



ÁLVARO SALGADO ARAÚJO SILVA PINTO

**DETECÇÃO DE MUDANÇAS NA COBERTURA DO
SOLO DO CERRADO BRASILEIRO A PARTIR DE
ÍNDICES ESPECTRAIS E DO ALGORITMO RANDOM
FORESTS**

LAVRAS-MG

2019

ÁLVARO SALGADO ARAÚJO SILVA PINTO

**DETECÇÃO DE MUDANÇAS NA COBERTURA DO SOLO DO CERRADO
BRASILEIRO A PARTIR DE ÍNDICES ESPECTRAIS E DO ALGORITMO
RANDOM FORESTS**

Monografia apresentada à Universidade Federal de Lavras, como parte das exigências do Curso de Engenharia Florestal, para a obtenção do título de Bacharel.

Prof. Dr. Fausto Weimar Acerbi Júnior

Orientador

Dra. Eduarda Martiniano de Oliveira Silveira

Coorientadora

LAVRAS-MG

2019

ÁLVARO SALGADO ARAÚJO SILVA PINTO

**DETECÇÃO DE MUDANÇAS NA COBERTURA DO SOLO DO CERRADO
BRASILEIRO A PARTIR DE ÍNDICES ESPECTRAIS E DO ALGORITMO
RANDOM FORESTS**

**LAND COVER CHANGE DETECTION OF THE BRAZILIAN SAVANNAS USING
SPECTRAL INDICES AND THE RANDOM FORESTS ALGORITHM**

Monografia apresentada à Universidade Federal de Lavras, como parte das exigências do Curso de Engenharia Florestal, para a obtenção do título de Bacharel.

APROVADA em 19 de junho de 2019.

Prof. Fausto Weimar Acerbi Júnior - UFLA

Inácio Thomaz Bueno - UFLA

Kalill Viana Da Páscoa - UFLA

Prof. Dr. Fausto Weimar Acerbi Júnior

Orientador

Dra. Eduarda Martiniano de Oliveira Silveira

Coorientadora

Lavras-MG

2019

*Aos meus pais, Ari e Marly, por não medirem esforços para que eu chegasse até aqui.
À minha família e amigos pelo apoio concedido.*

Dedico

AGRADECIMENTOS

A Deus, pelas oportunidades concedidas e por me abençoar diariamente.

Aos meus pais, por serem à base da minha vida, por me apoiarem e acreditarem em mim em todos os momentos, por me ensinarem o que é caráter e ética, sem eles eu não seria nada.

Aos meus avós, Wilson e Ione, e a minha madrinha, Norma, por serem exemplos, pelo carinho, pelos conselhos, por sempre estarem presentes e contribuírem para o meu crescimento.

À minha família, que sempre esteve ao meu lado. Em especial aos meus primos Bebeto, Matheus e Fernando, e as minhas primas, Jéssica e Fernanda, obrigado por torcerem por mim.

À minha namorada, Juliana, pelo companherismo, ajuda, paciência, confiança e incentivo nas horas difíceis.

Aos irmãos que a vida me deu, Guilherme, Juninho e Franz, pelos bons momentos compartilhados e por estarem comigo desde sempre.

Ao amigo, professor e orientador, Faustinho, pela confiança depositada, pelo apoio concedido durante a realização do trabalho, e por todos os ensinamentos que contribuíram para minha formação pessoal e profissional.

À Duda, pela disponibilidade, por toda paciência e auxílio durante o desenvolvimento deste trabalho. Sua coorientação foi fundamental, obrigado!

A todos os membros do Laboratório de Geoprocessamento e amigos do LEMAF, pela troca de conhecimento, por me ajudarem a crescer durante a graduação, e pelos bons momentos que sempre terei como lembranças. Em especial aos amigos: Breno, Flávio, Gabriel, Henrique, Luiza, Rafa e Thainá.

À Universidade Federal de Lavras, em especial ao Departamento de Ciências Florestais, pela oportunidade e pela concessão da bolsa de iniciação científica.

Ao Inácio e ao Kalill, por terem aceitado compor a minha banca examinadora.

A todos que de alguma forma contribuíram direta ou indiretamente para a realização deste trabalho.

MUITO OBRIGADO!

Resumo Geral

O objetivo deste trabalho foi analisar a capacidade de 7 índices de vegetação em detectar e diferenciar mudanças na cobertura do solo em uma cena Landsat inserida no Cerrado Brasileiro, para isto foi utilizado o algoritmo de aprendizagem de máquina *Random Forest*. Foram geradas as imagens diferença entre os anos de 2006 a 2017, estas imagens foram segmentadas e posteriormente foram coletadas 50 amostras por classe e ano das classes queimada, desmatamento, regeneração e não mudança (sazonalidade). A partir destas amostras extraiu-se valores mínimos, médios, máximos e desvios padrão para treinamento do algoritmo *Random Forest*. Como resultado, verificou-se que todos os índices utilizados contribuíram para a acurácia global de 92,37%, comprovando sua alta capacidade em diferenciar vegetação de não vegetação. Os índices NBR e NBR2 foram os mais significativos ao diferenciar queimadas de desmatamentos, sendo que a alta separabilidade destes índices também foi comprovada em outros estudos realizados no Cerrado.

Palavras-chave: Sensoriamento remoto, Índices de vegetação, Desmatamentos, Queimadas, Áreas em regeneração.

SUMÁRIO

PRIMEIRA PARTE	7
1 INTRODUÇÃO.....	7
2 REFERENCIAL TEÓRICO	9
2.1 O Cerrado.....	9
2.2 Detecção de mudanças no Cerrado.....	10
2.3 Sensoriamento remoto: índices espectrais.....	14
3 CONSIDERAÇÕES FINAIS.....	18
REFERÊNCIAS.....	19
SEGUNDA PARTE – ARTIGO	22
DETECÇÃO DE MUDANÇAS NA COBERTURA DO SOLO DO CERRADO BRASILEIRO A PARTIR DE ÍNDICES ESPECTRAIS E DO ALGORITMO RANDOM FORESTS	22

PRIMEIRA PARTE

INTRODUÇÃO

Ao longo das últimas décadas o Cerrado Brasileiro vem sofrendo constantemente com o avanço da atividade antrópica, em sua maioria oriunda da agricultura e da pecuária. A exploração no Cerrado iniciou-se na década de 40 e foi intensificada na década de 70, quando o bioma tornou-se uma importante fronteira agrícola brasileira, sendo responsável pela maioria das “commodities” exportadas pelo país (PRADO, 2012). Como consequência desta expansão, a área total convertida pelo uso antrópico é estimada em mais de 40% do bioma (SANO, 2010). O cenário é agravado pelo fato de o Cerrado possuir mais de 4.800 espécies endêmicas e ser considerado o segundo maior bioma do país, abrangendo cerca de 2.000.000 km² (MYERS et al., 2000; MITTERMEIER et al., 2005; KLINK; MACHADO, 2005). Tudo isto contribuiu para que o Cerrado fosse considerado um dos “hotspots” mundiais para conservação da fauna e da flora.

Em razão do aumento da pressão nacional e internacional sobre a criação de novas políticas que tenham como finalidade a conservação e a restauração de áreas degradadas no Cerrado, o governo brasileiro passou a financiar projetos de monitoramento no bioma, como por exemplo, o projeto de detecção de desmatamentos no Cerrado, que tem como objetivo principal a quantificação de desmatamentos e queimadas, além de disponibilizar informações sobre riscos de incêndios florestais e estimar a emissão de gases poluentes provenientes da conversão de áreas nativas (PROJETO MONITORAMENTO CERRADO, 2019). Juntamente com este projeto houve uma mobilização da comunidade acadêmica com intuito de gerar novos métodos de detecção de mudanças no Cerrado, pois até então a atenção no país era voltada a Mata Atlântica e a Floresta Amazônica, que já possuem grandes áreas conservadas e uma vasta base de dados (STRASSBURG et al., 2017).

O principal desafio em mapear o Cerrado consiste em diferenciar polígonos de desmatamento de mudanças relacionadas a sazonalidade, pois mudanças fenológicas podem ser detectadas como desmatamento. O sensoriamento remoto constitui-se como uma das técnicas mais eficazes no que se diz respeito a detecção de mudanças no uso e cobertura do solo (ASNER et al., 2005), e por isso inúmeros métodos foram desenvolvidos neste sentido por pesquisadores da área, entre eles nota-se o de diferença por índices espectrais.

Esses índices são calculados a partir da razão entre as bandas de um sensor, e diferencia as classes por meio da diferença de absorção de clorofila e da reflectância emitida

pelas folhas, o que origina a assinatura espectral (BARBOSA, 2006). Diversos trabalhos realizados no Cerrado comprovaram a eficácia dos índices espectrais em definir e separar classes como: queimada (MELCHIORI et al., 2015; MILLER; THODE, 2007; PEREIRA et al., 2017), desmatamento (BUENO et al., 2019; BARROSO; SANO; FREITAS, 2017; SILVEIRA et al., 2018a) e sazonalidade (RESENDE et al., 2015), o que corrobora com o desenvolvimento de novas metodologias envolvendo os mesmos em estudos no bioma.

O objetivo desse estudo foi avaliar a acurácia da classificação de imagens utilizando índices espectrais derivados dos sensores TM/Landsat and OLI/Landsat para treinamento do algoritmo *Random Forests* (BREIMAN, 2001) no Bioma Cerrado. As classes analisadas foram: desmatamento, queimadas, regeneração e áreas sazonais (não mudança).

1 REFERENCIAL TEÓRICO

1.1 O Cerrado

O cerrado Brasileiro é tido como o segundo maior bioma do Brasil, ocupando cerca de 22% do país, numa área estimada em 2.000.000 km², está presente em estados do Centro-Oeste, Nordeste, Norte e sudeste, totalizando 15 estados mais o Distrito Federal. O clima pela classificação de Köppen é o AW (tropical de savana), as temperaturas nos meses mais frios são superiores a 18°C, sendo que a temperatura média mensal é de 22°C. A elevação no bioma varia de 300 a 1.600 metros de altitude e a precipitação é concentrada nos meses de outubro a março variando de 750 a 2000 mm, com média mensal de 1500 mm, podendo chegar a 0 mm nos meses secos (RIBEIRO; WALTER, 1998; KLINK; MACHADO, 2005).

A vegetação no bioma é típica de savanas, com predominância de gramíneas e herbáceas, podendo haver alguns arbustos espalhados que não formam um dossel contínuo, entretanto também podem ser notadas formações florestais e campestres (RIBEIRO; WALTER, 1998). Ao todo estima-se que há cerca de 7.000 espécies no Cerrado (SAWYER, 2002).

As formações florestais são compostas por tipos de vegetação onde a predominância é de espécies arbóreas, como em Matas Ciliares e Matas de Galeria que a partir de suas copas formam dosséis, estando associadas a cursos d'água, e também por Mata seca e Cerradão, que ocorrem em divisores topográficos ou divisores de água, em solos onde há boa drenagem (RIBEIRO; WALTER, 1998).

As formações savânicas podem ser caracterizadas como formações onde há a presença de gramíneas e arbustos, porém em menor densidade quando se comparado as formações florestais, nelas estão presentes o Cerrado stricto sensu, parque Cerrado, Palmeiral e Vereda, onde as principais diferenças são a disposição e a densidade de árvores dispostas sob o terreno, além dos tipos de solos presentes em suas extensões (RAMOS et al., 2006; RIBEIRO; WALTER, 1998).

