Revista Brasileira de Geografia Física

Homepage: <https://periodicos.ufpe.br/revistas/rbgfe>

Análise de acurácia para o mapeamento de áreas queimadas utilizando uma cena VIIRS 1Km e classificação por Random Forest

Juarez Antônio da Silva Júnior¹, Ubiratan Joaquim da Silva Júnior², Admilson da Penha Pacheco³

¹ Graduado em Engenharia Cartográfica e de Agrimensura pela Universidade Federal de Pernambuco (UFPE). Departamento de Engenharia Cartográfica e de Agrimensura (Decart), Av. Prof. Moraes Rego, 1235 - Cidade Universitária, Recife - PE - CEP: 50670-901. juarez.ufpe@gmail.com. ² Mestre em Ciências Geodésicas e Tecnologias da Geoinformação pela Universidade Federal de Pernambuco (UFPE). Departamento de Engenharia Cartográfica e de Agrimensura (Decart), Av. Prof. Moraes Rego, 1235 - Cidade Universitária, Recife - PE - CEP: 50670-901. ubiratan.joaquim@ufpe.br. ³ Doutor em Geofísica pela Universidade de São Paulo (USP). Instituto Astronômico e Geofísico (IAG), R. da Reitoria, 374 - Cidade Universitária, Butantã, São Paulo - SP, 05508-220. admilson.pacheco@ufpe.br.

Artigo recebido em 20/01/2021 e aceito em 14/09/2021

RESUMO

A disponibilidade de dados de sensoriamento remoto com média resolução espacial tem oferecido diversas possibilidades de mapeamentos para áreas atingidas por incêndios florestais na superfície terrestre. Neste contexto, análises de limitações de precisão espacial dos sensores tem sido objeto de pesquisas globais. O objetivo deste estudo foi analisar a acurácia de mapeamento do sensor VIIRS a bordo do satélite NOAA, utilizando o classificador Random Forest (RF) para a detecção de áreas queimadas, em quatro pontos do Parque Nacional da Chapada dos Veadeiros - Goiás, inserido na savana brasileira. A metodologia consistiu em validar a classificação por meio do coeficiente de Sorensen-Dice (DC) numa abordagem estratificada, tendo como referência os produtos: Aq30m, Fire_cci e MCD64A1. Como resultado, os modelos de RF, incluíram 400 árvores e um atributo, com erro inferior a 4%. Dentre os modelos globais, o MCD64A1 apresentou uma exatidão significativa, superior a 50%, sobretudo em feições de áreas queimadas superiores a 200Km². Com isso, os dados sugerem que a qualidade de acurácia do processo de validação de produtos de mapeamento para áreas queimadas está associada ao intervalo temporal mínimo de disponibilidade dos dados de validação e o tamanho da área atingida pelo fogo. Baseado nisto, os resultados mostram eficácia na utilização do algoritmo RF em imagens de média resolução espacial para detecção de queimadas em florestas sazonalmente secas, como o Cerrado.

Palavras-Chave: Cerrado, queimadas, Random Forest.

Accuracy analysis for mapping burnt areas using a 1Km VIIRS scene and Random Forest classification

ABSTRACT

The availability of remote sensing data with medium spatial resolution has offered several mapping possibilities for areas affected by forest fires on the Earth's surface. In this context, the analysis of sensor spatial accuracy limitations has been the subject of global research. The objective of this study was to analyze the mapping accuracy of the VIIRS sensor on board the NOAA satellite, using the Random Forest (RF) classifier for the detection of burned areas, in four points of the Chapada dos Veadeiros National Park - Goiás, inserted in the Brazilian savanna. The methodology consisted in validating the classification using the Sorensen-Dice coefficient (SD) in a stratified approach, using as reference the products: Aq30m, Fire_cci and MCD64A1. As a result, the RF models, included 400 trees and one attribute, with an error of less than 4%. Among the global models, the MCD64A1 presented a significant accuracy, greater than 50%, especially in features of burned areas greater than 200Km². Thus, the data suggest that the quality of accuracy of the validation process of mapping products for burned areas is associated with the minimum time interval of availability of validation data and the size of the area affected by fire. Based on this, the results show effectiveness in using the RF algorithm on medium spatial resolution images for fire detection in seasonally dry forests, such as the Cerrado.

Keywords: Cerrado, fires, Random Forest.

Introdução

O fogo é um dos principais fatores que afetam a degradação florestal em regiões tropicais, principalmente em anos secos, onde essas regiões

se tornam uma fonte líquida de carbono (Lizundia-Loiola; Pettinari; Chuvieco, 2020), a exemplo do Cerrado, inserido na Savana brasileira. Com isso,

quantificar os incêndios florestais continua sendo uma tarefa desafiadora para a implementação de políticas públicas voltadas para a mitigação das mudanças climáticas (Shimabukuro et al., 2020). No Cerrado, além da presença natural do fogo em períodos secos (Oliveira et al., 2021) o aumento das atividades antrópicas, como silvicultura, agricultura e pecuária, teve impactos severos neste ecossistema, representando a principal ameaça à conservação deste bioma (Alencar et al., 2020). Com isso, mapear as mudanças no regime de fogo é, essencial para a conservação eficaz dessa vegetação ameaçada e fragmentada da Savana brasileira (Conciani et al., 2021).

Neste aspecto, dados de sensoriamento remoto (SR) têm sido, por décadas, usados para avaliação e monitoramento objetivos, precisos e sistemáticos de incêndios florestais (Kganyago & Shikwambana, 2020). A exemplo do produto de área queimada do Conjunto de Radiômetro de Imagem Infravermelho Visível (VIIRS) (Vermote; Franch; Claverie, 2016) com resolução espacial grosseira, que fornece informações para os múltiplos usuários envolvidos em ciência do fogo e suas diversas aplicações (Boschetti et al., 2019). Há, no entanto, uma grande demanda por produtos de área queimada de média a alta resolução espacial (Conciani et al., 2021) que proporcionariam um aperfeiçoamento da contabilidade do orçamento de carbono e estimativa de emissões pirogênicas (Van der Werf et al., 2017), estimativas dos impactos do fogo na dinâmica da vegetação (Bowman et al., 2015), avaliação pós-fogo e remediação, dentre outros (Trigg e Roy, 2007; Mouillot et al., 2014).

