançados, as Abordagens com Sistemas de Informação Geográfica, a Análise Visual e por fim os Outros Modelos. O nível de complexidade de cada técnica de detecção está ligado a seu recorte temático, espacial e temporal. Das diversas formas de detecção de mudanças, uma separação entre metodologias pode ser estabelecida também pelo número de imagens utilizadas na comparação: se forem apenas duas imagens, a detecção de mudanças é identificada como bitemporal, se forem utilizadas três ou mais imagens, denomina-se ou detecção multitemporal, ou dependendo da forma de análise, pode-se chegar as trajetórias evolutivas (Coppin et al., 2004).

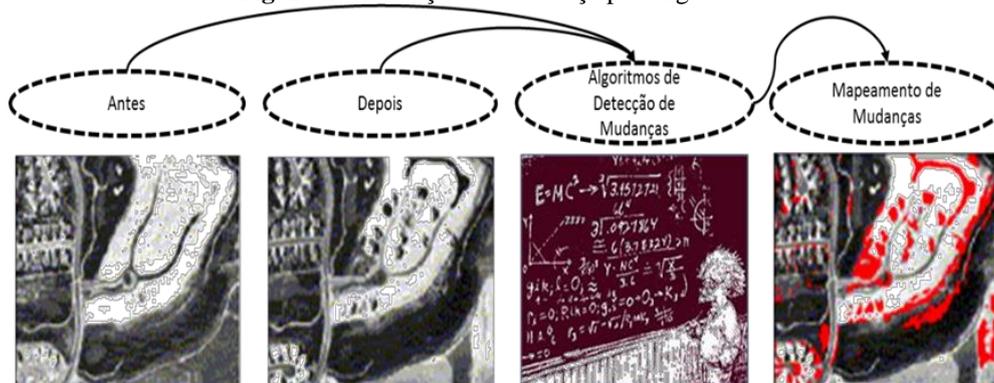
A dimensão temporal influencia profundamente os resultados da detecção de duas formas: tanto pelo tempo entre as capturas das imagens quanto pela época do ano do imageamento. O distanciamento no tempo deve ser entendido como uma função dos objetivos do trabalho, da mesma forma que a escala e detalhamento

espacial, e por isto deve ser adequado à dinâmica das mudanças. Fenômenos naturais de sucessão podem demandar um distanciamento de décadas entre uma imagem e outra, já os impactos do fogo, poucos meses. Quanto às épocas de aquisição, a importância delas está diretamente relacionada à minoração das diferenças na iluminação da cena que podem fazer que o pré-processamento das imagens se tornem mais simples. (Coppin et al., 2004; Rogan et al., 2002; Lu et al., 2004). Não há um espaçamento temporal padrão, pois sua escolha é subordinada ao tipo de mudança e objetivos pesquisados, podendo variar de intervalos curtos (dias, meses ou poucos anos) a intervalos maiores, como é o caso da detecção da regeneração de florestas, quando décadas são necessárias. Assim, o recorte temporal a se usar depende da dinâmica do fenômeno a ser estudado (Dobson et al.; 1995; Coppin et al., 2004; Lu et al., 2004).

A rigor, além do tempo entre imagens, todos os fatores que podem influenciar nos resultados devem ser controlados ao máximo. Independente da metodologia adotada, vários desses fatores controlam uma pesquisa de detecção de mudanças a partir do Sensoriamento Remoto (Lu et al., 2004), como: a precisão da geometria das imagens, a qualidade da calibração ou da normalização dos dados, a disponibilidade de dados de campo, a complexidade do uso e cobertura do solo na área de estudo, o algoritmo de detecção usado, o esquema de classificação criado, a experiência do analista e seu conhecimento acerca da área em estudo e, por fim, as restrições de tempo e de recursos.

Numa detecção integrada, quando se utiliza duas ou mais imagens digitais de diferentes datas em conjunção para o processo de detecção (Figura 1), a escolha do algoritmo não é simples, cada algoritmo possui uma forma própria de lidar com a extração e com a classificação das mudanças. Isso fica claro quando reconhece-se que ao se empregar diferentes algoritmos sobre os mesmos dados, resultados diferentes serão obtidos, o mesmo ocorrerá se um algoritmo for aplicado sobre o mesmo conjunto de dados, mas com variáveis espaciais, espectrais, temporais e temáticas configuradas de forma diferente, donde se pode concluir que não há um algoritmo aplicável para todas as situações (Coppin et al., 2004).

Figura 1 – Detecção de Mudança por Algoritmos.



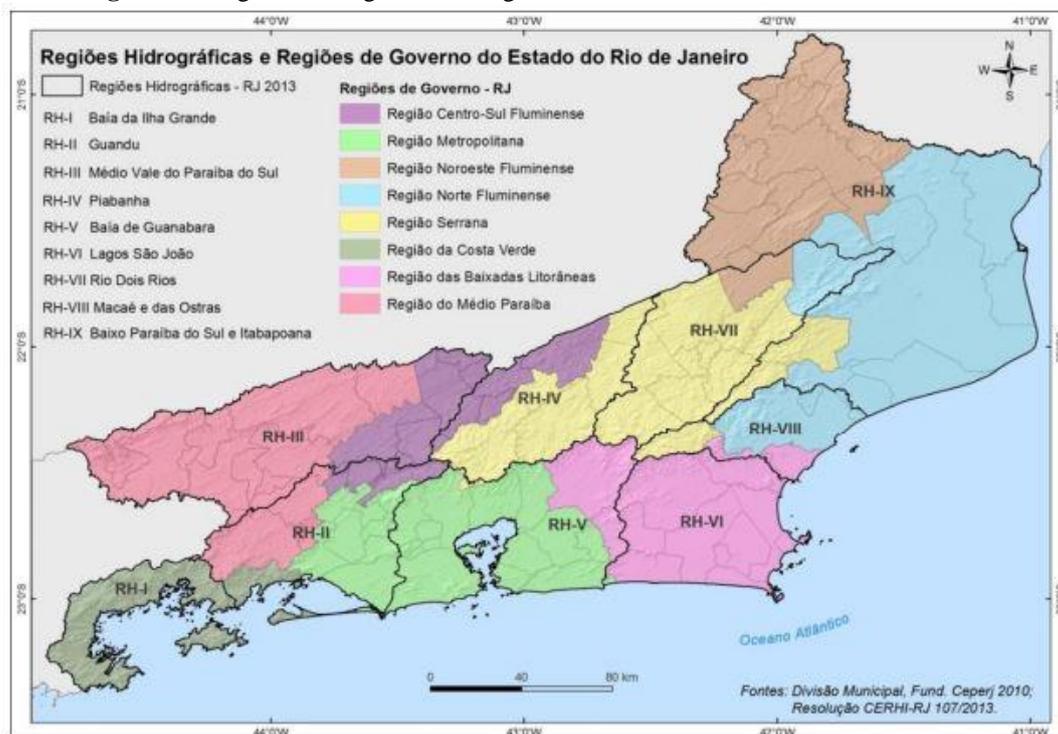
Fonte: Adaptado de Shukka Methods – Change Detection