As formações campestres possuem três principais tipos fitofisionômicos: Campo Sujo, Campo Limpo e Campo Rupestre, sendo que a principal diferença entre eles consiste na presença e quantidade de arbustos, que ocorrem com maior densidade no Campo Sujo do que no Campo Rupestre, já no Campo Limpo a presença de arbustos é praticamente insignificante (RIBEIRO; WALTER, 1998).

A exploração do Cerrado iniciou-se na década de 40, mas foi intensificada na década de 70 com as políticas de incentivo a expansão da agropecuária, o que resultou em uma área de intervenção antrópica correspondente a mais de 40% do bioma, sendo em sua maioria plantações agrícolas e pastagens (SANO., et al 2010). Somente entre os anos de 2001 a 2017 foram desmatados cerca de 272.198,8 km² (TERRABRASILIS, 2019), sendo que de 2002 a 2011 o desmatamento foi de 1% ao ano, o que representa quase o triplo do desmatamento da Amazônia neste período, consequência das poucas áreas de preservação ambiental no bioma, cerca de 7,5% de sua extensão, contra 46% na Amazônia. Além disso, tendo como base o atual código florestal cerca de 40% de vegetação nativa do Cerrado ainda pode ser convertida legalmente em outros usos, a situação é agravada pelo fato de que são poucas as pesquisas realizadas neste bioma quando se comparado, por exemplo, a Amazônia e a Mata Atlântica (STRASSBURG et al., 2017).

Devido a grande diversidade de espécies em extinção, endêmicas (cerca de 4.800), e ao histórico de desmatamento, o Cerrado é considerado um dos “hotspots” mundiais (MYERS et al., 2000; MITTERMEIER et al., 2005), e por isso diversas linhas de pesquisa estão sendo desenvolvidas com intuito de mapear e quantificar os danos sofridos durante os anos de exploração e ocupação antrópica, além de propor soluções que visam cessar ou diminuir estas ações, dentre elas está o sensoriamento remoto, que constitui-se como uma alternativa viável para detectar as mudanças no uso e cobertura do solo do Cerrado (ASNER et al., 2005).

1.2 Detecção de mudanças no Cerrado

Florestas estão em constante mudança, sendo que estas podem ser induzidas por ações humanas, ao converter o uso do solo, ou por mudanças naturais como epidemias, incêndios naturais e sazonalidade. No passado toda informação sobre florestas era obtida a partir de levantamentos realizados em campo, porém em 1930 imagens aéreas foram disponibilizadas para a comunidade acadêmica facilitando o desenvolvimento de estudos, porém somente em 1972, quando houve o lançamento do satélite Landsat-1, foram iniciadas as técnicas de sensoriamento remoto, permitindo a identificação e detecção de mudanças na vegetação (COPPIN; BAUER, 1996).

A detecção de mudanças pode ser definida como um processo que identifica diferenças no estado de um objeto ou fenômeno quando este é observado em diferentes espaços de tempo, o que em sensoriamento remoto traduz-se em variações de valores de reflectância (SINGH, 1989), sendo que é de suma importância a mensuração qualitativa e

quantitativa dessas mudanças. Mapas precisos e o monitoramento das fisionomias do Cerrado são necessários para criação de novas áreas para conservação, promover o uso sustentável da terra, além de melhorar o entendimento das dinâmicas do bioma e como elas impactam no balanço de carbono, ciclagem de nutrientes e recursos hídricos (SANO et al., 2010).

O principal projeto de detecção de desmatamentos no Cerrado foi desenvolvido pelo INPE, a partir do monitoramento sistemático do desmatamento na região, sendo este um sistema oficial de detecção de mudanças financiado por órgãos do governo brasileiro. O projeto consiste na construção de uma série histórica bienal da remoção de vegetação devido a atividade antrópica, contendo um mapeamento anual do desmatamento, o que aumenta a base de dados sobre a cobertura do solo no Cerrado e garante assim a tomada de decisão de governantes na implementação e execução de políticas públicas visando a proteção do bioma, além de fornecer dados para a realização de outros estudos (PROJETO MONITORAMENTO CERRADO, 2019).

Estratégias de monitoramento em nível regional são adotadas por alguns estados, como Minas Gerais, onde a Universidade Federal de Lavras realiza mapeamentos e monitoramentos constantes da flora nativa e dos reflorestamentos dos biomas contidos no estado, entre eles o Cerrado. Inicialmente foram utilizadas imagens provenientes do satélite Landsat, que apresenta resolução espacial média, porém devido a maior disponibilidade e ao decréscimo do valor para aquisição de imagens de outros sensores, o governo começou a diversificar a obtenção das mesmas, adquirindo imagens de alta resolução espacial. A limitação deste estudo está em não considerar áreas de regeneração de florestas nativas, o que é essencial para a elaboração de projetos de recuperação de áreas degradadas e para incentivos governamentais que visam o aumento de áreas regeneradas (CARVALHO JUNIOR, 2008).

Pesquisas neste sentido vêm ganhando cada vez mais força no Cerrado brasileiro, porém o mapeamento do uso e cobertura do solo no bioma é um grande desafio para a comunidade acadêmica, em virtude de sua alta sazonalidade, que faz com que mudanças fenológicas sejam detectadas como desmatamento devido a alteração dos valores espectrais medidos pelos satélites. (JIN et al., 2013; ZHANG et al., 2016). Ferreira et al. (2007) constataram a dificuldade em diferenciar as fitofisionomias do Cerrado de classes de uso da terra, como por exemplo, Campo Limpo e Campo Sujo de pastagens, o que conseqüentemente influi negativamente na identificação de desmatamentos. Além disso, podem haver erros de classificação e separabilidade entre classes com mudanças relacionadas ao fogo, que é um fenômeno de ocorrência natural no bioma, principalmente durante a estação seca, devido ao

acúmulo de biomassa seca e palha, o que é agravado pela intensa atividade antrópica no bioma, podendo causar incêndios incontroláveis (COUTINHO, 2002).

Barroso et al. (2017) propôs em sua metodologia a obtenção de imagens Landsat em duas passagens seguidas do sensor na área de estudo, visando a detecção de desmatamentos recentes, reduzindo os erros de comissão e inclusão com outras classes, como queimadas e sazonalidade. Lambin (1999) ressaltou a importância da integração entre informações espaciais, compreendendo a dinâmica espacial da área de estudo; espectrais, observando as variações nos valores dos pixels em uma imagem devido a intervenção antrópica ou sazonal; e temporais, onde podem haver alterações detectáveis em séries temporais curtas, como a sazonalidade e outras em séries mais longas, sendo estas, em sua maioria, modificações permanentes, em estudos onde o objetivo consiste em detectar mudanças. A correta utilização dessas informações permite indicar com maior precisão variações em atributos biofísicos da superfície e da vegetação.

Ao longo dos anos diversos métodos de detecção de mudanças envolvendo sensoriamento remoto são desenvolvidos pela comunidade acadêmica, os principais foram listados por Hall e Hay (2003) apud Couto Junior (2011) (Tabela 1), sendo que estes métodos podem ser utilizados para quantificar, controlar e reduzir a atividade antrópica no Cerrado.

Diversos trabalhos utilizaram dados de sensoriamento remoto aliados a valores espectrais derivados de índices de vegetação em classificações, a fim de avaliar a capacidade desses valores em reduzir o impacto da sazonalidade sob a acurácia da classificação em séries temporais do satélite Landsat. Nestes estudos pôde-se notar que os valores espectrais contribuíram para o aumento da acurácia da classificação, reduzindo a influência da sazonalidade na detecção de desmatamentos e aumentando a separabilidade entre polígonos de sazonalidade e desmatamento (SILVEIRA et al., 2018a; SILVEIRA et al., 2018b).

Tabela 1. Métodos de detecção de mudanças (continua)

Método	Autores
Análise vetorial de mudança	Malila (1980), Virag e Colwell (1987), Lambin e Strahler (1994), Lambin (1996), Johnson e Kasischke (1998)
Análise de membros finais	Adams et al. (1995), Kressler e Steinnocher (1999)
Diferença de imagem	Knapp e Robinson (1981), Jenson e Toll (1982), Nelson (1983), Singh (1986), Gong et al. (1992), Manalavan et al. (1995)
Razão de imagem	Wilson, Blackman e Spann (1976), Todd (1977), Howarth e Wickware (1981), Nelson (1983), Singh (1984, 1986)
Regressão de imagem	Singh (1986), Hanaizumi et al. (1991), Jha e Unni (1994)
Textura Local	Lazaroff e Brennan (1992)
Análise de Componentes Principais	Lodwick (1979), Byrne et al. (1980), Singh e Harrison (1985), Fung e LeDrew (1987), Deer e Longmore (1994), Siljeström Ribed e Moreno López (1995), Collins e Woodcock (1996)
Análise de Forma	Choo et al. (1998)
Diferença de Índices Espectrais	Angelici, Bryntin e Friwmasn (1977), Coiner (1980), Banner e Lynham (1981), Nelson (1983), Singh (1984, 1986), Coppin e Bauer (1994), Lyon et al. (1998), Liesenberg (2007)
Ondaleta	Collins e Woodcock (1994), Carvalho et al. (2001)
Inteligência Artificial	Matsuyama (1987)
Redes Neurais	Gopal e Woodcock (1996), Dai e Khorram (1997), Chan et al. (2001)

Tabela 1. Métodos de detecção de mudanças (conclusão)

Classificação direta em vários dados	Weismiller et al. (1977), Hoffer e Lee (1989)
Sistema esperto	Stefanov et al. (2001)
Comparação nebulosa pós classificação	Fisher e Pathirana (1993), Deer (1998), Eklund et al. (2000), Deer e Eklund (2001), Foody (2001)
Comparação pós classificação	Gordon (1980), Riordan (1980), Jensen et al. (1995), Munyati (2000)
Detecção de mudanças baseada em objetos	Desclée, Bogaert e Defourny (2006), Niemeyer et al. (2006), Bontemps et al. (2008), Conchedda, Durieux e Mayaux (2008), Duveiller et al. (2008), McDermid et al. (2008), Radoux e Defourny (2008), Chirici e tal. (2011)
Análises temporais	Kennedy et al. (2010), Verbesselt et al. (2010), Almeida et al. (2014)
Aprendizagem profunda	Hinton et al. (2006), Bengio et al. (2006), Ranzato et al. (2006), Zhao et al. (2014), Gong et al. (2016), Zhang et al. (2016).

Fonte: Adaptação de Hall e Hay (2003), Couto Junior (2011).

1.3 Sensoriamento remoto: índices espectrais

Sensoriamento remoto é tido como uma ciência que permite a obtenção de imagens e informações sobre objetos sem nenhum contato físico com ele, estas imagens e informações são provenientes de sensores que captam a energia eletromagnética refletida por um objeto, sendo que o comprimento de onda difere de um objeto a outro, criando uma assinatura espectral, o que possibilita a separação e identificação dos mesmos (FIGUEIREDO, 2005).