Os algoritmos de detecção de área queimada são diversos e possuem múltiplas aplicações por meio de dados derivados de SR (Arvor et al., 2021). Entretanto, na maioria das vezes, visam discriminar áreas queimadas em condições locais-regionais, dificultando a generalização para outros locais com características de incêndio diferentes. Com isso, considerando a ampla variedade de condições de queima em todo o mundo, torna-se desafiador projetar um algoritmo de área queimada global. Em alguns casos, esses algoritmos contam com princípios físicos que são adaptados localmente (Giglio et al., 2009; Alonso-Canas e Chuvieco, 2015). Neste aspecto, informações de precisão e desempenho dos produtos derivados das imagens de satélite possibilitam uma utilização adequada pelos usuários nos mapeamentos (Arvor et al., 2021). Portanto, para produtos globais, devido ao grande número de fatores que podem afetar

adversamente sua qualidade de mapeamento (Roy et al., 2019), a avaliação é necessária e indispensável.

O Random Forest (RF) (Breiman, 2001) é um dos algoritmos mais frequentemente usado para classificação de imagens de satélite (Rodriguez-Galiano et al., 2012; Belgiu e Drăguț, 2016). Seu potencial para integrar dados de diferentes escalas e fontes, e sua robustez a ruídos e distribuições não normais explicam o amplo uso de RF para muitas aplicações de imagens de satélite (Ramo e Chuvieco, 2017). Arvo et al. (2021), analisou o desempenho do RF para o mapeamento de áreas desmatadas na Amazônia Brasileira a partir de imagens derivadas do satélite Sentinel 2. Tanase et al. (2020), avaliaram os produtos derivados do algoritmo para imagens Sentinel 1 analisando a detecção de áreas queimada na África do Sul. Bispo et al. (2020), realizaram um mapeamento de biomassa lenhosa no Cerrado através do RF, identificando os estágios de regeneração da vegetação. O RF também foi aplicado para pesquisas de incêndios florestais, na previsão de ocorrência de incêndios (Oliveira et al., 2012), determinação de fatores de severidade de incêndios (Holden; Morgan; Evans, 2009) e caracterização dos regimes de fogo (Archibald et al., 2009; Aldersley; Murray; Cornell, 2011). Entretanto, ainda não foi testado para queimadas discriminação de área.

Portanto, este trabalho objetiva discutir os resultados obtidos por dados de sensoriamento remoto a partir de imagens do VIIRS (1Km) e o algoritmo de classificação de imagem Random Forest para a detecção de áreas queimadas bem como a avaliação dos parâmetros dos modelos de classificação. A metodologia desenvolvida é validada em uma área de estudo de recobrimento da cena VIIRS selecionada em quatro órbitas/ponto do Landsat, através dos dados de referência espacial de área queimada com resolução espacial mais fina.

Material e métodos

Dados

Nesta pesquisa foi utilizado uma cena do sensor VIIRS (VNP09GA.A2019260.h13v10.001.20192610735 23) datada 17 de setembro de 2019 disponibilizado pela plataforma LP DAAC (<https://lpdaac.usgs.gov/products/vnp09gav001/>). O produto diário (VNP09GA) fornece uma estimativa da refletância diária da superfície terrestre a bordo do satélite NOAA/NASA *Suomi-*

National Polar-Orbiting Partnership (S-NPP). Os dados são fornecidos para nove bandas de resolução moderada (M1, M2, M3, M4, M5, M7, M8, M10, M11) com resolução espacial de 1 quilômetro (Tabela 1).

Tabela 1. Características espectrais do sensor orbital VIIRS.

Banda	Condução de registros de dados ambientais	Faixa Espectral (μm)
M1	Cor do Oceano e Aerossol	0.40 - 0.42
M2	Cor do Oceano e Aerossol	0.43 - 0.45
M3	Cor do Oceano e Aerossol	0.47 - 0.49
M4	Cor do Oceano e Aerossol	0.54 - 0.56
M5	Cor do Oceano e Aerossol	0.66 - 0.68
M7	Cor do Oceano e Aerossol	0.84 - 0.88
M8	Tamanho de partícula da nuvem	1.23 - 1.25
M10	Neve	1.58 - 1.64
M11	Nuvens	2.22 - 2.27

O produto VNP09GA é referenciado a um Sistema de Coordenadas Sinusoidal Projetado, entretanto a cena foi convertida para o sistema SIRGAS2000 através do código em linguagem Python disponível em: (<https://lpdaac.usgs.gov/resources/elearning/worki-ng-daily-nasa-viirs-surface-reflectance-data/>).

Para fornecer uma estimativa da refletância espectral da superfície como seria medida ao nível do solo, essas bandas são adquiridas com correção atmosférica, reduzindo os efeitos das perturbações causadas por gases moleculares, incluindo ozônio e vapor de água e aerossóis atmosféricos (Vermote, 2016).

Vizualização das amostras em campo

A caracterização visual da área queimada presente no local de estudo ocorreu através de visitas em campo no período de maio a novembro de 2019, na Reserva Chapada dos Veadeiros-GO (completamente inserida na cena VIIRS). As fotografias foram registradas por um *smartphone* e um aplicativo GPS presente no mesmo, onde foi possível compreender espaço-temporalmente a compreensão da dinâmica da

vegetação pré- e pós-incêndio do Bioma Cerrado. O mapa da (Figura 1) mostra os pontos fotografados bem como suas coordenadas geográficas.

Figura 1. Localização dos pontos na paisagem fotografados no Parque Nacional da Chapada dos Veadeiros-GO pré- e pós-incêndio nos meses de maio a novembro de 2019.

Classificação Random Forest

O algoritmo Random Forest, proposto por (Breiman, 2001), é um método composto por um conjunto de árvores de decisão que são construídas a partir de dados de treinamento amostral tomadas aleatoriamente a partir das quais uma atribuição de classe final é determinada. Dessa forma, as florestas aleatórias são criadas calculando a média das árvores. Uma árvore de decisão é uma sequência de regras que dividem o espaço de recursos em partições com valores semelhantes à variável de resposta (Kantola *et al.*, 2010).