Portanto, o objetivo desse trabalho é analisar o comportamento de algoritmos de detecção de mudanças em uma classificação híbrida integrada. Essa classificação será testada usando imagens de mesoresolução como as dos satélites LANDSAT num contexto temporal de 35 anos em 8 datas com abrangência total do estado do Rio de Janeiro, Brasil. Para isso o trabalho está construído com o intuito de resolver problemas metodológicos da construção desses algoritmos, na classificação das mudanças e na exploração desses algoritmos para entender suas vantagens e limitações.

2. Área de Estudo

Como explanado anteriormente, o trabalho se dará em toda área do estado do Rio de Janeiro, unidade federativa situada na região sudeste brasileiro. O estado possui uma complexidade natural e socioeconômica que está ligada diretamente com sua diversidade paisagista e transformações recentes. Há diversas regionalizações do estado, duas delas estão em destaque na Figura 2 apresentada abaixo. As divisões hidrográficas nos ajudam a entender as dinâmicas naturais da área que influenciam diretamente na cobertura e uso do solo do mesmo. Já as divisões de governo facilitam a forma de pensar o estado em sistemas naturais e econômicos complexos.

Figura 2 – Regiões Hidrográficas e Regiões de Governo do estado do Rio de Janeiro



Fonte: SEA/INEA

O relevo e o clima do estado interagem estreitamente e atuam diretamente na formação e disponibilidade dos recursos naturais e econômicos, característicos de cada região. No relevo do território fluminense, destaca-se a presença de duas grandes serras, a Serra do Mar, que separa as regiões hidrográficas ao norte das setentrionais e a Serra da Mantiqueira, essa última presente exclusivamente na Região do Médio Paraíba, entre essas duas serras, desenvolve-se a bacia do rio Paraíba do Sul.

O Rio de Janeiro tornou-se um estado essencialmente urbano, seguindo uma tendência histórica definida há mais de meio século. De acordo com os Censos Demográficos do IBGE, em 1950 a população urbana do estado já correspondia a 73% da população total. Em 2010, com cerca de 16 milhões de habitantes, 97% estão concentrados em cidades, observa-se que as áreas urbanas da RH-II, da Região Serrana (RHs IV e VII) e da faixa litorânea da RH-VI se expandem atreladas à expansão da Região Metropolitana em torno da Baía de Guanabara (RH-V) (SEA/INEA, 2018). As pastagens distribuem-se por todo o estado, ocupando mais de 50% das Regiões Hidrográficas, com exceção da RH-I, onde o relevo, montanhoso em maior parte, praticamente impede essa forma de uso, e com exceção da RH-V, onde o uso agropecuário perde espaço para a expansão da

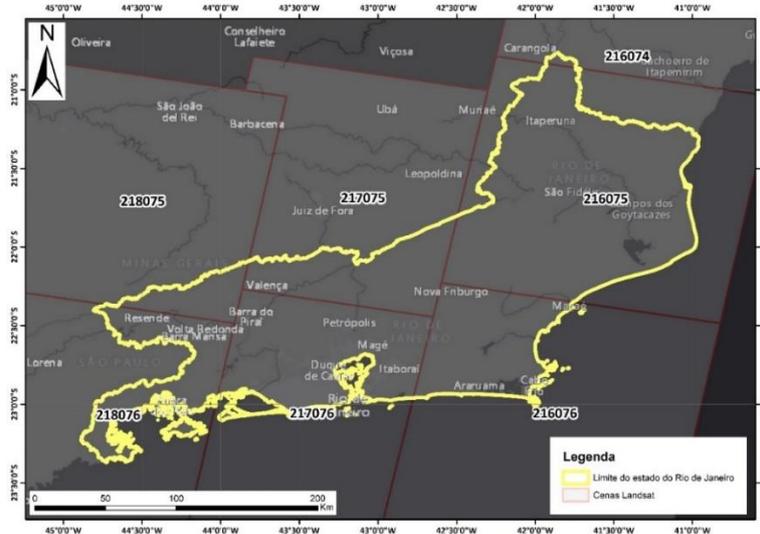
Região Metropolitana (SEA/INEA, 2018).

Essas características geomorfológicas e de distribuição dos usos do solo, caracterizam as mudanças recentes do estado estudadas nesse artigo. Dessa forma essas regionalizações foram usadas para a identificação das ocorrências e o entendimento da situação geográfica dessas transformações.

3. Material e Métodos

Em atendimento às demandas de estudos de longas séries temporais em áreas de grande abrangência, optou-se, neste trabalho, pelo uso de imagens Landsat. Os sensores desta série de satélites apresentam resoluções espectrais e espaciais adequadas a classificações de média escala, devendo-se ressaltar ainda que as imagens são gratuitas e de fácil acesso. As imagens foram obtidas através do Catálogo de Imagens do USGS, seguindo alguns pré-requisitos: i) a menor porcentagem de nuvens possível; ii) os meses de imageamento foram de maio a setembro - em virtude da menor umidade relativa do ar e menor nebulosidade e; iii) margem de ± 1 ano para aquisição das imagens - devido à dificuldade de aquisição frente aos critérios anteriores. Assim, as datas para aquisição foram: 1985 ± 1 , 1990 ± 1 , 1995 ± 1 , 2000 ± 1 , 2005 ± 1 , 2010 ± 1 e 2015 ± 1 e 2018, o que resultam em 56 imagens para cobrir todo recorte espacial e temporal de estudo (Figura 3).