Um sensor possui características próprias, que podem limitar seu uso em determinados trabalhos, a capacidade de um sensor pode ser avaliada a partir de sua resolução espacial, que é definida como o tamanho de um pixel da imagem em relação a superfície da terra; resolução espectral, que está relacionada com o número e largura das bandas espectrais; resolução

radiométrica, que é associada aos níveis de cinza refletidos pela imagem em função do número de bits; e resolução temporal, que corresponde ao período de tempo em que um satélite recobre a mesma área (FIGUEIREDO, 2005).

Mundialmente os sensores mais utilizados são os da série Landsat, devido ao grande período de tempo que estão em órbita e a suas características, que os tornam indicados a estudos ambientais. O Satélite Landsat 5 foi lançado pela NASA em 1984, permanecendo em órbita até 2013, ano em que foi lançado o satélite Landsat 8 (NASA, 2019). O número de bandas aumentou de 7 no Landsat 5, para 11 no Landsat 8, proporcionando maiores possibilidades de combinações matemáticas envolvendo bandas, entre elas a operação aritmética de razão de bandas, que fornece os índices espectrais.

Os índices espectrais consistem em equações matemáticas que relacionam a assinatura espectral com parâmetros quantitativos e qualitativos mensuráveis em campo, eles são eficazes pois detectam a diferença de absorção da clorofila e da reflectância emitida pelas folhas, principalmente nas bandas do infravermelho (BARBOSA, 2006).

Desenvolvido por Tucker (1979), o índice NDVI (*Normalized Difference Vegetation Index*) está entre os mais utilizados em estudos ambientais, sua equação consiste na razão da subtração entre as bandas do infravermelho próximo com as bandas do vermelho sobre a soma das duas, e seu valor varia de -1 a 1, sendo que quanto menor o valor de reflectância menos densa é a vegetação. Sabe-se que este índice possui limitações no que se diz respeito a saturação dos valores em vegetações de maior densidade, e por isso Huete et al. (2002) desenvolveram o índice EVI (*Enhanced Vegetation Index*), que é mais sensível a altas densidades, captando melhor as variações do dossel. Além disso, o NDVI é sensível a variações de tipo de solo, o que é corrigido pelo índice SAVI (*Soil-Adjusted Vegetation Index*) e por sua variação MSAVI (*Modified Soil-Adjusted Vegetation Index*), que apresentam técnicas que minimizam as influências do brilho do solo, praticamente eliminando as variações induzidas por ele nos valores de reflectância (HUETE, 1988; RONDEAUX; STEVEN; BARET, 1996).

Estes índices espectrais estão entre os mais utilizados em estudos de detecção de mudanças no Cerrado, Silveira et al. (2018b) utilizou o índice NVDI associado a informações espaciais para reduzir a influência da sazonalidade na detecção de polígonos de desmatamento em uma imagem Landsat, obtendo acurácia global de 96.53%. Bayma e Sano (2015) analisaram o uso de séries temporais do MODIS EVI e MODIS NDVI para detectar desmatamentos no cerrado e pôde concluir que o NDVI foi superior ao EVI, pois durante um desmatamento os valores de NDVI decaíram de maneira mais acentuada. Carvalho Júnior et

al. (2008) utilizaram o NDVI MODIS para diferenciar as fitofisionomias do Cerrado e comprovou a eficiência do índice na separabilidade das classes, mesmo em um sensor de baixa resolução espacial (250m) e com alta mistura espectral.

Com o avanço das pesquisas em sensoriamento remoto diversos outros índices espectrais foram desenvolvidos utilizando equações que visam melhorar a qualidade e a precisão da detecção de mudanças, as alterações podem ser notadas principalmente no ajuste de parâmetros, resultando em índices ajustados a solo, fogo, normalizados a vegetação, entre outros.

Miller e Thode (2007) propuseram os índices NBR (*Normalized Burn Ratio*) e NBR2 (*Normalized Burn Ratio 2*), inicialmente recomendados para detecção de queimadas. O primeiro é baseado na razão entre a subtração das bandas do infravermelho próximo com o infravermelho de ondas curtas 2 sobre a soma destas bandas; o segundo é calculado pela razão entre a diferenciada banda do infravermelho de ondas curtas 1 com o infravermelho de ondas curtas 2 sobre a soma dos mesmos. A partir do uso destas bandas os dois índices mostraram-se sensíveis ao detectar mudanças na quantidade de vegetação verde, teor de umidade e algumas condições que o solo apresenta após o fogo.

Wilson e Sader (2002) comprovaram o potencial do índice espectral NDMI (*Normalized Difference Moisture Index*) ao compará-lo com o NDVI em um estudo onde o objetivo consistiu em detectar mudanças em florestas sob diferentes níveis de colheita. Quando a atividade de colheita retirou toda a vegetação deixando o solo exposto, ambos os índices obtiveram boas acurácias ao detectar a mudança, entretanto quando houve uma colheita parcial da floresta o índice NDMI apresentou maiores acurácias quando comparado ao NDVI, evidenciando a aplicabilidade do índice em pesquisas cujo objetivo é monitorar distúrbios que causam a remoção parcial ou total da vegetação de um local, detectando diminuições ou aumentos na biomassa verde associados a colheita ou regeneração florestal. A equação do NDMI é definida pela razão entre a subtração do infravermelho próximo com o infravermelho de onda curta 1 sobre a soma dos mesmos.

Estudos comprovaram o grande potencial no uso das bandas do infravermelho de ondas curtas 1 e 2 (SWIR 1 e SWIR2) ao detectar e diferenciar desmatamentos de sazonalidade (BUENO et al., 2019), estas bandas estão presentes em índices como NBR, NBR2 e NDMI. O índice NBR foi utilizado para discriminar áreas desmatadas de áreas queimadas no Cerrado, obtendo erros de comissão e omissão inferiores a 5%, onde dos 178 polígonos classificados como desmatamento apenas 7 foram incluídos na classe de queimadas. (BARROSO; SANO; FREITAS, 2017)

Também foram realizados no Cerrado trabalhos com intuito de detectar mudanças provocadas por incêndios, novamente notou-se a grande capacidade dos índices espectrais em detectar estas mudanças e separá-las de outras classes, principalmente os índices que contêm a banda do infravermelho de ondas curtas 1 ou 2 em suas equações, como NBR, NBR2 e NDMI, em geral estes índices apresentaram melhores resultados quando comparados a outros que não utilizam essas bandas (MELCHIORI et al., 2015; MILLER; THODE, 2007; PEREIRA et al., 2015; PEREIRA et al., 2017). O índice NBR também foi eficaz ao detectar áreas vegetais em regeneração no mesmo bioma (RESENDE et al., 2015).

1.4 Random Forests

O Random forest é um algoritmo de aprendizado de máquina que realiza combinações aleatórias entre árvores de decisão visando previsões com alta acurácia e estabilidade, podendo ser empregado em classificações ou regressões. (BREIMAN, 2001). O número de variáveis a serem selecionadas (Mtry) e o número de árvores a serem geradas (Ntree) são os únicos parâmetros a serem definidos. A ntree é definida para manter o nível de precisão, a maioria dos estudos define seu valor em 500, pois os erros se estabilizam antes do número máximo de árvores. Já o número de variáveis a serem selecionadas pode permanecer em seu valor padrão.

Este algoritmo pode ser utilizado para classificar e ranquear quais variáveis possuem maior capacidade em separar os alvos analisados, e por isso vêm sendo empregado em estudos de classificação do uso e cobertura do solo (TSUTSUMIDA; COMBER, 2015; HAAS; BAN, 2014; COLDITZ, 2015; JIN et al., 2016).

2 CONSIDERAÇÕES FINAIS

A metodologia utilizada neste trabalho contribui para o aumento da base de dados em estudos de detecção de mudanças no Cerrado brasileiro, que apesar de ser o bioma no país que atualmente mais sofre pressão antrópica, possui poucos trabalhos neste sentido quando se comparado aos outros biomas contidos no Brasil. A classificação apresentou alta acurácia ao diferenciar as classes analisadas, entre elas a sazonalidade, que é tida como um dos maiores desafios ao mapear o Cerrado, além disso, pôde-se notar que os índices espectrais que contem as bandas do infravermelho 1 e 2, mesmo que pouco empregados em estudos no bioma, apresentaram resultados superiores aos índices mais utilizados, como o NDVI. Os resultados demonstraram o grande potencial de aplicabilidade do método na elaboração de políticas públicas, auxiliando no desenvolvimento de projetos de preservação e restauração do Cerrado, sendo possível a partir dele, identificar e quantificar queimadas, desmatamentos, e áreas em regeneração.

REFERÊNCIAS

- ASNER, G. P. et al. Ecosystem structure throughout the Brazilian Amazon from Landsat observations and automated spectral unmixing. **Earth Interactions**, v. 9, n. 7, p. 1–31, 2005.
- BAATZ, M.; SCHÄPE, A. Multiresolution Segmentation: An Optimization Approach for High Quality Multi-Scale Image Segmentation. In: **Angewandte Geographische Informations-Verarbeitung XII**. [s.l.: s.n.]. p. 12–23.
- BACCINI, A. et al. A first map of tropical Africa's above-ground biomass derived from satellite imagery. **Environmental Research Letters**, v. 3, n. 4, 2008.
- BANSKOTA, A. et al. Forest Monitoring Using Landsat Time Series Data: A Review. **Canadian Journal of Remote Sensing**, v. 40, n. 5, p. 362–384, 2014.
- BARBOSA, K. M. DO N. **Monitoramento Espacial de Biomassa e Carbono Orgânico da Vegetação Herbácea de Várzea na Amazônia Central**. [s.l.: s.n.].
- BARROSO, A. G.; SANO, E. E.; FREITAS, D. M. DE. IDENTIFICAÇÃO DE DESMATAMENTOS NO CERRADO UTILIZANDO TÉCNICAS DE DIFERENÇA DE IMAGENS E ÍNDICE DE QUEIMADA POR DIFERENÇA NORMALIZADA. **Rev. Bras. Cartografia**, v. 69, n. 7, p. 1397–1409, 2017.
- BAYMA, A. P.; SANO, E. E. Boletim de Ciências Geodésicas. **Boletim de Ciências Geodésicas**, v. 21, n. 4, p. 797–813, 2015.
- BREIMAN, L. RANDOM FORESTS. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001.
- BUENO, I. et al. Object-Based Change Detection in the Cerrado Biome Using Landsat Time Series. **Remote Sensing**, v. 11, n. 570, p. 1–14, 2019.
- CHAN, J. C. W.; PAELINCKX, D. Evaluation of Random Forest and Adaboost tree-based ensemble classification and spectral band selection for ecotope mapping using airborne hyperspectral imagery. **Remote Sensing of Environment**, v. 112, n. 6, p. 2999–3011, 2008.
- COHEN, W. B.; GOWARD, SAMUEL N. Landsat's Role in Ecological Applications of Remote Sensing. **Bioscience**, v. 54, n. 6, p. 535–545, 2004.
- COLDITZ, R. R. An evaluation of different training sample allocation schemes for discrete and continuous land cover classification using decision tree-based algorithms. **Remote Sensing**, v. 7, n. 8, p. 9655–9681, 2015.
- CONGALTON, R. G. A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data. **Remote Sensing of Environment**, v. 37, n. 1, p. 35–46, 1991.
- COPPIN, P. R.; BAUER, M. E. Digital Change Detection in Forest Ecosystems with Remote Sensing Imagery. **Remote Sensing Reviews**, v. 13, n. 3–4, p. 207–234, 1996.
- COUTINHO, L. M. O bioma do Cerrado. In: **Eugen Warming e o Cerrado brasileiro um século depois**. [s.l.: s.n.]. p. 77–91.
- DEVRIES, B. et al. Characterizing Forest Change Using Community-Based Monitoring Data and Landsat Time Series. **PLOS ONE**, v. 11, n. 3, p. 1–25, 28 mar. 2016.
- FERREIRA, M. E. et al. Desmatamentos no bioma Cerrado: uma análise temporal (2001-2005) com base nos dados MODIS - MOD13Q1. **XIII Simpósio Brasileiro de Sensoriamento Remoto**, p. 3877–3883, 2007.
- FIGUEIREDO, D. Conceitos Básicos de Sensoriamento Remoto. **Companhia Nacional de Abastecimento-CONAB**, v. 1, p. 32, 2005.
- HAAS, J.; BAN, Y. International Journal of Applied Earth Observation and Geoinformation Urban growth and environmental impacts in Jing-Jin-Ji, the Yangtze, River Delta and the Pearl River Delta. **International Journal of Applied Earth Observations and Geoinformation**, v. 30, p. 42–55, 2014.
- HALL, O.; HAY, G. J. A multiscale object-specific approach to digital change detection. **International Journal of Applied Earth Observation and Geoinformation**, v. 4, n. 4, p. 311–327, 2003.