Para implementar o RF (Breiman, 2001), dois parâmetros precisam ser configurados: o número de árvores (*ntree*) e o número de feições em cada divisão (*mtry*). Vários estudos afirmam que resultados satisfatórios podem ser alcançados com os parâmetros padrão (Duro; Franklin; Dubé, 2012; Zhang e Roy, 2017; Noi e Kappas, 2018). Porém, segundo (Liaw e Wiener, 2002), o grande número de árvores proporcionará um resultado estável de importância variável. Além disso, (Breiman, 2001) afirmou que usar mais árvores do que o necessário pode ser desnecessário, mas isso não prejudica o modelo. Em relação ao parâmetro *mtry*, seguimos o recomendado por (Duro; Franklin; Dubé, 2012) e foi utilizado um valor padrão $mtry = \sqrt{p}$ para classificações de categoria binária, onde *p* é o número de variáveis preditoras.

Neste estudo, para encontrar o modelo de RF ideal para classificação, uma faixa de valores de *ntree* de 50 a 400 foi testada e avaliada para *mtry* = 1,41 $\approx$ 1. A seguir é mostrado as etapas do algoritmo RF: **Algoritmo: Entrada:** tamanho da floresta (número de *ntree*). **Etapa 1** - Seleção de amostra aleatória de um determinado conjunto de dados de um determinado tamanho. **Etapa 2** - O algoritmo constrói um conjunto de árvores de decisão (floresta aleatória) para o conjunto de dados com base no tamanho de floresta. Aqui o modelo é treinado. **Etapa 3** - Para cada instância de teste, a votação será realizada em cada uma das árvores de decisão para gerar o resultado da previsão. **Etapa 4** - Por fim, é selecionado o resultado de previsão mais votado como o resultado da previsão. **Saída:** classe prevista (1 para incêndio previsto e 0 para nenhum incêndio previsto).

No final da execução, o algoritmo RF calcula a proporção entre as classificações erradas e o número total de elementos resultando numa estimativa de erro de generalização denominado (OOB) Erro Fora da Bolsa (Out-of-Bag) (Breiman, 2001). O erro OOB utiliza 1/3 do número total de árvores geradas no conjunto e converge conforme o número de árvores aumenta, portanto, o RF não se ajusta aos dados. O RF também fornece uma avaliação da importância relativa dos diferentes recursos ou variáveis durante o processo de classificação. Esse aspecto é útil para estudos de múltiplas fontes, onde a dimensionalidade dos dados é muito alta, e é importante saber como cada variável preditiva influencia o modelo de classificação para poder selecionar as melhores variáveis (Ghimire *et al.*, 2010). Para avaliar a importância de cada característica (por exemplo, bandas de uma imagem de satélite), o RF muda uma das variáveis aleatórias de entrada, mantendo o resto constante, e mede a diminuição na precisão que ocorreu por meio da estimativa de acurácia medido através do índice de Gini (Breiman, 2001).

Segundo Lawrence; Wood; Sheley, 2006, Brewer *et al.*, 2005, o Random Forest tem uma alta precisão de predição e alta tolerância a *outliers* e “ruído”, e tem mostrado boa capacidade de predição na previsão de incêndios florestais.

Validação de áreas queimadas

Com a finalidade de comparar espacialmente a área queimada e avaliar a qualidade do mapa gerado por dados do sensor VIIRS pós classificação RF, foram utilizados dados de referência espacial de área queimada através de produtos oficiais e modelos globais. A validação foi, portanto, realizada através dos

produtos Aq30m, Fire_cci e MCD64A1 através de quatro locais delimitada por orbitas/ponto da grade Landsat, na parte central do bioma Cerrado, (Figura 2).

Figura 2. Local de estudo compreende parte do Bioma Cerrado e os estados de Minas Gerais e Bahia.

Ressalta-se que as datas dos produtos utilizados como validação foram as mais próximas possíveis a data de gravação da imagem do sensor VIIRS e o intervalo de tempo máximo permitido entre cenas consecutivas é de um mês. O MCD064A1 e o Fire_cci são disponibilizados mensalmente, e por isso, foram utilizados os dados referentes ao período de setembro de 2019.

Produtos de Validação

Aq30m

Os dados de referência espacial de áreas queimadas foram disponibilizados gratuitamente pelo Sistema de Monitoramento de Queimadas do INPE, através da plataforma BDQueimadas (<http://queimadas.dgi.inpe.br/queimadas/bdqueimadas/>), em formato *shapefile* nas datas próximas das cenas utilizadas. Os dados são distribuídos em polígonos vetoriais georreferenciados representando as estimativas das cicatrizes das áreas queimadas geradas a partir de imagens de resolução espacial 30 metros.

MODIS/ Terra e Aqua Burned Area (MCD64A1)

O produto de dados de Área queimada MCD64A1 Versão 6 combinado dos satélites Terra e Aqua é um produto mensal em grade global de 500 metros (m) contendo informações de qualidade e área queimada por pixel. A abordagem de mapeamento de área queimada MCD64A1 emprega Imagens do Espectrorradiômetro de

Imagem de Resolução Moderada (MODIS), juntamente com observações de fogo ativo MODIS de 1 quilômetro (km), onde algoritmo identifica a data de queima das células de grade de 500 m em cada bloco MODIS individual (Giglio *et al.*, 2015).

Fire_cci

O produto de pixel de área queimada MODIS Fire_cci versão 5.1 (FireCCI51) é um conjunto de dados de resolução espacial global mensal de resolução espacial de 250m, contendo informações sobre a área queimada, bem como dados auxiliares. Baseia-se na refletância de superfície na faixa do infravermelho próximo (NIR) do instrumento MODIS a bordo do satélite Terra, bem como nas informações de fogo ativo do mesmo sensor dos satélites Terra e Aqua. O FireCCI51 foi desenvolvido como parte do Programa ESA Climate Change Initiative (CCI), e faz parte do Serviço de Mudanças Climáticas Copernicus (C3S) (Chuvieco *et al.*, 2018).