Figura 3 – Articulação de Imagens Landsat no estado do Rio de Janeiro



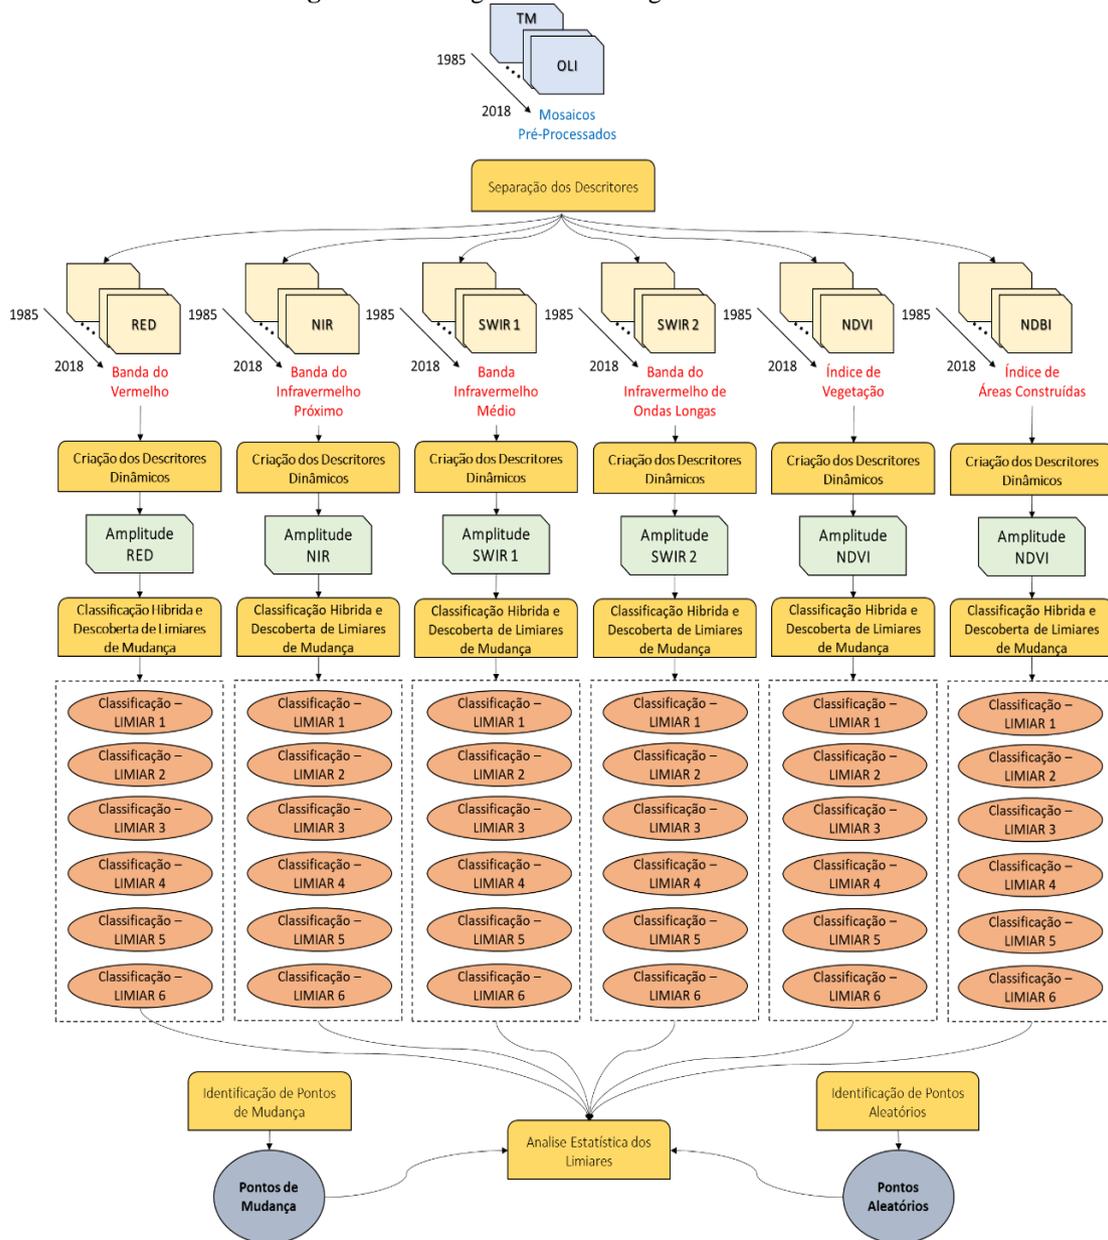
Fonte: Elaborada pelos autores

O estudo apresentado nesse trabalho começa a partir de mosaicos pré-processados. Como o mostrado em Lu et al. (2010), o pré-processamento é importante quando pensamos em classificações integradas e algoritmos de detecção de mudanças. Por esse motivo foram realizadas a correção atmosférica, a compatibilização e normalização radiométrica e por fim a mosaicagem, adaptadas de Abreu (2018), Fernandes et al. (2017) e Amaral (2015) e demonstradas em Amaral (2019a e 2019b) e Weckmüller & Vicens (2016).

A partir dos 8 mosaicos pré-processados foi realizada a metodologia desse trabalho. Primeiramente, a criação de descritores dinâmicos e uma classificação de legenda simples de mudança e não mudança a partir de métodos híbridos e, por fim, sua validação a partir de uma análise estatística. De forma sucinta, o método é apresentado no fluxograma da Figura 4. Devido aos complexos padrões de mudanças na paisagem, e seus registros espectrais, selecionar um algoritmo adequado para uma análise espaço-temporal específica não é tarefa trivial. Algumas técnicas, como a diferenciação de imagens, podem fornecer informações sobre mudança

/ não mudança ou padrões simples, enquanto outras técnicas, como a comparação de classificações temáticas, podem fornecer uma matriz completa de trajetórias de mudança (Lu et al. 2010). A abordagem escolhida para esse trabalho foi a de classificação, onde a técnica específica é a de classificação híbrida, que consiste no uso de atributos relativos ao pixel ou objeto geográfico - associado a Classificação Orientada a Objetos Geográfico (Weckmüller & Vicens, 2016). Por conta do uso de valores extraídos dos pixels, foi necessário o uso de técnicas da abordagem de álgebra de imagens para a criação dos descritores temporais que melhor se ajustem às classes dinâmicas propostas.

Figura 4 – Fluxograma Metodológico do Trabalho



Fonte: Elaborada pelos autores

3.1. Descritores Dinâmicos de Mudança

Interpreta-se como descritor dinâmico, a variável que consegue descrever a dinâmica da cobertura de modo que possamos entender suas transformações ao longo do tempo, como por exemplo a dinâmica urbana ou a dinâmica dos oceanos. Unindo essa ideia ao sensoriamento remoto podemos conceber que os descritores dinâmicos são as variáveis que nos indicam a dinâmica de alvos a partir de suas características espectrais ao longo do tempo. Assim, pode-se haver descritores dinâmicos de diferentes conjunturas, mas que precisam de uma componente temporal intrínseca a ele. Essa componente temporal pode ser dada pela aritmética básica entre as imagens de uma mesma área em momentos diferentes, como soma ou divisão da resposta dos pixels dessas mesmas imagens. Essas variáveis podem ser simples como as próprias bandas espectrais das imagens ou mais complexas como os índices radiométricos.