- HAN, H.; GUO, X.; YU, H. **Variable selection using Mean Decrease Accuracy and Mean Decrease Gini based on Random Forest**. Proceedings of the IEEE International Conference on Software Engineering and Service Sciences, ICSESS. **Anais...IEEE**, 2016
- HUETE, A. et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, p. 195–213, 2002.
- HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295–309, 1988.
- JIN, S. et al. A comprehensive change detection method for updating the National Land Cover Database to circa 2011. **Remote Sensing of Environment**, v. 132, p. 159–175, 2013.
- JIN, Y. et al. Mapping deforestation in north korea using phenology-based multi-index and random forest. **Remote Sensing**, v. 8, n. 12, p. 1–15, 2016.
- JUNIOR, A. C. DE S. C. **Monitoramento Do Cerrado Em Minas Gerais Usando Análises Estatísticas Baseadas Em Objetos** : [s.l: s.n.].
- JÚNIOR, O. A. DE C. et al. CLASSIFICAÇÃO DE PADRÕES DE SAVANA USANDO ASSINATURAS TEMPORAIS NDVI DO SENSOR MODIS NO PARQUE NACIONAL CHAPADA DOS VEADEIROS. **Revista Brasileira de Geofísica**, v. 26, n. 4, p. 505–517, 2008.
- KLINK, C. A.; MACHADO, R. B. A conservação do Cerrado brasileiro. **MEGADIVERSIDADE**, v. 1, n. 1, p. 147–155, 2005.
- LAMBIN, E. F. Monitoring Forest Degradation in Tropical Regions by Remote Sensing: Some Methodological Issues Eric F. Lambin. **Global Ecology and Biogeography**, v. 8, n. 3, p. 191–198, 1999.
- LIAW, A.; WIENER, M. Classification and Regression by random forest. **R News**, v. 2, p. 18–22, 2002.
- MELCHIORI, A. E. et al. Spectral indices and multi-temporal change image detection algorithms for burned area extraction in the Brazilian Cerrado. **XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, v. 17, n. 1, p. 643–650, 2015.
- MILLER, J. D.; THODE, A. E. Quantifying burn severity in a heterogeneous landscape with a relative version of the delta Normalized Burn Ratio (dNBR). **Remote Sensing of Environment**, v. 109, n. 1, p. 66–80, 2007.
- MITTERMEIER, RUSSELL A. et al. A Brief History of Biodiversity Conservation in Brazil. **Conservation Biology**, v. 19, n. 3, p. 601–607, 2005.
- MYERS, N. et al. Biodiversity hotspots for conservation priorities. **Nature**, v. 403, n. 24, p. 853–858, 2000.
- NASA. **Landsat Science**. Disponível em: <<https://landsat.gsfc.nasa.gov/>>. Acesso em: 17 maio. 2019.
- PEREIRA, A. A. et al. Avaliação de nove índices espectrais quanto a separabilidade entre queimadas e diferentes alvos. **XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, v. 17, p. 3105–3112, 2015.
- PEREIRA, A. A. et al. Avaliação de índices espectrais para identificação de áreas queimadas no cerrado utilizando dados LandSat TM. **Rev. Bras. Cartogr**, v. 68, n. 8, p. 1665–1680, 2016.
- PEREIRA, A. A. **Queimadas No Bioma Cerrado**. [s.l: s.n.].
- PRADO, L. D. A.; MAZIARA, F.; FERREIRA, M. E. EXPANSÃO DA FRONTEIRA AGRÍCOLA E MUDANÇAS NO USO DO SOLO NA REGIÃO SUL DE GOIÁS: AÇÃO ANTRÓPICA E CARACTERÍSTICAS NATURAIS DO ESPAÇO. **B.goiano.geografia. Goiânia**, v. 32, n. 1, p. 151–165, 2012.
- Projeto Monitoramento Cerrado**. Disponível em: <<http://www.obt.inpe.br/cerrado/>>. Acesso em: 14 maio. 2019.
- R CORE DEVELOPMENT TEAM. **A language and environment for statistical**

computing. [s.l: s.n.].

RAMOS, M. V. V. et al. Veredas do triângulo mineiro: solos, água e uso. **Ciência e Agrotecnologia**, v. 30, n. 2, p. 283–293, 2006.

RESENDE, F. C. et al. **Análise de Índices Espectrais para Estimativa de Áreas de Regeneração Florestal no Parque Nacional Chapada Das Mesas.** [s.l.] Unspecified, 2015. v. 3

RIBEIRO, J. F.; WALTER, B. M. T. Fitofisionomias do bioma Cerrado. In: **Cerrado : ambiente e flora.** [s.l: s.n.]. p. 556.

RONDEAUX, G.; STEVEN, M.; BARET, F. Optimization of soil-adjusted vegetation indices. **Remote Sensing of Environment**, v. 55, n. 2, p. 95–107, 1996.

SANO, E. E. et al. Land cover mapping of the tropical savanna region in Brazil. **Environmental Monitoring and Assessment**, v. 166, n. 1–4, p. 113–124, 2010.

SAWYER, D. População , Meio Ambiente e Desenvolvimento Sustentável no Cerrado. In: **População, Meio Ambiente e Desenvolvimento Sustentável no Cerrado.** [s.l: s.n.]. p. 279–302.

SCHROEDER, T. A. et al. Mapping wildfire and clearcut harvest disturbances in boreal forests with Landsat time series data. **Remote Sensing of Environment**, v. 115, n. 6, p. 1421–1433, 2011.

SILVEIRA, E. M. DE O. et al. Reducing the effects of vegetation phenology on change detection in tropical seasonal biomes. **GIScience and Remote Sensing**, v. 00, n. 00, p. 1–19, 2018a.

SILVEIRA, E. M. O. et al. Using spatial features to reduce the impact of seasonality for detecting tropical forest changes from landsat time series. **Remote Sensing**, v. 10, n. 808, p. 1–21, 2018b.

SINGH, A. Review Article: Digital change detection techniques using remotely-sensed data. **International Journal of Remote Sensing**, v. 10, n. 6, p. 989–1003, 1989.

STRASSBURG, B. B. N. et al. Moment of truth for the Cerrado hotspot. **Nature Ecology and Evolution**, v. 1, n. 4, p. 1–3, 2017.

TerraBrasilis. Disponível em:

<<http://terrabrasilis.dpi.inpe.br/map/dashboard/deforestation/biomes/cerrado/increments>>.

Acesso em: 4 abr. 2019.

TSUTSUMIDA, N.; COMBER, A. J. International Journal of Applied Earth Observation and Geoinformation Measures of spatio-temporal accuracy for time series land cover data. **International Journal of Applied Earth Observations and Geoinformation**, v. 41, p. 46–55, 2015.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p. 127–150, 1979.

WILSON, E. H.; SADER, S. A. Detection of forest harvest type using multiple dates of Landsat TM imagery. **Remote Sensing of Environment**, v. 80, n. 3, p. 385–396, 2002.

ZHANG, K. et al. Remote sensing of seasonal changes and disturbances in mangrove forest: A case study from South Florida. **Ecosphere**, v. 7, n. 6, p. 1–23, 2016.

SEGUNDA PARTE – ARTIGO

DETECÇÃO DE MUDANÇAS NA COBERTURA DO SOLO DO CERRADO BRASILEIRO A PARTIR DE ÍNDICES ESPECTRAIS E DO ALGORITMO RANDOM FORESTS

LAND COVER CHANGE DETECTION OF THE BRAZILIAN SAVANNAS USING SPECTRAL INDICES AND THE RANDOM FORESTS ALGORITHM

Álvaro Salgado Araújo Silva Pinto¹, Eduarda Martiniano de Oliveira Silveira², Thainá Guimarães Rocha³, Fausto Weimar Acerbi Júnior⁴, Inácio Thomaz Bueno⁵

¹ Universidade Federal de Lavras, Departamento de Ciências Florestais, Campus da UFLA, Caixa postal 3037, Lavras-MG, 37200-000, Brasil

¹alvarosalgado96@yahoo.com.br; ²dudalavras@hotmail.com; ³thaina.g.rocha@gmail.com; ⁴fausto@dcf.ufla.br; ⁵inaciotbueno@gmail.com.

RESUMO

O objetivo deste trabalho foi analisar a capacidade de 7 índices de vegetação em detectar e diferenciar mudanças na cobertura do solo no Cerrado Brasileiro. Para isto foi utilizado o algoritmo de aprendizagem de máquina Random Forests. Foram geradas as imagens diferença entre os anos de 2006 a 2017, estas imagens foram segmentadas e posteriormente foram coletadas 50 amostras por classe e ano das classes queimada, desmatamento, regeneração e não mudança (sazonalidade). A partir destas amostras extraiu-se valores mínimos, médios, máximos e desvios padrão para treinamento do algoritmo Random Forests. Como resultado, verificou-se que todos os índices utilizados contribuíram para a acurácia global de 92,37%, comprovando sua alta capacidade em diferenciar vegetação de não vegetação. Os índices NBR e NBR2 foram os mais significativos ao diferenciar queimadas de desmatamentos, sendo que a alta separabilidade destes índices também foi comprovada em outros estudos realizados no Cerrado.

Palavras-chave — Sensoriamento remoto, Índices de vegetação, Desmatamentos, Queimadas, Áreas em regeneração.

ABSTRACT

The objective of this work was to analyze 7 vegetation indices in order to detect and differentiate land cover changes in the Brazilian savannas, also known as the Cerrado. We calculated the difference images from Landsat scenes of the years 2006 to 2017. The difference images were segmented and 50 samples per class (burned, deforestation, regeneration and no changed areas) per year were collected. Then, we extracted from each

sample the minimum, average, maximum and standard deviation values for training the Random Forest algorithm. The results showed the importance of all indices to achieve the overall accuracy of 92.37%, proving their high capacity to differentiate vegetated from non-vegetated areas. The NBR and NBR2 were the most significant indices for differentiation of burned areas and deforestation. Similar results were also reported by other authors studying land cover changes in the Cerrado.