Procedimento de Validação Coeficiente de Sorensen-Dice

A qualidade de um determinado mapa temático derivado de sensoriamento remoto é geralmente avaliada com base em uma comparação sistemática com outros mapas também derivados de sensoriamento remoto. A avaliação da qualidade é geralmente realizada com base em medidas de verificação derivadas de tabelas de contingência (Tabela 2) (Story e Congalton, 1986). Neste trabalho, a medida de verificação utilizada é a Coeficiente Sørensen–Dice (DC) definida como uma medida de similaridade entre o classificador e o mapa de referência em termos do número de pixels queimados comuns, Equação 1.

$$DC = \frac{2}{2 + \frac{EO}{1 - EO} + \frac{EC}{1 - EC}} \quad (1)$$

As medidas gerais de Erro de Omissão (EO) e Erro de Comissão (EC) podem ser calculadas diretamente para um mapa de área queimada e não queimada, contando o número de pixels em cada categoria. No entanto, para uma análise mais precisa, precisamos medir a precisão de cada cicatriz de validação. A definição de erro de omissão é a proporção da cicatriz queimada que não foi corretamente classificada pelo algoritmo. Em contrapartida, a definição de erro de comissão que é o erro cometido ao atribuir um pixel à classe *i*, quando este pertence a alguma outra classe. O Coeficiente (DC) varia de 0 a 1, onde valores

próximos ou igual 1 corresponde a maior fração de sobreposição de pixels classificados como queimados para aqueles realmente queimados no mapa de referência enquanto valores próximos ou igual a 0 corresponde ausência de sobreposição da categoria de presença.

Tabela 2. Tabela de contingência para o caso dicotômico de pixels classificados como queimados vs. não queimados em uma determinada região de estudo.

		Referência		
		Q	NQ	
Produto	Q	a	b	a + b
	NQ	c	d	c + d
		a + c	b + d	a + b + c + d

Análise de Regressão Linear

A proporção de pixels detectadas como queimadas pela classificação RF na imagem do sensor VIIRS foi comparada com a proporção marcada como queimada nos dados de referência Aq30m, Fire_cci e MCD64A1 independentes através de uma regressão linear, Equação 2.

$$Y = b + aX \quad (2)$$

As linhas de regressão foram ajustadas aos dados; a inclinação (*a*) de regressão são uma indicação da exatidão da detecção da proporção de área queimada, enquanto o coeficiente de determinação (*R*²) é uma indicação da precisão, ou seja, é um indicativo da qualidade de coerência ou repetibilidade (Boschetti *et al.*, 2003).

Uma inclinação da linha de regressão igual à unidade com uma interceptação zero indica que a detecção da proporção de área queimada é precisa na escala de pixels. Um coeficiente de determinação igual a 1 indica maior precisão e que a variabilidade dos dados é totalmente explicada pelo modelo linear (todos os pontos caem na linha de regressão), enquanto um coeficiente de determinação igual a zero indica que não há relação entre o modelo linear e a variabilidade dos dados (Roy e Boschetti, 2009).

Resultados e discussão

Seleção de parâmetros de RF

Conforme declarado na metodologia, o parâmetro *ntree* afeta significativamente o desempenho do classificador de RF. Neste estudo, usamos uma cena VIIRS com nove bandas para classificação de áreas queimadas, ou seja, os dados de entrada possuem 9 variáveis. Para *mtry* $\approx$ 1, a classificação foi implementada com vários números de árvores com a finalidade de encontrar um número *ntree* ideal para o classificador RF, bem como a variável mais importante na classificação. Foram testadas nas nove bandas compostas do VIIRS, o parâmetro *ntree* com 50, 100, 150, 200, 250, 300, 350 e 400 árvores.

A partir de vários modelos de RF criados, a (Figura 3) mostra o erro OOB em função do número de árvores. É demonstrado em estudos realizados por (Breiman 1996, 2001) que o erro OOB é um bom estimador do erro de generalização em função do número de árvores.

Figura 3. Efeito do número de árvores (*ntree*) em função da variação de erro OOB.

Embora todos os modelos apresentem baixas estimativas de erro (> 6%), os menores valores foram encontrados para o modelo com maior número de árvores, como esperado. Para *ntree* de 50-150 resultaram numa diminuição do desempenho de classificação e uma estabilização dos erros no intervalo de 150-350 árvores foram estabelecidas com valores em torno de 4,5%. Os resultados desta análise mostram um comportamento inversamente proporcional entre o erro OOB e o *ntree*, chegando numa estimativa de erro de (5,22%) quando o *ntree* é igual 50 e (3,91%) para *ntree* igual a 400, a partir do qual pode-se inferir que um RF é sensível ao número de árvores uma vez atingido o ponto para o qual o erro converge.

Em conformidade com os resultados encontrados em (Comert; Matci; Avdan, 2019) e (Ramo e Chuvieco, 2017) mostraram alta estimativa de acurácia para *ntree* igual 400 na

aplicação do modelo RF em áreas de incêndios florestais na Turquia e em escala de cobertura global respectivamente, enquanto (Rodríguez-Galiano *et al.*, 2012) encontrou estabilidade de erro OOB para número de árvores acima de 100 na classificação do uso da terra no sul da Espanha. Entretanto (Ramo e Chuvieco, 2017) e (Rodríguez-Galiano *et al.*, 2012) relataram severa carga alto computacional e grande aumento no tempo de classificação, para um número de árvores acima de 300 divergindo com as afirmações de (Breiman, 2001) onde o autor relata que o RF remove sub-nós de um nó de decisão, o que o torna leve, do ponto de vista computacional.

A (Figura 4) mostra a contribuição das bandas individuais para alcançar classificação por RF. A importância foi calculada a partir da importância da precisão da permutação método. O gráfico mostra que as bandas M1-M5 e m10 apresentaram os menores níveis de importâncias com valores abaixo de 2% enquanto as bandas M7, M8 e M11 tiveram maior impacto na caracterização do modelo de classificação implementado, principalmente as bandas M7 e M8 com nível de importância acima de 6%. Vale observar que não foram apresentados níveis de importância negativa, pois necessitaria de uma retomada no processamento com a remoção deste

Figura 4. Estimativa de importância das bandas do sensor VIIRS na classificação por RF.

recurso, que teria como resultado uma melhora o desempenho.

A maior nível de importância vista para a banda M7 reforça o alto poder discriminatório da banda espectral do infravermelho próximo (NIR) consistente com trabalhos de (Veraverbeke *et al.*, 2011), (Smith *et al.*, 2007), (Pereira *et al.*, 1999), (Lasaponara *et al.*, 2006). Esta região espectral tem sido amplamente considerada como a melhor região espectral para detectar e mapear áreas queimadas (Ngadze *et al.*, 2020, Mallinis; Mitsopoulos; Chrysafi, 2018). A região do NIR é

fortemente refletida pela vegetação. Como resultado, a remoção da vegetação ou queimadura implica uma queda pós-incêndio da refletância do infravermelho próximo, e por isso, o uso de dados nesta faixa espectral é decisivo no processo de classificação de imagens de áreas queimadas.