Os índices radiométricos são medidas capazes de identificar e realçar em imagens de satélites determinados tipos de informações, tais como áreas edificadas, cobertura vegetal, cursos d'água, solo exposto, entre outros, além da normalização contribuir na redução de ruídos e efeitos de iluminação. Esses índices também fornecem parâmetros capazes de detectar e separar alvos compostos de materiais diferentes. Muitos deles foram criados para fins distintos e específicos. Para esse trabalho os índices radiométricos usados foram os índices normalizados de vegetação e de áreas construídas, respectivamente, NDVI (*Normalized Difference Vegetation Index*) (Rouse et al., 1974) e NDBI (*Normalized Difference Built-Up Index*) (Zha et al., 2003), respectivamente apresentados na Equação 1 e 2.

$$NDVI = \frac{(NIR-RED)}{(NIR+RED)} \text{ Eq. 1}$$

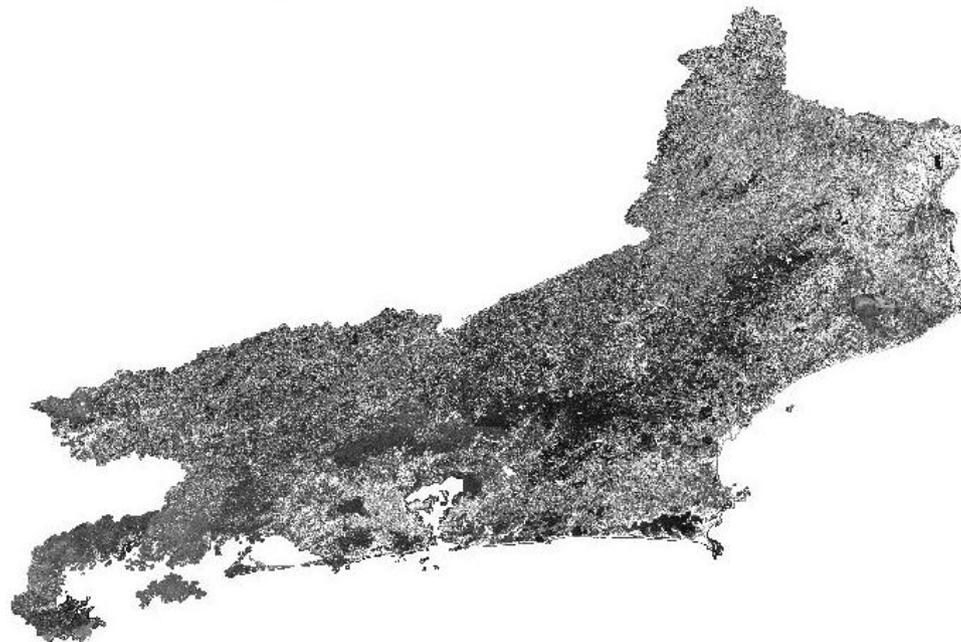
$$NDBI = \frac{(SWIR\ 2-NIR)}{(SWIR\ 2+NIR)} \text{ Eq. 2}$$

A álgebra de imagens digitais como uma forma de criação de algoritmos de detecção de mudanças se apresenta de acordo com Lu et al. (2010) pela aritmética de imagens, regressão de imagens, razão de imagens, aritmética de índices de radiométricos, análise de mudança de vetor (CVA) e subtração de fundo. Esses algoritmos são relativamente simples, fáceis de implementar e interpretar. A Aritmética básica de bandas ou índices radiométricos é uma formulação algorítmica de processamento de imagens que pode apresentar resultados expressivos. Considerado um processo bastante rápido para ajustar e suavizar imagens muito ruidosas ou ainda, para se obter realces de toda a área de uma imagem ou de alvos específicos. O processo de transformação é executado pixel a pixel por meio de uma regra matemática pré-definida envolvendo, normalmente, no mínimo duas bandas do mesmo sensor ou bandas de datas de aquisição diferentes. Dependendo da operação, ela se apresenta como um recurso para reduzir o número de imagens, o que é uma vantagem em termos de armazenamento e processamento.

Para fins de descritores dinâmicos, a subtração de imagens é uma operação de grande recurso prático, que pode também se apresentar como a amplitude de imagens quando os intervalos de observação da paisagem são maiores que dois momentos distintos (Weckmüller & Vicens, 2016). já que a amplitude é uma medida de dispersão que nos dá a diferença entre o valor máximo e o valor mínimo num conjunto de imagens. Com isso a partir das bandas do Vermelho (RED), Infravermelho Próximo (NIR) e as duas bandas do Infravermelho de Ondas Curtas (SWIR 1 e SWIR 2), além dos índices radiométricos NDVI e NDBI dos oito mosaicos foram criadas imagens amplitude para cada uma das bandas e índices. Essa amplitude foi calculada de pixel a pixel para cada imagem, registrando a diferença entre os maiores e menores valores (de cada pixel ao longo do tempo), dando origem a seis descritores dinâmicos que a partir de seus valores podem representar as dinâmicas do recorte espacial durante todo o recorte temporal de estudo (Figura 5). Na figura, os valores escuros representam os valores mais baixos (próximos a 0) e podem ser interpretados como áreas de não mudança, já

os valores mais claros representam as áreas de mudança.

Figura 5 – Amplitude da Banda do Vermelho



Fonte: Elaborada pelos autores

3.2. Abordagem híbrida - do Pixel ao Objeto

Com os descritores dinâmicos devidamente construídos, passou-se para a fase de classificação digital onde se utilizou o software *eCognition Developer* um software consagrado pela sua diversidade de opções em projetos usando GEOBIA (Classificação baseadas em Objetos Geográficos). A abordagem GEOBIA, traz vantagens em relação aos modelos tradicionais de classificação de imagens (por pixel), justamente pela consideração das regiões de pixels, ao invés de pixels isolados. Deste modo, descreve-se cada região de acordo com as características do objeto como área, altura, largura, densidade, altura da borda, textura, relações entre objetos vizinhos, entre outros (Hay & Castilla, 2008). Através do GEOBIA, obtém-se um aumento significativo no número de variáveis que podem ser consideradas na classificação, pois esta não se fundamenta exclusivamente em informações espectrais.

A abordagem de classificação híbrida, consiste no uso de produtos provenientes de álgebra dos pixels das imagens originais, para a construção de objetos geográficos a partir de uma segmentação única, onde esses objetos herdam as características das imagens processadas no nível do pixel (Jianya et al., 2008). Essa abordagem se caracteriza pela vantagem de ser possível a adoção de diferentes atributos dos objetos da imagem e dos realces de descritores espectrais que auxiliam na extração de informações para a construção de modelos de classificação. Nesse caso, a geração dos objetos geográficos foi efetuada somente com as imagens realçadas dos descritores criados.