Key words — Remote sensing, vegetation indices, deforestation, burned, regeneration areas.

INTRODUÇÃO

O cerrado Brasileiro consiste no segundo maior bioma do Brasil e está localizado em sua maioria na região Centro-Oeste, mas também compreende partes das regiões Norte, Nordeste e Sudeste do país (SANO et al., 2010). Ocupa 22% do território nacional, e abriga mais de 7.000 espécies arbóreas, sendo considerada a mais diversificada savana do mundo (SAWYER, 2002). A exploração do bioma iniciou-se na década de 40 com a criação do “*Projeto de Colonização nos Cerrados*”, porém grande parte da conversão da vegetação nativa deveu-se as políticas de expansão agropecuária na década de 70 (PRADO et al., 2012). Portanto, amparadas no lema “Integrar para não entregar” as políticas de expansão agropecuária foram efetivas, tornando o Cerrado um polo da agricultura e da pecuária. Contudo, o saldo negativo é uma área desmatada de 272.198,8 km² entre os anos de 2001 a 2017 (TERRABRASILIS, 2019). Isto é agravado pelo fato de que há poucos estudos no Cerrado quando comparado a outros biomas brasileiros como Amazônia e Floresta Atlântica, consequentemente o entendimento do uso e da cobertura do solo é limitado (BUENO et al., 2019). Isto contribuiu para que o Cerrado fosse considerado um dos “hotspots” mundiais para conservação da biodiversidade (MYERS et al., 2000; MITTERMEIER et al., 2005)

Os índices de espectrais provêm de expressões matemáticas que levam em conta valores de reflectância, o que os torna sensíveis a mudanças espectrais na vegetação (PEREIRA et al., 2016), e em razão disso vêm sendo amplamente empregados em estudos que visam detectar mudanças na cobertura do solo. Silveira et al. (2018b), aplicaram o índice de vegetação NDVI (“*The Normalized Difference Vegetation Index*”) em conjunto com métricas espaciais para minimizar o efeito da sazonalidade na detecção de mudanças na cobertura do solo em áreas de Cerrado, enquanto Bueno et al. (2019) estudaram a capacidade das bandas do infravermelho de ondas curtas (bandas 5 e 7) em diferenciar desmatamentos de

mudanças sazonais. Resende et al. (2015) analisaram índices espectrais para estimativas de áreas de regeneração florestal, já outros trabalhos utilizaram estes índices com intuito de separar polígonos de queimada de mudanças sazonais ou outros alvos (PEREIRA et al., 2015; PEREIRA et al., 2016).

Mudanças constantes e a sazonalidade tornam-se desafios para o mapeamento e monitoramento da cobertura do solo em áreas de Cerrado, uma vez que as mudanças fenológicas podem ser detectadas como desmatamentos devido a alteração das assinaturas espectrais medidas pelos satélites (JIN et al., 2013; ZHANG et al., 2016). Estudos realizados no Cerrado mostraram a grande dificuldade em detectar a sazonalidade no bioma e separá-la de outras classes, pois modificações no valor do índice de área foliar entre a estação seca e chuvosa ocorrem frequentemente, neste sentido nota-se a importância de se utilizar índices de vegetação (BUENO et al., 2019; SILVEIRA et al., 2018a). Mapas precisos e o monitoramento das fisionomias do Cerrado são necessários para criação de novas áreas para conservação, promover o uso sustentável da terra, além de melhorar o entendimento das dinâmicas do bioma e como elas impactam no balanço de carbono, ciclagem de nutrientes e recursos hídricos (SANO et al., 2010).

Outra alternativa para minimizar os efeitos da sazonalidade é a análise de séries temporais de imagens, contudo, devido ao grande volume de informação gerado, essa análise requer o uso de algoritmos robustos. Desta forma, o objetivo desse estudo foi avaliar a acurácia da detecção de mudanças na cobertura do solo em uma série temporal de imagens utilizando índices espectrais para treinamento do algoritmo Random Forests no bioma Cerrado, além de analisar a capacidade dos índices espectrais utilizados em detectar essas mudanças. As classes de mudança analisadas foram: desmatamentos, queimadas, regeneração e áreas sazonais (não mudança).

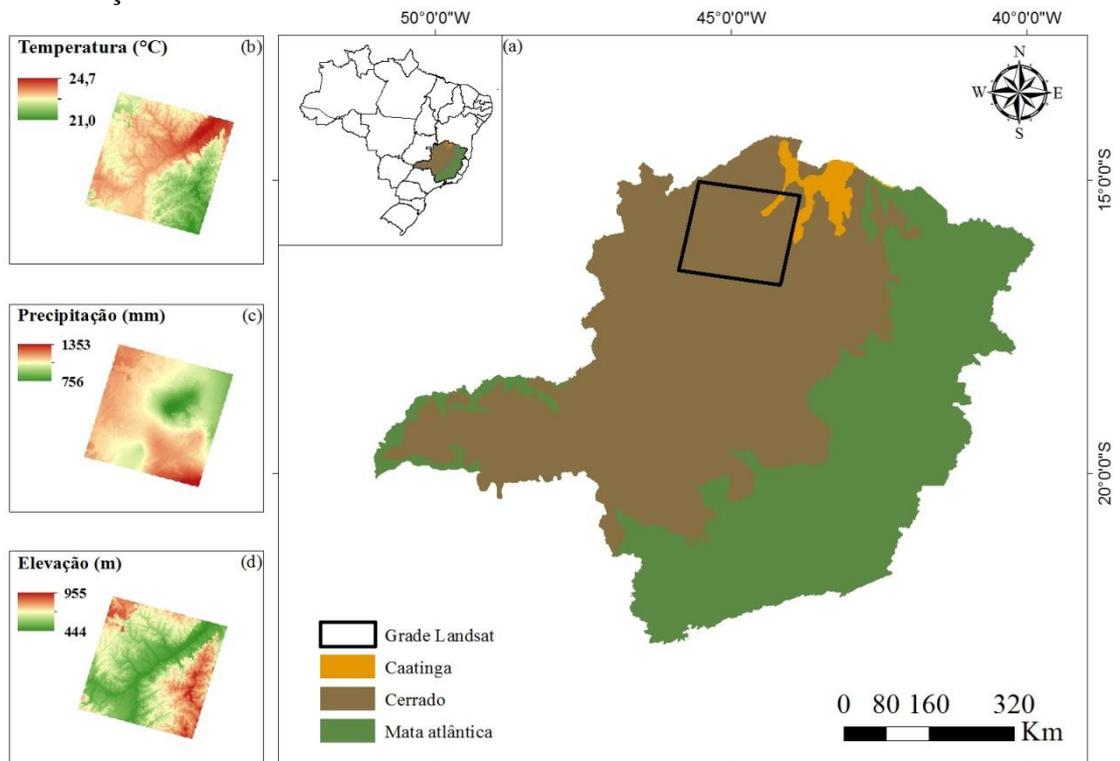
MATERIAIS E MÉTODOS

Área de estudo e base de dados

A área de estudo compreende a uma cena Landsat representada pela órbita 219 e ponto 71, localizada na região norte do estado de Minas Gerais, Brasil (Figura 1). A cena abrange 19 municípios inseridos na bacia hidrográfica do Rio São Francisco. O bioma predominante no local é o Cerrado, havendo também uma pequena área de Caatinga. Segundo Carvalho e Scolforo (2008), as fitofisionomias presentes na área são Cerrado sensu stricto, Campo Cerrado, Vereda, Floresta Estacional Decidual e Floresta Estacional Semidecidual, o que demonstra a grande diversidade contida na região (Tabela 1).

O clima do Cerrado de acordo com a classificação de Köppen é o tropical de savana (Aw), com temperaturas mensais acima de 22°C (Figure 1b), altitude de 300 a 1600 metros (Figura 1d) e precipitação pluviométrica média anual de 1.500 mm (Figura 1c), concentrada nos meses de outubro a março, sendo que nos meses sem chuvas este valor pode chegar a 0 mm, o que explica a alta sazonalidade (KLINK; MACHADO, 2005) (Figura 2).

Figura 1. (a) Área de estudo (Cena 219/71), contendo as delimitações dos biomas Brasileiros no Estado de Minas Gerais e sua localização no país; (b) Variações de temperatura na área de estudo; (c) Variações de precipitação na área de estudo; (d) Variações de elevação na área de estudo



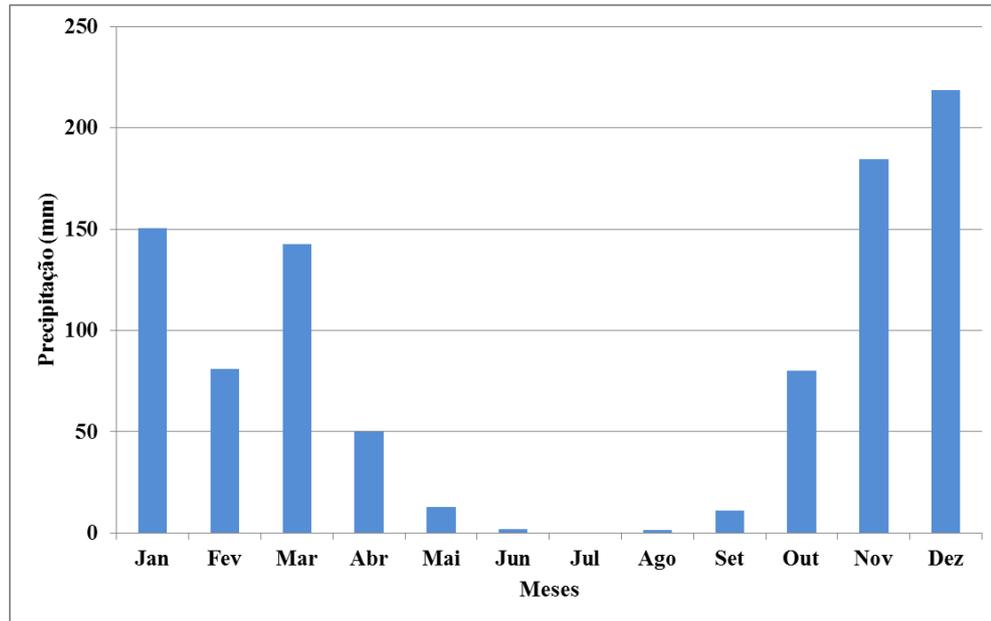
Fonte: Do autor (2019).

Tabela 1. Fitofisionomias contidas na área de estudo

Tipo de vegetação	Vista panorâmica	Vista área Landsat TM R3 G2 B1
Floresta estacional semidecidual		
Campo Cerrado		
Vereda		
Floresta estacional decidual		
Cerrado sensu stricto		

Fonte: Adaptação de Silveira et al., (2018b).

Figura 2. Precipitação anual na área de estudo



Fonte: Do autor (2019).

As imagens foram adquiridas a partir do portal USGS *Earth Resources Observation and Science* (EROS), provenientes dos satélites Landsat/TM e Landsat/OLI, órbita 219 e ponto 71, com resolução espacial de 30 metros. Foram obtidas 11 imagens para o estudo, sendo estas compreendidas entre os anos de 2006 a 2017, exceto no ano 2012, onde não há imagens disponíveis para esse satélite (Tabela 2). As imagens adquiridas no portal já possuem as correções geométricas e radiométricas, portanto não foi necessário realizá-las. Juntamente com as bandas foram obtidos 7 índices espectrais (Tabela 3).