Ocupando a segunda e terceira posições respectivamente, as bandas M8 e M11 apresentaram um nível de importância de (6,12%) e (1,92%) na classificação. A refletância infravermelho de ondas curtas (SWIR) aumenta após a queima, devido à remoção da vegetação retentora de água pelo fogo, sendo superior do que nos comprimentos de onda visíveis (Key e Benson, 2005; Veraverbeke; Harris; Hook, 2011) e assim com o infravermelho próximo, está presente em boa parte dos índices de vegetação em abordagens em áreas queimadas, como o Índice de Área Queimada Modificado (BAIM) (Martín; Gómez; Chuvieco, 2005), Taxa de Queima Normalizada (NBR) (Key e Benson, 1999), Taxa de Queima Normalizada 2 (NBR2) (García e Caselles, 1991), Índice de Área Queimada (BAI) (Martín e Chuvieco, 1998).

A banda M8, usada neste estudo, está situada próxima da região espectral NIR. Portanto, espera-se que esta banda seja mais sensível a perturbações causadas por incêndios e ao conteúdo de umidade na estrutura da vegetação, que é a variável mais importante que influencia a região no comportamento espectral no NIR (Jacquemoud *et al.*, 2009; Bacour; Baret; Jacquemoud, 2002). Em estudos utilizando VIIRS 375 m e 1Km, DaCamara *et al.*, 2019, encontraram feições bastante discriminantes utilizando a banda M11 também correspondente com trabalhos de (Schepers *et al.*, 2014) e (Briones-Herrera *et al.*, 2020).

As bandas M1-M5, como esperado, apresentaram as menores nível de importância na classificação em conformidade com trabalhos anteriores (Ngadze *et al.*, 2020; Veraverbeke; Harris; Hook, 2011; Plenou e Koutsias, 2013), onde relatam que os comprimentos de onda do visível (VIS) tem um desempenho muito baixo na distinção entre áreas queimadas e não queimadas.

Uma explicação provável é que água e sua presença em mangues, florestas densas e tipos de solo são todos relativamente escuros, o que causa confusão espectral com áreas queimadas nesses comprimentos de onda (Pereira, 1999) e diferente da SWIR, grandes quantidades de fuligem na atmosfera e a fumaça da queima de biomassa bastante presente na centro-oeste brasileiro, também é um aerossol absorvente na região do visível (Pereira *et al.*, 1999). Consequentemente

causando confusões no classificador (erros de superestimação) e no operador (erro de omissão) principalmente quando os polígonos amostrais são coletados por fotointerpretação. Nossos resultados suportam a hipótese de que as diferenças na proporção de importância na classificação RF estão diretamente ligadas à dinâmica de absorção das bandas espectrais em áreas queimadas.

Resultado da Classificação RF

De acordo com os dados obtidos nos perímetros de incêndio por RF, foram mapeados aproximadamente 14,7 km² de área queimada para toda a cena. A maior proporção foi vista no recobrimento do estado da Bahia com 6,43 Km² concentradas em zonas de pastagem e próximo ao reservatório de Sobradinho (

Figura 5c). Em seguida, para o recorte do estado do Tocantins, foram quantificados cerca de 3,6 Km² com presença significativa em dentro de áreas de preservação. Em setembro de 2019, foram detectados 4505 focos de calor no estado do Tocantins enquanto o estado da Bahia, foram detectados 1896 focos de calor segundo o Banco de Dados de Queimadas (BDQueimadas), porém vale destacar que a cena VIIRS recobriu aproximadamente 40% do estado do Tocantins e 50% do estado da Bahia, ou seja, o maior recobrimento territorial da cena utilizada favoreceu a detecção de áreas queimadas para o estado da Bahia.

Cerca de 1,1 Km² de área queimada foram detectadas em Terras Indígenas e 2,31 Km² em Unidades de Conversação Federal. A T.I e a U.C.F mais queimada foi o Parque do Araguaia com 0,4 Km² e o Parque Nacional do Araguaia com 0,61 Km², respectivamente, (

Figura 5d e e). Esses resultados corroboram o número de focos de calor no período em análise, onde para a T.I Parque do Araguaia foram detectados 630 focos de calor ocupando a primeira posição entre todas as T.Is, enquanto a U.C.F Parque Nacional do Araguaia ocupou a quinta posição entre as U.C.Fs com o maior número de focos de calor detectados pelos satélites de referência do BDQueimadas.

Alta frequência de pixels relacionados a incêndios de extensão (1~2Km²) foram encontrados em áreas de pastagem como mostra a figura 5a e bastante distribuídos em toda cena, principalmente no setor sul. Já os polígonos mais compactos (>200 Km²) foram encontradas na vegetação nativa e outras com o agravante de

estarem próximas a vegetação ciliar e rios (figura 5b). A menor proporção de áreas queimadas foi encontrada na porção do bioma Mata Atlântica, de área aproximadamente 0,1Km², com maior

frequência em centros urbanos presentes em zonas de transição com o bioma cerrado.

Figura 5. Áreas queimadas detectadas pelo modelo RF em partes da área de estudo.

Avaliação de precisão

A (Figura 6) fornece a distribuição espacial dos acertos, erros de omissão e erros de comissão obtidos ao comparar a área queimada obtida por dados VIIRS e classificação RF versus os mapas de referência de cicatrizes de queimaduras derivados do Aq30m, Fire_cci e MCD64A1 nos locais selecionados de órbitas/ponto Landsat: 223/68; 223/69; 221/69 e 221/70. Existe uma predominância de cicatrizes de fogo muito pequenas, porém essas cicatrizes representam menos de 10% do total da área queimada. Por outro lado, a maior quantidade de área queimada

pertence a grandes cicatrizes de incêndio, que por sua vez, é responsável pelo menor número de cicatrizes. As contribuições relativas dessas três classes de cicatrizes mudam drasticamente de órbita/ponto para órbita/ponto. Visualmente as cenas mostram feições compactas de pixels subestimados de área queimada principalmente nos locais onde houve a validação realizada pelos produtos Fire_cci e MCD64, embora não seja possível identificar uma tendência constante de distribuição dos erros espaciais pelos diferentes produtos de validação e órbitas/ponto.