Inseriu-se no projeto as seis imagens de amplitude para a realização do processamento e classificação, além dos mosaicos de 1985 e 2018 para análises visuais. Para a criação dos objetos geográficos, foram testadas segmentações em diferentes níveis no sistema *eCognition* para seleção do melhor ajuste de escala dos objetos. O processo de segmentação subdivide uma imagem em agrupamentos de pixels contínuos que apresentam uniformidade de resposta segundo determinados critérios, chamados segmentos. O nível de abrangência e de

detalhe que os segmentos devem alcançar é uma das complexidades que deve ser tratada. Uma segmentação é adequada a um projeto quando os objetos de interesse tiverem sido delimitados em segmentos representativos, normalmente por critérios de forma e/ou resposta espectral.

Neste trabalho, segmentação foi feita considerando as imagens amplitudes criadas anteriormente e inseridas no programa. A melhor segmentação atribuída foi realizada através do algoritmo *Multiresolution Segmentation* com os parâmetros: fator de escala 40, forma 0.1 e compacidade 0.5. Os resultados foram alcançados de forma heurística e comparados a partir de avaliação visual. Para a análise da segmentação considerou-se não só objetos distintos no espaço, mas também no tempo, visto que o estudo considera uma análise temporal integrada. Em outras palavras, como foram usadas imagens de amplitude dos índices e das bandas ao longo do recorte temporal, o que se segmenta são objetos ao longo do espaço e do tempo, só se fazendo realmente útil para classificações multitemporais. Assim, os objetos criados a partir da segmentação tem como característica a dinâmica no intervalo de tempos estudado.

3.3. Análise Exploratória de Descritores Dinâmicos

Como o objetivo desse trabalho é identificar e entender como cada descritor se comporta como uma variável de detecção de mudança, uma chave de interpretação mais simples foi construída dando origem a duas classes. Assim, em um primeiro momento, o objetivo foi a separação das classes de **MUDANÇA** e **NÃO MUDANÇA**, onde se propôs de forma heurística e exploratória, fazer a descoberta do melhor descritor e limiar de mudança a serem adotados. Nessa análise exploratória, para cada descritor foram impostos seis limiares que classificariam as mudanças, sendo a não-mudança atribuída, de forma complementar, às áreas não classificadas. Os 36 limiares representam o conjunto resultante da consideração das abordagens encontradas em Amaral (2019b) e Abreu (2018), acrescido de novos limiares, de valores relativamente próximos aos já considerados para a exploração de novos testes num contexto diferente dos trabalhos citados.

Foram geradas 36 classificações objetivando a identificação de mudanças abruptas da cobertura, como o desmatamento, expansão urbana entre outras. É possível observar (Figura 6) que todos os limiares apresentados e testados são relativamente próximos de 0, já que hipoteticamente uma imagem que não sofreu mudanças durante um período de tempo deve ter respostas espectrais semelhantes ou quase idênticas em todas as datas, o que faz com que suas diferenças fiquem próximas de 0. Nas amplitudes dos índices radiométricos além de 0, uma área de não mudança, também pode estar representada por valores próximos a 2, devido aos valores negativos que esses índices possuem, logo nesses casos como mostrado na Figura 6, foram construídos dois modelos unidos.

O processo de verificação da exatidão das classificações de cada descritor foi realizado de duas maneiras. O primeiro foi através do método de pontos aleatórios para a análise quantitativa de acertos e erros para cada descritor. Ao todo foram gerados 1000 pontos que foram identificados através da análise visual dos mosaicos de cada data, como mudança ou não mudança. Já o segundo método de validação desses descritores foi a identificação e coleta de pontos de mudança em toda a imagem. Mesmo que trabalhoso, optou-se por dois métodos de validação em virtude do receio de que o primeiro método mascarasse os resultados da validação pela predominância de áreas de não mudança no recorte de estudo. Dessa forma, o uso concomitante do método por pontos aleatórios e por pontos já identificados como mudança, dá maior segurança no estabelecimento do melhor descritor.

Ao fim desse processo de coleta e identificação dos pontos, comparou-se os mesmos com as classificações obtidas a partir de cada descritor e seus respectivos limiares. Considerou-se como melhor resposta, o descritor que apresentasse: i) a maior Média Geral, dada pela média entre a porcentagem de acertos gerados pelos pontos aleatórios e os pontos de mudança e; ii) o menor Desvio Padrão entre os resultados dos dois métodos.

Figura 6 – Descritores e Limiares de Mudança

Amplitude NDBI	{	LIMIAR 1 - 0,3 < Mudança < 1,7 LIMIAR 2 - 0,4 < Mudança < 1,6 LIMIAR 3 - 0,5 < Mudança < 1,5 LIMIAR 4 - 0,35 < Mudança < 1,65 LIMIAR 5 - 0,42 < Mudança < 1,58 LIMIAR 6 - 0,45 < Mudança < 1,55	Descritores feitos a partir de índices radiométricos normalizados possuem valores de 0 a 2	
Amplitude NDVI	{	LIMIAR 1 - 0,3 < Mudança < 1,7 LIMIAR 2 - 0,4 < Mudança < 1,6 LIMIAR 3 - 0,5 < Mudança < 1,5 LIMIAR 4 - 0,32 < Mudança < 1,68 LIMIAR 5 - 0,35 < Mudança < 1,65 LIMIAR 6 - 0,37 < Mudança < 1,63		
Amplitude NIR	{	LIMIAR 1 - 1000 < Mudança LIMIAR 2 - 1300 < Mudança LIMIAR 3 - 1400 < Mudança LIMIAR 4 - 1500 < Mudança LIMIAR 5 - 1600 < Mudança LIMIAR 6 - 2000 < Mudança		
Amplitude RED	{	LIMIAR 1 - 500 < Mudança LIMIAR 2 - 750 < Mudança LIMIAR 3 - 800 < Mudança LIMIAR 4 - 850 < Mudança LIMIAR 5 - 900 < Mudança LIMIAR 6 - 950 < Mudança		Descritores feitos a partir de bandas espectrais possuem valores de 0 a 56536
Amplitude SWIR 1	{	LIMIAR 1 - 1000 < Mudança LIMIAR 2 - 1100 < Mudança LIMIAR 3 - 1200 < Mudança LIMIAR 4 - 1300 < Mudança LIMIAR 5 - 1400 < Mudança LIMIAR 6 - 1500 < Mudança		
Amplitude SWIR 2	{	LIMIAR 1 - 1000 < Mudança LIMIAR 2 - 1100 < Mudança LIMIAR 3 - 1300 < Mudança LIMIAR 4 - 1500 < Mudança LIMIAR 5 - 1550 < Mudança LIMIAR 6 - 1600 < Mudança		

Fonte: Elaborada pelos autores

4. Resultados e Discussão

Os valores encontrados na análise exploratória são explicitados abaixo pela Tabela 1, que os apresenta em porcentagem de acertos dos dois métodos de validação, sua média aritmética e seu desvio padrão. Sintetizando a análise temos marcados em amarelo os melhores limiares para cada um dos descritores e em verde o melhor limiar do melhor descritor considerando a média e desvio padrão entre todos os outros.