Tabela 2. Datas das imagens Landsat adquiridas em cada ano

ANO	PATH ROW
	219 71
2006*	14/set
2007*	01/set
2008*	03/set
2009*	05/ago
2010*	24/ago
2011*	24/jun
2012**	-
2013***	31/jul
2014***	19/ago
2015***	06/ago
2016***	08/ago
2017***	11/ago

*Satélite: Landsat 5 (Thematic Mapper – TM)

**Não há imagens do satélite Landsat para este ano

***Satélite: Landsat 8 (Operational Land Imager – OLI)

Fonte: Do autor (2019).

Índices espectrais

Sete índices foram selecionados por serem amplamente utilizados em estudos de detecção de mudanças (Tabela 3). Dentre os mais descritos na literatura, o Normalized Difference Vegetation Index – NDVI calcula a razão entre a diferença de reflectância do infravermelho próximo e do vermelho pela soma dessas bandas, resultando em valores que variam de -1 a 1. Os índices Soil Adjusted Vegetation Index – SAVI e sua variação Modified Soil-Adjusted Vegetation Index – MSAVI apresentam em suas fórmulas um fator (L) para a correção da influência do brilho dos solos, praticamente eliminando as variações induzidas pelo solo nos valores de reflectância (HUETE, 1988) (RONDEAUX; STEVEN; BARET, 1996). O Enhanced Vegetation Index – EVI, uma vez que este índice é mais sensível as variações do dossel, não saturando em locais onde há alta densidade de vegetação (HUETE et al., 2002). Os índices Normalized Burn Ratio – NBR, Normalized Burn Ratio 2 – NBR2 e o Normalized Difference Moisture Index – NDMI apresentam as bandas do infravermelho de ondas curtas em suas fórmulas, que apesar de serem bandas que dispõem de alta acurácia ao detectar polígonos de desmatamento e diferenciá-los de sazonalidade no Cerrado, vêm sendo pouco utilizadas em estudos neste bioma (BUENO et al., 2019).

Tabela 3. Índices de vegetação utilizados no estudo

Índice	Fórmula	Referência
EVI	$G \frac{\text{NIR}-\text{Red}}{\text{NIR}+C1*\text{Red}-C2*\text{Blue}+L}$	(HUETE, 1988)
SAVI	$\frac{\text{NIR}-\text{Red}}{\text{NIR}+\text{Red}} (1+L)$	(HUETE et al., 2002)
MSAVI	$\frac{2\text{NIR}+L-\sqrt{(2\text{NIR}+L)^2-8(\text{NIR}-\text{Red})}}{2}$	(RONDEAUX; STEVEN; BARET, 1996)
NBR	$\frac{\text{NIR} - \text{SWIR2}}{\text{NIR} + \text{SWIR2}}$	(MILLER; THODE, 2007)
NBR2	$\frac{\text{SWIR1} - \text{SWIR2}}{\text{SWIR1} + \text{SWIR2}}$	(MILLER; THODE, 2007)
NDMI	$\frac{\text{NIR} - \text{SWIR1}}{\text{NIR} + \text{SWIR1}}$	(WILSON; SADER, 2002)
NDVI	$\frac{\text{NIR} - \text{Red}}{\text{NIR} + \text{Red}}$	(TUCKER, 1979)

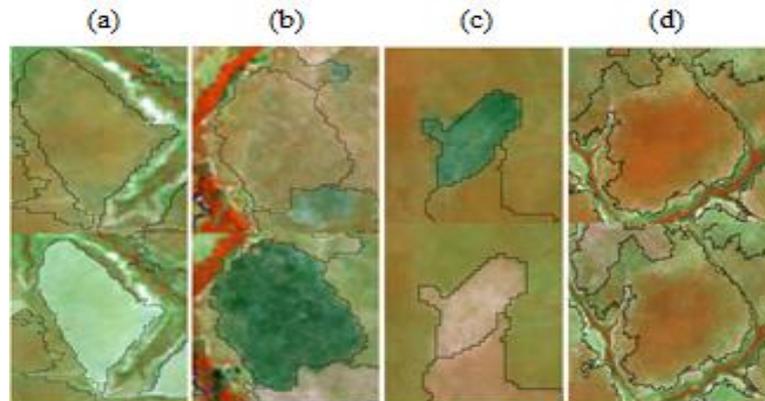
Fonte: Do autor (2019).

Obtenção das variáveis

O primeiro processo foi a geração das imagens diferenças de cada banda e índice espectral a partir da subtração da imagem de um ano pela imagem do ano anterior a ela. Em seguida, as imagens diferenças contendo as bandas espectrais foram segmentadas por meio do algoritmo de multiresolução (BAATZ; SCHÄPE, 2000) no *software* eCognition, onde escala, forma e compacidade foram definidos em 250, 0.1 e 0.5 respectivamente.

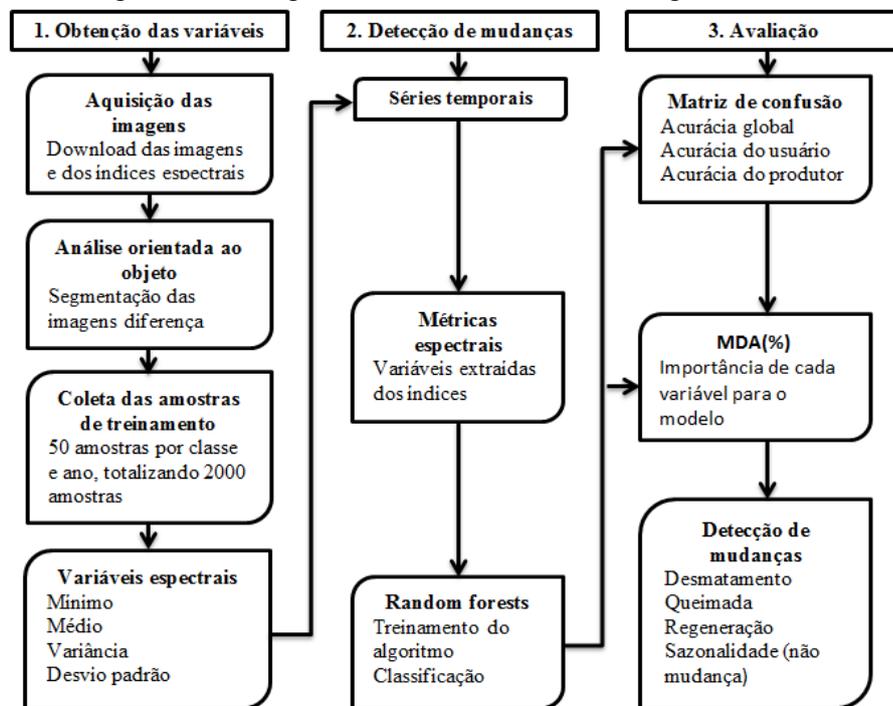
Foram coletadas amostras de treinamento e validação, 50 objetos por classe e ano, contemplando as classes: desmatamento, queimadas, regeneração e não mudança (áreas com sazonalidade) (Figura 3), totalizando 200 objetos por ano e 2.000 objetos em todos os 10 anos a serem analisados para cada índice espectral (Figura 4).

Figura 3. Exemplo das classes: (a) desmatamento; (b) queimada; (c) regeneração e (d) não mudança



Fonte: Do autor (2019).

Figura 4. Fluxograma detalhando a metodologia utilizada



Fonte: Do autor (2019).

Para cada objeto foram extraídos os valores de mínimo, média, máximo e desvio padrão de cada índice espectral.

Séries temporais

Variáveis de entrada foram submetidas a um treinamento e validação no algoritmo Random Forests (RF) (LIAW; WIENER, 2002) utilizando o *software* R (R Core Development Team 2014). O RF é um algoritmo de aprendizagem de máquina, que pode ser empregado em classificações ou regressões. Para isso cria árvores de decisão e as combina, visando previsões com maior acurácia e estabilidade (DEVRIES et al., 2016). A escolha deste

algoritmo foi baseada em sua grande eficácia ao realizar previsões, facilidade de implementação em grandes conjuntos de dados (BREIMAN, 2001), além de sua baixa sensibilidade a ruídos nas amostras de treinamento (BACCINI et al., 2008).

Uma amostra de 70% dos dados de entrada foi utilizada para treinamento enquanto os 30% restantes foram utilizados para validação. Dois parâmetros foram definidos para a execução do Random Forests: o número de árvores de decisão a serem geradas (Ntree), estabelecido em 500, e o número de variáveis a serem selecionadas e testadas por árvore (Mtry) igual a 1 (SILVEIRA et al., 2018b).

Avaliação

Após a classificação, o MDA% (Mean Decrease Accuracy) foi obtido para verificação do índice espectral mais importante para a classificação, ou seja, aquele que mais aumenta a precisão quando incluído no modelo. O MDA% consiste em um conjunto de dados que não são usados para construir as árvores aleatórias, mas sim para estimar o erro e prever a importância de uma variável para o modelo (HAN; GUO; YU, 2016).

Os erros das árvores criadas e os valores das acurácias (acurácia global, acurácia do produtor e acurácia do usuário) foram obtidos através da matriz de confusão (CONGALTON, 1991).

RESULTADOS

Classificação

A classificação obtida com o algoritmo Random Forest apresentou resultados satisfatórios na separação entre as classes desmatamento, queimadas, regeneração e não mudança, atingindo acurácia global de 92,37%. As maiores acurácias do usuário foram encontradas para as classes regeneração e desmatamento, sendo 96.75% e 95.46%, respectivamente. Dentre as classes analisadas, o desmatamento foi a que apresentou menor acuracidade do produtor (90.83%) (Tabela 4).

Tabela 4. Matriz de confusão

Classes	Ac. Usuário (%)	Ac. Produtor (%)
Desmatamento	95,46	90,83
Queimada	85,14	93,71
Não mudança	88,28	93,39
Regeneração	96,75	94,90
Ac. Global (%)	92,37	

Fonte: Do autor (2019).

O modelo foi executado 9 vezes, na primeira vez foram utilizadas todas as 4 variáveis (mínimo, médio, máximo e desvio padrão) extraídas dos 7 índices, totalizando 28 variáveis, e na última foram utilizadas apenas as 3 variáveis mais importantes para o modelo (alto MDA%), e a maior acurácia apresentada deu-se na matriz de confusão onde estavam incluídas todas as 28 variáveis, por isso pôde-se concluir que todas as variáveis provenientes de cada índice espectral utilizado contribuíram para a acurácia global obtida, mesmo as variáveis pouco importantes para o modelo (baixo MDA%) (Tabela 5).