Figura 6. Distribuição espacial dos pixels onde áreas realmente queimadas foram detectadas (vermelho), juntamente com erros de omissão (verde) e de comissão (amarelo).

As órbitas/ponto 221/70 e 221/69 validadas com o produto Fire_cci apresentaram o maior número de pixels de erro de omissão com 27558 e 295211 pixels e ambas com estimativas de 80%, respectivamente. Problemas devido às diferenças de resolução espacial dos conjuntos de dados, possivelmente combinados com erros de georreferenciamento que se propagam em múltiplas cenas MODIS e VIIRS podem estar associados. A área queimada na órbita/ponto 221/69 validado com produto Aq30m apresentou a menor distribuição de erros de omissão, com 605 pixels e assim resultando numa estimativa de erro de 53%, embora ao contrário de regiões onde as cicatrizes grandes são predominantes, os sensores de baixa resolução tendem a subestimar áreas queimadas em regiões onde as cicatrizes queimadas são pequenas e fragmentadas. Um grande número de erros de omissão são, portanto, esperados nos três produtos de validação analisados, mas, devido a sua resolução espacial mais fina, o Aq30m é capaz de identificar uma fração maior de pixels parcialmente queimados.

Os pixels de erro de comissão aparecem com menor distribuição em relação aos pixels de erro de omissão, chegando a razoavelmente boas estimativas na validação realizada com produto MCD64A1 nas órbitas/ponto 221/69 (27%) e 221/70 (21%), onde nestes locais, os pixels de erro de comissão encontra-se localizadas em maior ocorrência ao longo das bordas das cicatrizes mais compactas e em polígonos mais isolados. As maiores estimativas de erros de comissão foram encontradas nas órbitas/ponto 221/69 e 223/69 com 76% e 80% respectivamente nas validações realizadas pelos produtos Fire_cci e Aq30m respectivamente. A incerteza nas datas de detecção pode levar a este tipo de erro na avaliação da precisão. Além disso, esses resultados sugerem que uma fração substancial dos erros de comissão encontrados com produto de validação com maior resolução (Aq30m) não são necessariamente “alarmes falsos” no sentido estrito, mas como uma superestimativa do tamanho das cicatrizes reais (Libonati *et al.*, 2015). Por outro lado, conforme apontado por (Padilla *et al.*, 2015), áreas pequenas e irregulares não queimadas dentro de grandes manchas queimadas podem levar a um aumento nos erros de comissão, especialmente para algoritmos de alta sensibilidade. A área de um pequeno incêndio pode abranger mais de dois ou mais pixels VIIRS, cobrindo apenas pequenas frações de cada pixel, resultando,

consequentemente, em uma falha na detecção desse evento de incêndio em qualquer um dos pixels afetados. Além disso, vários desses incêndios de pequeno porte ocorrem em vegetação do Cerrado limpo presentes no estado do Goiás, que queima muito rápido, mas também se recupera muito rápido sem deixar cicatrizes fortemente marcadas e claramente espectralmente discerníveis. Essas condições não são favoráveis aos algoritmos de área queimada, que são baseados em mudanças abruptas e permanentes nas reflectâncias espectrais (Fornacca; Ren; Xiao, 2017).

Mesmo com pixels de erros de comissão e omissão significativos as órbitas/ponto 221/69 e 221/70 apresentam a maior aderência de área queimadas com os produtos de validação, que em média foi de 64% e 73% prevista pelo RF foram corretamente classificadas, o que refletiu diretamente nas estimativas de coeficiente (DC) mostrado na (Figura 7).

Figura 7. Coeficiente DC nas órbitas/ponto selecionadas para a validação da área queimada por meio de cenas dos produtos Aq30m, Fire_cci e MCD64A1.

Os resultados mostram que a avaliação da classificação baseado em RF e dados VIIRS mapeou a área queimada exibindo coeficientes (DC) moderadamente baixos (>0,5) de concordância geral com os mapas de referência, o que é esperado, uma vez que a classe-alvo é muito menos frequente do que a classe de não ocorrência.

Os valores do coeficiente DC, assim como a dinâmica espacial de erro de omissão e comissão mostrado na figura 6, apresentaram um comportamento singular para cada órbita/ponto. Por exemplo, para as órbitas/ponto 221/69 e 221/70

as validações realizadas pelo produto Aq30m apresentaram alto rendimento, porém para as órbitas/ponto 223/69 e 223/70 mostram baixas estimativas. As validações realizadas pelo produto MCD64 e Fire_cci não apresentaram variações importantes entre as órbitas/ponto, porém com um decréscimo importante na órbita ponto 22169 para o Fire_cci. Esses resultados estão diretamente ligados ao incompatibilidades temporais dos dados utilizados com os produtos de validação, principalmente para Aq30m, por ter sido usadas dados de quatro datas diferentes. Para as órbitas ponto 22169 e 22170, houve disparidade temporal de um dia com a data da gravação da cena VIIRS enquanto as órbitas/ponto 223/69 e 223/68 houve diferença de 4 dias anteriores. A informação mensal da área queimadas no Fire_cci não se sobressaiu aos dados do MCD64A1, este que por sua vez, traz a informação da área queimada por data juliana que provavelmente trouxe maior proximidade aos dados da cena VIIRS.

Esses resultados estão de acordo com encontrado em (Shimabukuro *et al.*, 2020) afirmou que embora usem os mesmos conjuntos de dados do sensor MODIS, os produtos de áreas queimadas globais existentes (Fire_cci e MCD64A1) apresentam resultados diferentes. Essas diferenças se devem às metodologias e datas das imagens utilizadas para gerar esses produtos. Enquanto (Humber *et al.*, 2019) revelam que os produtos Fire_cci e MCD64A1 são eficientes na

identificação e validação de áreas queimadas em regiões nubladas devido à sua dependência de detecções ativas de incêndio como amostras de dados de treinamento.