Tabela 1 – Valores de Validação dos Descritores e Limiares

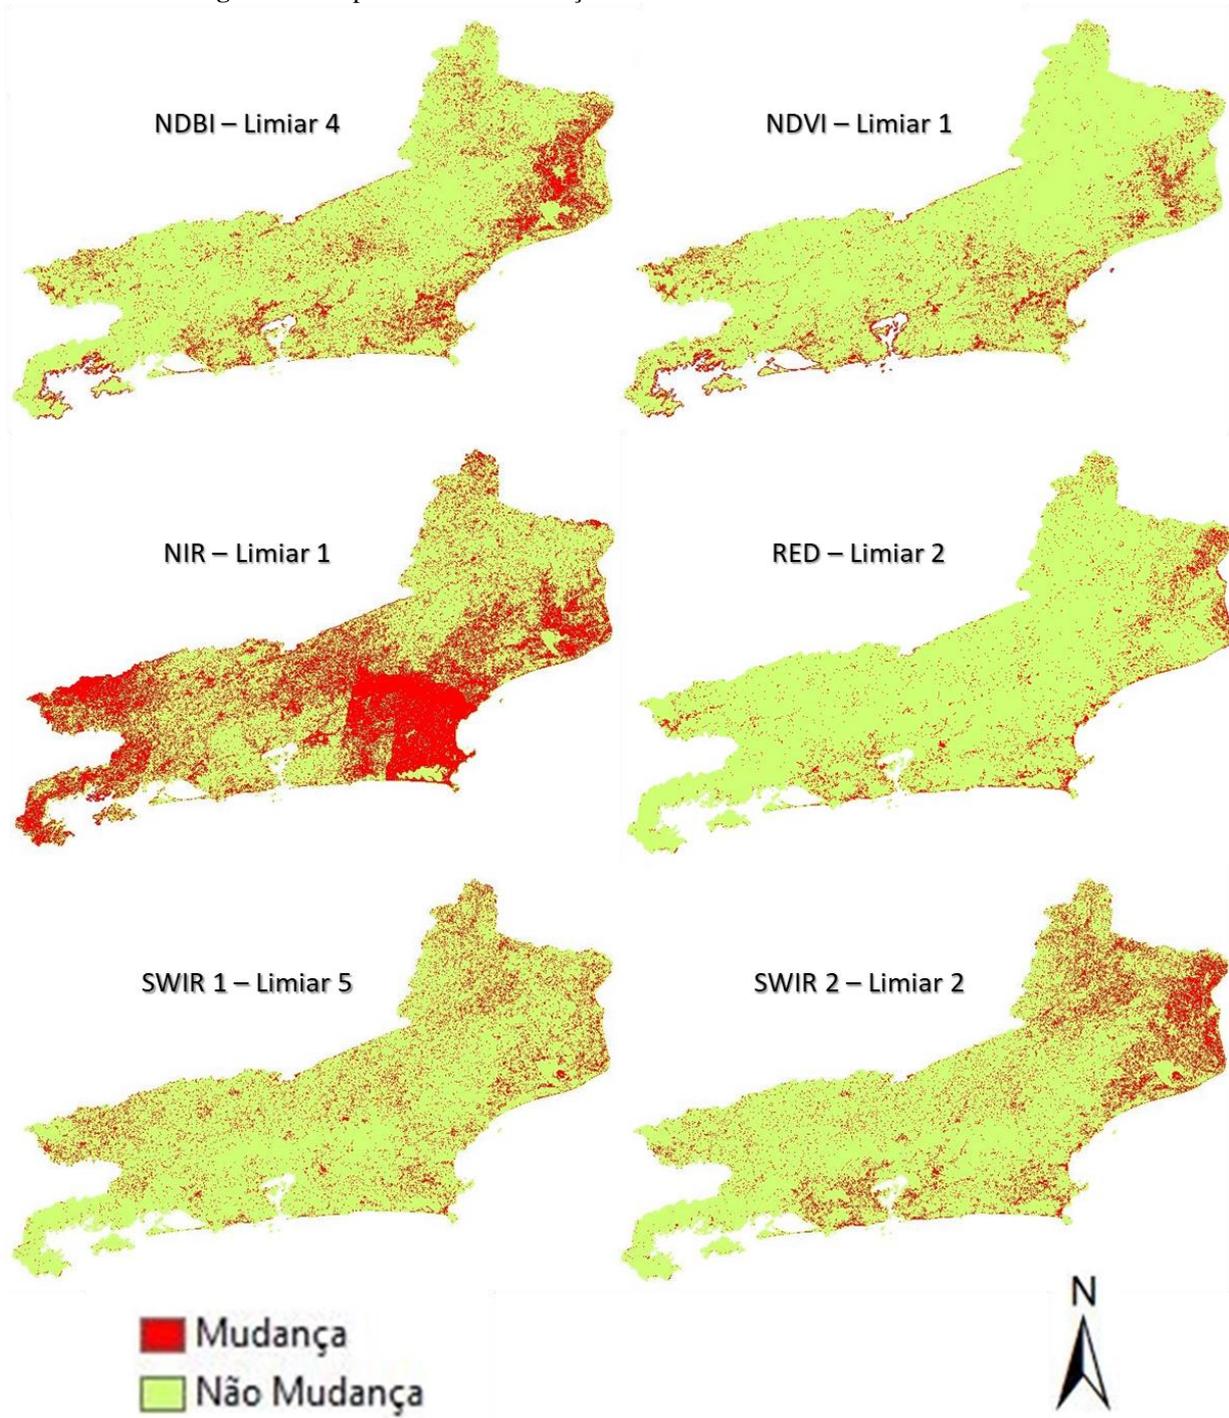
Limiares	Aleatórios (%)	Mudanças (%)	Média Geral (%)	Desvio Padrão
NDBI - Limiar 1	67,4	90,0	78,7	16,0
NDBI - Limiar 2	90,4	68,0	79,2	15,8
NDBI - Limiar 3	97,3	46,0	71,6	36,3
NDBI - Limiar 4	82,5	82,0	82,3	0,4
NDBI - Limiar 5	92,3	66,0	79,1	18,6