Tabela 5. Matrizes de confusão obtidas a partir do número de variáveis espectrais

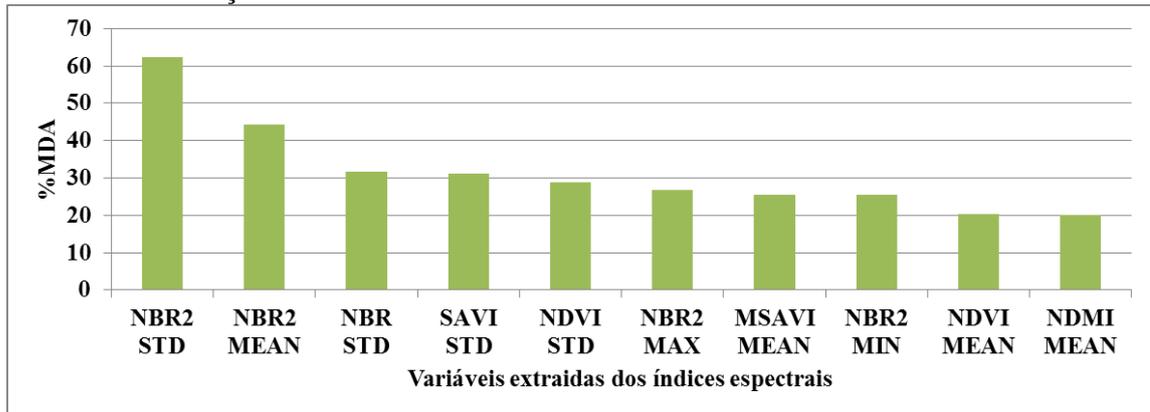
Matriz de confusão	Variáveis espectrais	Ac. Global (%)
1	28	92.37
2	23	91.01
3	18	91.66
4	14	91.27
5	11	91.53
6	9	91.14
7	7	90.63
8	5	89.99
9	3	83.83

Fonte: Do autor (2019).

Seleção dos índices

As variáveis de entrada que mais contribuíram para a alta acurácia global, sendo que entre os 10 índices que mais contribuíram para a precisão do modelo 7 possuem pelo menos uma das bandas do infravermelho de onda curta. Neste sentido o NBR2 foi o mais importante para a precisão do modelo, pois ao excluí-lo do mesmo a acurácia global decresceu cerca de 62,25% na estatística de desvio padrão, 44,21% na estatística de média, além de 26,75% e 25,36% nas estatísticas de máximo e mínimo respectivamente (Figura 5).

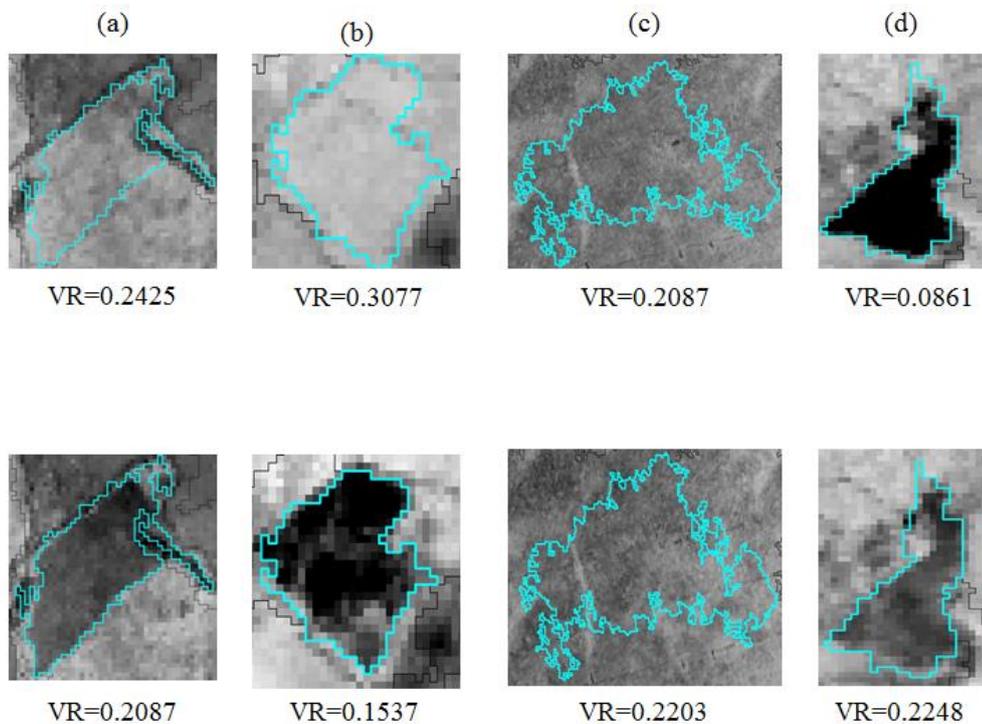
Figura 5. % Mean Decrease Accuracy (MDA) das 10 variáveis mais importantes utilizadas na classificação



Fonte: Do autor (2019).

O índice NBR2 também mostrou-se eficaz ao captar a sazonalidade (não mudança) na cena, pois houve pouca mudança no valor de reflectância dos polígonos desta classe, fazendo com que não houvesse conflito da mesma com as demais classes mapeadas no estudo. Também foi pouco suscetível ao problema de saturação, pois considerando que seus valores variam de -1 a 1, pôde-se notar que em polígonos onde havia vegetação densa estes valores ainda estavam distantes de seu máximo (Figura 6).

Figura 6. Diferença no Valor de Reflectância (VR) do índice NBR2 das classes: (a) Desmatamento; (b) Queimada; (c) Não mudança (sazonalidade); (d) Regeneração

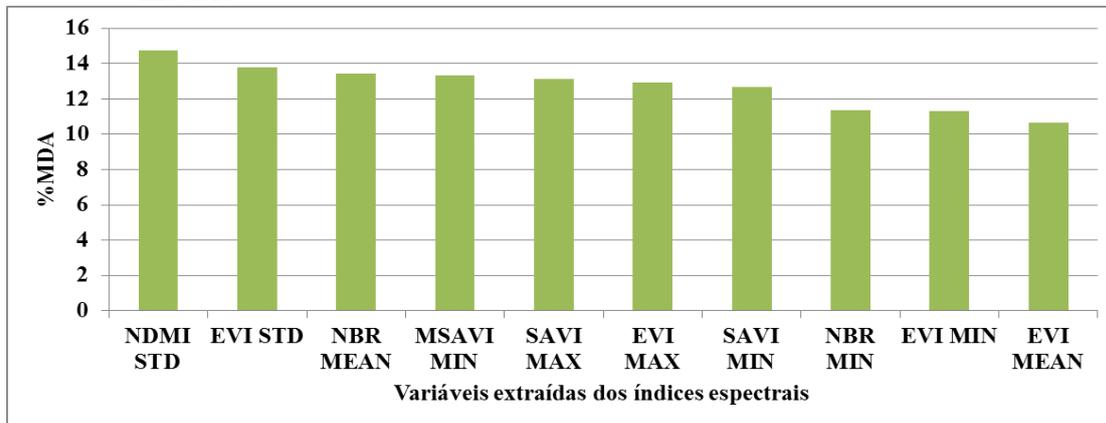


Fonte: Do autor (2019).

O índice espectral que menos influenciou a acurácia obtida foi o EVI, sendo que na variável média o índice apresentou MDA igual a 10.64%, também notou-se que dos índices

que utilizam as bandas do infravermelho de ondas curtas em suas equações, apenas as variáveis média e mínimo provenientes do NBR configuraram entre as 10 variáveis menos importantes para a acurácia do modelo (Figura 7).

Figura 7. % Mean Decrease Accuracy (MDA) das 10 variáveis menos importantes para o modelo



Fonte: Do autor (2019).

DISCUSSÃO

A sazonalidade e heterogeneidade de fitofisionomias em biomas do Cerrado faz com que haja diversos padrões espectrais para as classes de interesse, o que influi diretamente nos resultados de classificações provenientes de algoritmos como o Random Forests.

As acurácias do usuário e do produtor de todas as classes analisadas foram maiores que 85.14%, contribuindo para a alta acurácia global de 92.37%, o que é consequência da robustez do modelo construído para treinamento do Random Forests, e da qualidade das amostras coletadas, onde houve boa separabilidade entre as classes que foram classificadas pelo algoritmo, com intervalos de reflectância bem definidos. Dos 7 índices utilizados, o NBR2 obteve maior êxito na discriminação entre polígonos de queimada, desmatamento, regeneração e sazonalidade, isto também pôde ser notado em outros trabalhos que tiveram regiões do Cerrado Brasileiro como área de estudo, comprovando a capacidade do índice em apresentar altas acurácias na separabilidade destas classes em áreas heterogêneas.

Chan; Paelinckx, (2008) compararam o algoritmo Random Forest com o algoritmo Adaboost, os dois apresentaram acurácias similares, porém o Random Forest mostrou-se mais rápido e estável, além disso, ambos os algoritmos obtiveram melhores resultados quando utilizaram bandas do infravermelho de ondas curtas, o que demonstra a importância dessas bandas para estudos ambientais quando associadas a variáveis espectrais.

O índice espectral NBR2 utiliza as bandas do infravermelho de ondas curtas em sua equação, bandas estas que são menos impactadas por ruídos atmosféricos, e que geralmente apresentam valores baixos para florestas e altos para solos e componentes não fotossintéticos da vegetação (BANSKOTA et al., 2014), ao contrário do NDVI, que é altamente impactado pelo solo e por ruídos atmosféricos (SCHROEDER et al., 2011). Isto faz com que os índices calculados a partir das bandas do infravermelho de ondas curtas sejam eficazes em caracterizar e identificar mudanças na estrutura de povoamentos florestais, reforçando sua importância em estudos ecológicos que envolvem sensoriamento remoto (COHEN; GOWARD, 2004).

Bueno et al. (2019) utilizaram uma cena contida no Cerrado em seu estudo, e a partir de variáveis extraídas de índices espectrais a classificou com intuito de diferenciar polígonos de desmatamento e sazonalidade, onde pôde concluir que os índices que possuem a banda do infravermelho curto 2 (SWIR2) em suas equações apresentaram maior acurácia, o que comprova o potencial dessas bandas em detectar desmatamentos, mesmo diante de altos níveis de sazonalidade.

Num estudo com o objetivo de separar queimadas de outros alvos utilizando uma cena Landsat no Cerrado, MIRBI e NBR2 foram os índices que resultaram em maior separabilidade (PEREIRA et al., 2016). O índice NBR apresentou resultados significativos para o mesmo propósito na cena 220/68, inserida no Cerrado, onde os erros de omissão e comissão foram inferiores a 5% (BARROSO; SANO; FREITAS, 2017). Já Melchiori et al. (2015) concluiu que os índices espectrais que apresentaram maior capacidade de discriminação de áreas queimadas no Cerrado foram o NBR2 e NDVI. Considerando o mapeamento de áreas em regeneração no Cerrado o NBR foi o índice que apresentou melhor distinção entre as fisionomias vegetais (RESENDE et al., 2015).

CONCLUSÕES

Por meio da validação dos valores espectrais no algoritmo Random Forest, foi possível observar que todos os 7 índices utilizados no estudo contribuíram para a alta separação entre as amostras de queimada e desmatamento, sendo que os índices NBR2 e NBR foram os mais significativos neste sentido.

Conclui-se que os índices espectrais possuem grande potencial no que se diz respeito ao monitoramento de queimadas e desmatamentos no Cerrado brasileiro. A partir deles é possível detectar, separar e quantificar com maior precisão estas mudanças, o que poderá

facilitar e automatizar o aumento e a manutenção das bases de dados existentes para este bioma.