Em Libonati *et al.*, 2015, os autores relataram o que o produto Aq30m apresenta um número reduzido de erros de omissão e valores altos de acurácia global do que os dois produtos padrão MODIS (MCD64A1 e MCD45A1) em análises no Cerrado brasileiro. No entanto os resultados mostraram que o MCD64A1 tem um bom desempenho para grandes incêndios, o que é uma indicação de que o VIIRS 1Km pode compensar a resolução espacial mais grosseira de 500 m nesse caso. Contudo, (Campagnolo *et al.*, 2021) revelou que a resolução espacial mais fina do Fire_cci entre os modelos globais de área queimada é vantajosa para mapear incêndios em classes de tamanho menores (0-250 ha, e mesmo 250-500 ha). Por fim, (Briones-Herrera *et al.*, 2020) mostrou que o uso de imagens VIIRS pode resultar em uma primeira estimativa rápida, provisória, de escala mais grosseira da extensão do fogo. Além da maior capacidade de detectar incêndios devido a sua maior latência temporal e não está efetivamente sujeita a limitações, como confusão com terras agrícolas, desmatamentos ou ao efeito de mudanças fenológicas que é constantemente encontrado em produtos MODIS.

Figura 8. Fotografia da dinâmica da vegetação pré (P3 e P6) e pós incêndio (P1, P2, P4 e P5) na Chapada dos Veadeiros - GO. Os pontos P3 e P6 são datadas (15/05/2019), P1 e P2 são datados (30/09/2019), P4 e P5 (20/11/2019).

Por outro lado, como mencionado anteriormente, o sinal potencialmente mais fraco

do NIR pode causar inconsistências em detectar áreas queimadas e outras feições do solo com

características espectrais similares, que pode ser bastante comum, uma vez que a área de estudo de validação está localizada no bioma Cerrado onde há alta complexidade espectral entre os elementos da paisagem mostrado na (Figura 8), principalmente quando há diminuição da vegetação na época seca ou vegetação pós incêndio.

A (Figura 9) relata os gráficos de dispersão obtidos pela combinação de proporção de pixels de grade detectadas como queimadas pelo produto VIIRS é comparada com a proporção de área detectada pelos dados de referência.

Figura 9. Gráficos de regressão linear entre a proporção de área queimada por RF e de referência em (Km²). A equação linear e a linha de regressão (preta) também são exibidas.

A análise mostra que a validação realizada com os produtos Aq30m na órbita/ponto 221/69 exibiu uma exatidão e precisão ligeiramente maior do que a validação com o produto Fire_cci e (inclinação: 0,459303 vs. 0,191657; R²: 0,56 vs.

0,25) e valores próximos de precisão ao produto MCD64A1 (R²: 0,56 vs. 0,5) embora com menor exatidão (inclinação: 0,459303 vs. 0,653082). Na órbita/ponto (221/70) a validação com o produto Fire_cci continuou com a menor estimativa de

exatidão e precisão (inclinação: 0,496896 vs. 0,415362 vs. 0,737821; R^2 : 0,45 vs. 0,35 vs. 0,45) enquanto para os produtos MCD64A1 e Aq30m apresentaram os mesmos valores de precisão embora o MCD64 apresentou a maior exatidão da série de regressão. As validações com as órbitas/ponto 223/69 e 233/68 apresentaram baixa precisão com todos os produtos com variações de

(R^2 : 0,3 ~ 0,42) entretanto, a validação com o produto MCD64A1, assim como nas outras órbitas/ponto, apresentaram o melhor rendimento em exatidão enquanto o Fire_cci, mostrou-se sem variações importantes. Para a validação com o Aq30m na órbita/ponto 223/70 apresentou a menor estimativa de exatidão geral dos dados.

Conclusão

Este artigo demonstrou o mapeamento de área queimada usando uma imagem VIIRS de resolução de 1Km e o classificador Random Forest na parte central do Brasil. O produto final da classificação mostrou perímetros de área queimada diretamente ligada ao uso e ocupação do solo embora o pré-processamento rigoroso de dados foi necessário devido aos requisitos do algoritmo de classificação e também de evitar inconsistências em mapear feições espectralmente semelhantes às áreas queimadas.

Os três produtos de validação testados neste estudo foram selecionados por causa de sua resolução temporal e espacial relativamente alta. Os resultados da avaliação permitiram a identificação da área queimada por RF com maior precisão possível e uma visão preliminar da atividade de incêndio nesta região. Embora tenha apresentado uma distribuição de erros espaciais bastante significativa. Um olhar mais atento a distribuição espacial dos erros de omissão e comissão permite identificar o tipo de erro com maior impacto nos resultados. Por exemplo, o uso de regras menos conservadoras (por exemplo, limiares mais baixos) para separar pixels queimados de não queimados resultará em melhores probabilidades de detecção ao custo de maiores erros de comissão. Os desenvolvedores de algoritmos de áreas queimadas muitas vezes optam pela abordagem oposta, contendo erros de comissão ao custo de erros de omissão maiores e nossos resultados confirmam essa afirmação. Quase todos os modelos analisados são mais precisos (menor comissão) do que sensíveis (maior omissão).

A influência do tamanho do evento de incêndio na probabilidade de detecção pode ser destacada ao se analisar a qualidade do mapeamento para diferentes tamanhos de incêndio: cada validação realizada pelos produtos de referência obteve os menores erros para incêndios maiores. Mas ainda assim foi possível identificar

relevante falta de aderência com os dados de referência que está diretamente ligado, como mencionado anteriormente, a dinâmica temporal dos dados de referência. Em nosso estudo, isso só foi verdade para a validação com o produto Aq30m, enquanto a validação com os produtos MCD64A1 e Fire_cci tiveram um desempenho considerável por se tratar de dados de área queimada mensalmente compactos. No geral o MCD64A1 apresentou-se como produto de validação mais consistente com a classificação gerada com uma detecção significativamente melhor de pequenas queimaduras, uma redução

modesta na incerteza temporal da data de queima e uma grande redução na extensão de áreas não mapeadas. Enquanto o produto Fire_cci não apresentou um resultado de precisão da validação esperado, porém nas órbitas/ponto 223/69 e 223/68 se sobressaiu à validação realizada pelo Aq30m.

O Random Forest provou ser um classificador robusto para a detecção de área queimada, apresentando resultados plausíveis com a dinâmica do uso e ocupação do solo da área de estudo. Erros de omissão e comissão foram estimados comparando os resultados de RF com perímetros de incêndio nacionais e globais. Quando comparado com perímetros nacionais de datas próximas ao dado de entrada, forneceram uma precisão mais bastante relevante e equilibrada. Os modelos de RF mostraram grande potencial para serem aplicados a imagens do sensor VIIRS podendo gerar séries temporais consistentes de dados de área queimada.