NDBI - Limiar 6	94,0	57,0	75,5	26,1
NDVI - Limiar 1	90,5	73,0	81,7	12,3
NDVI - Limiar 2	96,4	49,0	72,7	33,5
NDVI - Limiar 3	98,5	19,0	58,7	56,2
NDVI - Limiar 4	92,6	64,0	78,3	20,2
NDVI - Limiar 5	94,7	60,0	77,3	24,5
NDVI - Limiar 6	95,5	57,0	76,2	27,2
NIR - Limiar 1	62,4	69,0	65,7	4,7
NIR - Limiar 2	81,2	40,0	60,6	29,1
NIR - Limiar 3	85,2	37,0	61,1	34,1
NIR - Limiar 4	89,1	28,0	58,6	43,2
NIR - Limiar 5	96,8	10,0	53,4	61,4
NIR - Limiar 6	97,3	10,0	53,6	61,7
RED - Limiar 1	70,9	86,0	78,4	10,7
RED - Limiar 2	92,8	69,0	80,9	16,8
RED - Limiar 3	94,5	66,0	80,2	20,1
RED - Limiar 4	95,7	62,0	78,8	23,8
RED - Limiar 5	96,7	54,0	75,3	30,2
RED - Limiar 6	97,5	51,0	74,2	32,9
SWIR 1 - Limiar 1	56,7	91,0	73,8	24,3
SWIR 1 - Limiar 2	65,8	87,0	76,4	15,0
SWIR 1 - Limiar 3	73,4	83,0	78,2	6,8
SWIR 1 - Limiar 4	81,1	77,0	79,1	2,9
SWIR 1 - Limiar 5	87,0	73,0	80,0	9,9
SWIR 1 - Limiar 6	91,1	66,0	78,5	17,7
SWIR 2 - Limiar 1	77,2	82,0	79,6	3,4
SWIR 2 - Limiar 2	84,1	78,0	81,1	4,3
SWIR 2 - Limiar 3	91,6	67,0	79,3	17,4
SWIR 2 - Limiar 4	95,9	52,0	73,9	31,0
SWIR 2 - Limiar 5	96,4	48,0	72,2	34,2
SWIR 2 - Limiar 6	96,7	45,0	70,8	36,5

Fonte: Elaborada pelos autores

O infravermelho próximo (NIR) foi o descritor que apresentou o pior resultado dentre os descritores analisados. Sugere-se algumas razões para o fato desse descritor, de uso clássico, não ter se mostrado eficaz na detecção de mudanças. Primeiro, pela sua alta sensibilidade a pequenas mudanças na coloração/tonalidade de áreas vegetadas, sejam elas florestas ou gramíneas/áreas agropastoris. Como mais de 80% do estado do Rio de Janeiro apresenta estes tipos de cobertura, identificou-se uma superestimação das áreas de mudança, trazendo resultados não satisfatórios para a detecção de mudanças abruptas. Desta forma, como observado em Amaral (2019b) índices de alta sensibilidade a mudanças deve ser usados de forma cuidadosa e ajustada ao que se quer medir. Outro problema observado e que é possível visualizar na Figura 7, é que o NIR foi o único descritor que apresentou sensibilidade ao mosaico das imagens, o que piorou ainda mais seus resultados, principalmente na RHVI (Lagos São João).

Figura 7 – Mapeamento de Mudanças dos Descritores e seus melhores limiares



Fonte: Elaborada pelos autores

Em contrapartida, o descritor NDVI apresentou resultados muito bons, principalmente quando falamos dos pontos aleatórios. Nesse caso o descritor prova o quão importante são os índices normalizados para a redução de ruídos causados por processamentos e, também mostra o quão importante foi o segundo método de validação para reduzir o mascaramento de resultados. De forma geral, através da análise visual é possível perceber que o NDVI, como praticamente todos os outros descritores, superestimou a legenda mudança nas áreas de gramínea/agropastoris, provavelmente por serem construídos, em parte, pelo NIR, fazendo com que a mudança de coloração dessas áreas fosse capturada. Além desse problema, o NDVI, como já esperado, superestima as áreas de mudança devido ao sombreamento topográfico ou mudança de exuberância das áreas florestadas. Todos esses aspectos fazem com que ele não seja um bom descritor para se trabalhar com as mudanças abruptas da floresta, mas sim mudanças cíclicas, como é o caso da exposição climática, degradação entre outros. Mesmo apresentando bons resultados, o NDVI não teve os melhores, de acordo com as análises visuais e estatísticas.

Outro descritor que apresentou resultados satisfatórios foi o NDBI, além de ter tido o melhor limiar de mudança, todos os seus valores médios foram acima de 70%, o que o identifica como ótimo descritor. Seu melhor limiar avaliado foi o que teve menor desvio padrão (0,4) entre todos os demais. Através de uma análise visual dos resultados apresentados na Figura 7, é possível observar que, da mesma forma que o NDVI, o NDBI também superestima a classificação de mudança em áreas agrícolas ou de vegetação rasteira que se encontram na RHIX do estado, provavelmente devido ao seu alto poder de realce para áreas de solo exposto, por exemplo. Outra característica semelhante ao NDVI é o seu poder de diminuir os ruídos que poderiam ter sido causados pela banda do NIR. É possível analisar em detalhe na Figura 8 como o melhor limiar do descritor se comporta.

O quarto descritor analisado foi o RED (banda do vermelho), que teve valores médios muito parecidos com o NDVI e o NDBI, o que o coloca também como um descritor bom para a detecção de mudanças. A única diferença nos resultados estatísticos foi que para o seu melhor limiar o descritor respondeu muito bem para a validação dos pontos aleatórios, mas não muito bem para os pontos de mudança, aumentando assim seu desvio padrão, o que gera problemas para a natureza dessa pesquisa que tem como objetivo geral o monitoramento de alvos. Quando passamos para as análises visuais verifica-se que o RED, diferente dos outros descritores, não superestima mudanças nas áreas agrícolas e, mas superestima as mudanças em áreas de solo exposto, como dunas e restingas e subestima mudanças em áreas florestadas. Isso corrobora com pesquisas anteriores Amaral (2019b) onde o descritor se apresenta mais eficaz nas análises de cobertura antrópica.