REFERÊNCIAS

- ASNER, G. P. et al. Ecosystem structure throughout the Brazilian Amazon from Landsat observations and automated spectral unmixing. **Earth Interactions**, v. 9, n. 7, p. 1–31, 2005.
- BAATZ, M.; SCHÄPE, A. Multiresolution Segmentation: An Optimization Approach for High Quality Multi-Scale Image Segmentation. In: **Angewandte Geographische Informations-Verarbeitung XII**. [s.l.: s.n.]. p. 12–23.
- BACCINI, A. et al. A first map of tropical Africa's above-ground biomass derived from satellite imagery. **Environmental Research Letters**, v. 3, n. 4, 2008.
- BANSKOTA, A. et al. Forest Monitoring Using Landsat Time Series Data: A Review. **Canadian Journal of Remote Sensing**, v. 40, n. 5, p. 362–384, 2014.
- BARBOSA, K. M. DO N. **Monitoramento Espacial de Biomassa e Carbono Orgânico da Vegetação Herbácea de Várzea na Amazônia Central**. [s.l.: s.n.].
- BARROSO, A. G.; SANO, E. E.; FREITAS, D. M. DE. IDENTIFICAÇÃO DE DESMATAMENTOS NO CERRADO UTILIZANDO TÉCNICAS DE DIFERENÇA DE IMAGENS E ÍNDICE DE QUEIMADA POR DIFERENÇA NORMALIZADA. **Rev. Bras. Cartografia**, v. 69, n. 7, p. 1397–1409, 2017.
- BAYMA, A. P.; SANO, E. E. Boletim de Ciências Geodésicas. **Boletim de Ciências Geodésicas**, v. 21, n. 4, p. 797–813, 2015.
- BREIMAN, L. RANDOM FORESTS. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001.
- BUENO, I. et al. Object-Based Change Detection in the Cerrado Biome Using Landsat Time Series. **Remote Sensing**, v. 11, n. 570, p. 1–14, 2019.
- CHAN, J. C. W.; PAELINCKX, D. Evaluation of Random Forest and Adaboost tree-based ensemble classification and spectral band selection for ecotope mapping using airborne hyperspectral imagery. **Remote Sensing of Environment**, v. 112, n. 6, p. 2999–3011, 2008.
- COHEN, W. B.; GOWARD, SAMUEL N. Landsat's Role in Ecological Applications of Remote Sensing. **Bioscience**, v. 54, n. 6, p. 535–545, 2004.
- COLDITZ, R. R. An evaluation of different training sample allocation schemes for discrete and continuous land cover classification using decision tree-based algorithms. **Remote Sensing**, v. 7, n. 8, p. 9655–9681, 2015.
- CONGALTON, R. G. A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data. **Remote Sensing of Environment**, v. 37, n. 1, p. 35–46, 1991.
- COPPIN, P. R.; BAUER, M. E. Digital Change Detection in Forest Ecosystems with Remote Sensing Imagery. **Remote Sensing Reviews**, v. 13, n. 3–4, p. 207–234, 1996.
- COUTINHO, L. M. O bioma do Cerrado. In: **Eugen Warming e o Cerrado brasileiro um século depois**. [s.l.: s.n.]. p. 77–91.
- DEVRIES, B. et al. Characterizing Forest Change Using Community-Based Monitoring Data and Landsat Time Series. **PLOS ONE**, v. 11, n. 3, p. 1–25, 28 mar. 2016.
- FERREIRA, M. E. et al. Desmatamentos no bioma Cerrado: uma análise temporal (2001–2005) com base nos dados MODIS - MOD13Q1. **XIII Simpósio Brasileiro de Sensoriamento Remoto**, p. 3877–3883, 2007.
- FIGUEIREDO, D. Conceitos Básicos de Sensoriamento Remoto. **Companhia Nacional de Abastecimento-CONAB**, v. 1, p. 32, 2005.
- HAAS, J.; BAN, Y. International Journal of Applied Earth Observation and Geoinformation Urban growth and environmental impacts in Jing-Jin-Ji, the Yangtze, River Delta and the Pearl River Delta. **International Journal of Applied Earth Observations and Geoinformation**, v. 30, p. 42–55, 2014.
- HALL, O.; HAY, G. J. A multiscale object-specific approach to digital change detection. **International Journal of Applied Earth Observation and Geoinformation**, v. 4, n. 4, p. 311–327, 2003.

- HAN, H.; GUO, X.; YU, H. **Variable selection using Mean Decrease Accuracy and Mean Decrease Gini based on Random Forest**. Proceedings of the IEEE International Conference on Software Engineering and Service Sciences, ICSESS. **Anais...IEEE**, 2016
- HUETE, A. et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, p. 195–213, 2002.
- HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295–309, 1988.
- JIN, S. et al. A comprehensive change detection method for updating the National Land Cover Database to circa 2011. **Remote Sensing of Environment**, v. 132, p. 159–175, 2013.
- JIN, Y. et al. Mapping deforestation in north korea using phenology-based multi-index and random forest. **Remote Sensing**, v. 8, n. 12, p. 1–15, 2016.
- JUNIOR, A. C. DE S. C. **Monitoramento Do Cerrado Em Minas Gerais Usando Análises Estatísticas Baseadas Em Objetos** : [s.l: s.n.].
- JÚNIOR, O. A. DE C. et al. CLASSIFICAÇÃO DE PADRÕES DE SAVANA USANDO ASSINATURAS TEMPORAIS NDVI DO SENSOR MODIS NO PARQUE NACIONAL CHAPADA DOS VEADEIROS. **Revista Brasileira de Geofísica**, v. 26, n. 4, p. 505–517, 2008.
- KLINK, C. A.; MACHADO, R. B. A conservação do Cerrado brasileiro. **MEGADIVERSIDADE**, v. 1, n. 1, p. 147–155, 2005.
- LAMBIN, E. F. Monitoring Forest Degradation in Tropical Regions by Remote Sensing : Some Methodological Issues Eric F . Lambin. **Global Ecology and Biogeography**, v. 8, n. 3, p. 191–198, 1999.
- LIAW, A.; WIENER, M. Classification and Regression by random forest. **R News**, v. 2, p. 18–22, 2002.
- MELCHIORI, A. E. et al. Spectral indices and multi-temporal change image detection algorithms for burned area extraction in the Brazilian Cerrado. **XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, v. 17, n. 1, p. 643–650, 2015.
- MILLER, J. D.; THODE, A. E. Quantifying burn severity in a heterogeneous landscape with a relative version of the delta Normalized Burn Ratio (dNBR). **Remote Sensing of Environment**, v. 109, n. 1, p. 66–80, 2007.
- MITTERMEIER, RUSSELL A. et al. A Brief History of Biodiversity Conservation in Brazil. **Conservation Biology**, v. 19, n. 3, p. 601–607, 2005.
- MYERS, N. et al. Biodiversity hotspots for conservation priorities. **Nature**, v. 403, n. 24, p. 853–858, 2000.
- NASA. **Landsat Science**. Disponível em: <<https://landsat.gsfc.nasa.gov/>>. Acesso em: 17 maio. 2019.
- PEREIRA, A. A. et al. Avaliação de nove índices espectrais quanto a separabilidade entre queimadas e diferentes alvos. **XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, v. 17, p. 3105–3112, 2015.
- PEREIRA, A. A. et al. Avaliação de índices espectrais para identificação de áreas queimadas no cerrado utilizando dados LandSat TM. **Rev. Bras. Cartogr**, v. 68, n. 8, p. 1665–1680, 2016.
- PEREIRA, A. A. **Queimadas No Bioma Cerrado**. [s.l: s.n.].
- PRADO, L. D. A.; MAZIARA, F.; FERREIRA, M. E. EXPANSÃO DA FRONTEIRA AGRÍCOLA E MUDANÇAS NO USO DO SOLO NA REGIÃO SUL DE GOIÁS: AÇÃO ANTRÓPICA E CARACTERÍSTICAS NATURAIS DO ESPAÇO. **B.goiano.geografia. Goiânia**, v. 32, n. 1, p. 151–165, 2012.
- Projeto Monitoramento Cerrado**. Disponível em: <<http://www.obt.inpe.br/cerrado/>>. Acesso em: 14 maio. 2019.
- R CORE DEVELOPMENT TEAM. **A language and environment for statistical**

computing. [s.l: s.n.].

RAMOS, M. V. V. et al. Veredas do triângulo mineiro: solos, água e uso. **Ciência e Agrotecnologia**, v. 30, n. 2, p. 283–293, 2006.

RESENDE, F. C. et al. **Análise de Índices Espectrais para Estimativa de Áreas de Regeneração Florestal no Parque Nacional Chapada Das Mesas.** [s.l.] Unspecified, 2015. v. 3

RIBEIRO, J. F.; WALTER, B. M. T. Fitofisionomias do bioma Cerrado. In: **Cerrado : ambiente e flora.** [s.l: s.n.]. p. 556.

RONDEAUX, G.; STEVEN, M.; BARET, F. Optimization of soil-adjusted vegetation indices. **Remote Sensing of Environment**, v. 55, n. 2, p. 95–107, 1996.

SANO, E. E. et al. Land cover mapping of the tropical savanna region in Brazil. **Environmental Monitoring and Assessment**, v. 166, n. 1–4, p. 113–124, 2010.

SAWYER, D. População , Meio Ambiente e Desenvolvimento Sustentável no Cerrado. In: **População, Meio Ambiente e Desenvolvimento Sustentável no Cerrado.** [s.l: s.n.]. p. 279–302.

SCHROEDER, T. A. et al. Mapping wildfire and clearcut harvest disturbances in boreal forests with Landsat time series data. **Remote Sensing of Environment**, v. 115, n. 6, p. 1421–1433, 2011.

SILVEIRA, E. M. DE O. et al. Reducing the effects of vegetation phenology on change detection in tropical seasonal biomes. **GIScience and Remote Sensing**, v. 00, n. 00, p. 1–19, 2018a.

SILVEIRA, E. M. O. et al. Using spatial features to reduce the impact of seasonality for detecting tropical forest changes from landsat time series. **Remote Sensing**, v. 10, n. 808, p. 1–21, 2018b.

SINGH, A. Review Article: Digital change detection techniques using remotely-sensed data. **International Journal of Remote Sensing**, v. 10, n. 6, p. 989–1003, 1989.

STRASSBURG, B. B. N. et al. Moment of truth for the Cerrado hotspot. **Nature Ecology and Evolution**, v. 1, n. 4, p. 1–3, 2017.

TerraBrasilis. Disponível em:

<<http://terrabrasilis.dpi.inpe.br/map/dashboard/deforestation/biomes/cerrado/increments>>.

Acesso em: 4 abr. 2019.

TSUTSUMIDA, N.; COMBER, A. J. International Journal of Applied Earth Observation and Geoinformation Measures of spatio-temporal accuracy for time series land cover data. **International Journal of Applied Earth Observations and Geoinformation**, v. 41, p. 46–55, 2015.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p. 127–150, 1979.

WILSON, E. H.; SADER, S. A. Detection of forest harvest type using multiple dates of Landsat TM imagery. **Remote Sensing of Environment**, v. 80, n. 3, p. 385–396, 2002.

ZHANG, K. et al. Remote sensing of seasonal changes and disturbances in mangrove forest: A case study from South Florida. **Ecosphere**, v. 7, n. 6, p. 1–23, 2016.