O SWIR 1 assim como o NDVI e o NDBI alcançou resultados aceitáveis e desvio padrão baixo, o que significa uma maior estabilidade de erros na validação entre os pontos aleatórios e os pontos de mudança. Na análise visual do descritor verifica-se que esse não superestima as mudanças em nenhuma área específica e é eficaz para análises de expansão e adensamento urbano. Outra potencialidade é que, diferente do RED, foi sensível à identificação de mudanças em áreas florestadas. Um dos problemas observados nesse descritor são as mudanças em áreas de sombreamento, que gera erros devido a problemas de topografia entre as imagens. Nesse caso específico, essas classificações errôneas se deram em áreas de morrotes no Vale do Paraíba.

Por fim, o último descritor analisado foi o SWIR 2. Esse descritor apresentou resultados muito bons, com o melhor limiar alcançando mais de 80% de acerto e um baixo desvio padrão (4,3). Pode-se observar que seus demais limiares tiveram valores baixos, principalmente quando nos pontos de mudança. Uma preocupação foi o fato de os resultados não apresentarem estabilidade para os diferentes limiares, o que faz com que seja necessário intensificar a análise dos mesmos para outras áreas. Nesse caso específico, foi que o limiar que responde da melhor forma é o único que pode ser usado para a detecção de mudanças, diferente do que vimos por exemplo no caso do NDBI. Após análise visual dos resultados, observou-se que os padrões são parecidos com os do NDBI por superestimar as mudanças nas áreas de pastagem e agricultura na RHIX, ser um ótimo descritor para estudos de adensamento e expansão urbana e retratar bem as mudanças nas áreas florestadas, o que corrobora com as análises encontradas em Abreu (2018).

7. Observações

O presente trabalho foi a conversão em artigo conciso de um dos capítulos da dissertação de mestrado do autor principal.

8. Referências

ABREU, Marcelo Bueno. Contribuição metodológica para detecção de mudança em cobertura florestal em mesoescala. **Tese (doutorado)** - UFRJ. 2018.

AMARAL, F. G. Análise espaço-temporal e trajetória evolutiva da mata atlântica através de imagens orbitais entre 1985 e 2018 no estado do Rio de Janeiro. Dissertação de Mestrado. Geografia – UFRJ. 2019a

AMARAL, Felipe Gonçalves; CRUZ, C. B. M.; da SILVA, C. B.; de ALMEIDA, P. M. M. Processamento digital de imagens para estudos de dinâmicas da paisagem. **Revista Tamoios**, [S.l.], v. 15, n. 2, dez. 2019. ISSN 1980-4490. doi: <https://doi.org/10.12957/tamoios.2019.45399>, 2019b

AMARAL, F. G.; ABREU, M. B. ; CRUZ, C. B. M. . Pré-processamento de imagens orbitais visando o estudo de detecção de mudanças. In: III Jornada de Geotecnologias do Estado do Rio de Janeiro, 2015, Rio de Janeiro. **Anais / III Jornada de Geotecnologias do Estado do Rio de Janeiro**. Rio de Janeiro: GEOPARTNERS, p. 301-311, 2015

ANTROP, Marc. Landscape change: Plan or chaos? **Landscape and urban planning**, v. 41, n. 3-4, p. 155-161, 1998.

COPPIN, Pol; JONCKHEERE, I.; NACKAERTS, K.; MUYS, B.; LAMBIN, E. Review Article Digital change detection methods in ecosystem monitoring: a review. **International journal of remote sensing**, v. 25, n. 9, p. 1565-1596, 2004.

DOBSON, M. Craig; ULABY; FAWWAZ T.; PIERCE, Leland E. Land-cover classification and estimation of terrain attributes using synthetic aperture radar. **Remote sensing of Environment**, v. 51, n. 1, p. 199-214, 1995.

FARINA, Almo. The cultural landscape as a model for the integration of ecology and economics. **BioScience**, v. 50, n. 4, p. 313-320, 2000.

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

JIANYA, Gong; Haigang, S.; Guorui, M.; Qiming, Z. A review of multi-temporal remote sensing data change detection algorithms. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 37, n. B7, p. 757-762, 2008.

LU D.; MAUSEL, P.; BRONDIZIO, E.; MORAN, E. Change detection techniques. **International Journal of Remote Sensing**, v. 25, pp. 2365-2407, 2004.

MACLEOD, Robb D.; CONGALTON, Russell G. A quantitative comparison of change-detection algorithms

for monitoring eelgrass from remotely sensed data. **Photogrammetric engineering and remote sensing**, v. 64, n. 3, p. 207-216, 1998.

MENKE, Aline Brignol; CARVALHO JUNIOR, Osmar Abílio de; GOMES, Roberto Arnaldo Trancoso; MARTINS, Éder de Souza; OLIVEIRA, Sandro Nunes de. Análise das mudanças do uso agrícola da terra a partir de dados de sensoriamento remoto multitemporal no município de Luis Eduardo Magalhães (BA-Brasil). **Soc. nat. (Online)**, Uberlândia, v. 21, n. 3, p. 315-326, Dec. 2009.

RHOADS, Bruce L.; WILSON, David. Observing our world. GOMEZ, Basil; JONES III, John Paul (Ed.). **Research methods in geography: A critical introduction**. p. 26-40, 2010.

ROGAN, John; FRANKLIN, Janet; ROBERTS, Dar A. A comparison of methods for monitoring multitemporal vegetation change using Thematic Mapper imagery. **Remote Sensing of Environment**, v. 80, n. 1, p. 143-156, 2002.

ROUSE, J.W.; HAAS, R.H.; SCHELL, J.A.; DEERING, D.W. Monitoring vegetation system in the great plains with ERTS. In **Proceedings of the Third Earth Resources Technology Satellite-1 Symposium**; Greenbelt, USA; NASASP-351, 1974; pp. 3010–3017.

SEA / INEA. **Projeto de Mapeamento da Cobertura da Terra e de Detecção de Mudanças na Cobertura Florestal do Estado do Rio de Janeiro**. Fundação COPPETEC - Laboratório Espaço de Sensoriamento Remoto e Estudos Ambientais. Rio de Janeiro. 2018.

SINGH, Ashbindu. Review article digital change detection techniques using remotely-sensed data. **International journal of remote sensing**, v. 10, n. 6, p. 989-1003, 1989.

WECKMÜLLER, Rômulo; VICENS, Raúl Sánchez. Método híbrido de detecção de mudanças: uma associação entre classificação baseada em objetos e baseada em pixels. **Revista Brasileira de Cartografia**, v. 68, n. 5, 2016.

ZHA, Yong; GAO, Jay; NI, Shaoxiang. Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. **International journal of remote sensing**, v. 24, n. 3, p. 583-594, 2003.