Referências

- Archibald, S.A.; Roy, D.P.; Van Wilgen, B.W.; Scholes, R.J. What limits fire? An examination of drivers of burnt area in southern africa. *Glob. Chang. Biol.* 2009, 15, 613–630. <https://doi.org/10.1111/j.1365-2486.2008.01754.x>
- Aldersley, A.; Murray, S.J.; Cornell, S.E. Global and regional analysis of climate and human

- drivers of wildfire. *Sci. Total Environ.* 2011, 409, 3472–3481. <https://doi.org/10.1016/j.scitotenv.2011.05.0>
- A. Alencar, J.Z. Shimbo, F. Lenti, C. Balzani Marques, B. Zimbres, M. Rosa, V. Arruda, I. Castro, J.P. Fernandes Márcico Ribeiro, V. Varela, I. Alencar, V. Piontekowski, V. Ribeiro, M.M.C. Bustamante, E. Eyji Sano, M. Barroso Mapping three decades of changes in the Brazilian savanna native vegetation using landsat data processed in the google earth engine platform *Remote Sensing*, 12 (6) (2020), p. 924.
- Alonso-Canas, I.; Chuvieco, E. Global burned area mapping from envisat-meris data. *Remote Sens. Environ.* 2015, 163, 140–152. <https://doi.org/10.1016/j.rse.2015.03.011>.
- ARVOR, Damien; BETBEDER, Julie; DAHER, Felipe R.G.; BLOSSIER, Tim; ROUX, Renan Le; CORGNE, Samuel; CORPETTI, Thomas; SILGUEIRO, Vinicius de Freitas; SILVA JUNIOR, Carlos Antonio da. Towards user-adaptive remote sensing: knowledge-driven automatic classification of sentinel-2 time series. *Remote Sensing Of Environment*, [S.L.], 264, 112615-112630, out. 2021.
- Baret et al., "Evaluation of the representativeness of networks of sites for the global validation and intercomparison of land biophysical products: proposition of the CEOS-BELMANIP," in *IEEE Transactions on Geoscience and Remote Sensing*, 44, no. 7, pp. 1794-1803, July 2006, doi: 10.1109/TGRS.2006.876030.
- Bacour, C.; Baret, F.; Jacquemoud, S. Information Content of HyMap Hyperspectral Imagery. *Proceedings of 1st International Symposium on Recent Advances in Quantitative Remote Sensing*, Valencia, Spain, 27 September–1 October 2002; pp. 503–508.
- BISPO, Polyanna da Conceição; RODRÍGUEZ-VEIGA, Pedro; ZIMBRES, Barbara; MIRANDA, Sabrina do Couto de; CEZARE, Cassio Henrique Giusti; FLEMING, Sam; BALDACCHINO, Francesca; LOUIS, Valentin; RAINS, Dominik; GARCIA, Mariano. Woody Aboveground Biomass Mapping of the Brazilian Savanna with a Multi-Sensor and Machine Learning Approach. *Remote Sensing*, [S.L.], 12, 2685-2640, 19 ago. 2020.
- Breiman, L. Random Forests. *Machine Learning* 45, 5–32 (2001). <https://doi.org/10.1023/A:1010933404324>
- Breiman, L.; Friedman, J.; Stone, C.J.; Olshen, R.A. *Classification and Regression Trees*; CRC Press: Florida, FL, USA, 1984.
- Brewer, C.K.; Winne, J.C.; Redmond, R.L.; Opitz, D.W.; Mangrich, M.V. Classifying and mapping wildfire severity: A comparison of methods. *Photogramm. Eng. Remote Sens.* 2005, 71, 1311–1320.
- Briones-Herrera, C.I.; Vega-Nieva, D.J.; Monjarás-Vega, N.A.; Briseño-Reyes, J.; López-Serrano, P.M.; Corral-Rivas, J.J.; Alvarado-Celestino, E.; Arellano-Pérez, S.; Álvarez-González, J.G.; Ruiz-González, A.D.; Jolly, W.M.; Parks, S.A. Near Real-Time Automated Early Mapping of the Perimeter of Large Forest Fires from the Aggregation of VIIRS and MODIS Active Fires in Mexico. *Remote Sensing*. 2020, 12, 2061. <https://doi.org/10.3390/rs12122061>
- Belgiu, M.; Drăguț, L. Random forest in remote sensing: A review of applications and future directions. *ISPRS J. Photogramm. Remote Sens.* 2016, 114, 24–31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
- Boschetti L, David P. Roy, Louis Giglio, Haiyan Huang, Maria Zubkova, Michael L. Humber, Global validation of the collection 6 MODIS burned area product, *Remote Sensing of Environment*, Volume 235, 2019, ISSN 0034-4257, <https://doi.org/10.1016/j.rse.2019.111490>.
- Bowman, David & Perry, George & Marston, J. (2015). Feedbacks and landscape-level vegetation dynamics. *Trends in ecology & evolution*. 30. <https://doi.org/10.1016/j.tree.2015.03.005>
- Boschetti L, P.A. Brivio, J.M. Gregoire The use of Meteosat and GSM imagery to detect burned areas in tropical environments. *Remote Sens. Environ.*, 85 (1) (2003), pp. 78-91
- Campagnolo M.L., R. Libonati, J.A. Rodrigues, J.M.C. Pereira. A comprehensive characterization of MODIS daily burned area mapping accuracy across fire sizes in tropical savannas, *Remote Sensing of Environment*, Volume 252, 2021, ISSN 0034-425. <https://doi.org/10.1016/j.rse.2020.112115>
- Carlos C. DaCamara, Renata Libonati, Miguel M. Pinto and Alexandra Hurduc (2019). Near- and Middle-Infrared Monitoring of Burned Areas from Space, *Satellite Information Classification and Interpretation*, Rustam B. Rustamov, IntechOpen, DOI: 10.5772/intechopen.82444.
- Chuvieco, E.; Pettinari, M.L.; Lizundia-Loiola, J.; Storm, T.; Padilla Parellada, M. (2018): ESA Fire Climate Change Initiative (Fire_cci): MODIS Fire_cci Burned Area Pixel product, version 5.1. Centre for Environmental Data

- Analysis. (2018)
<https://doi.org/10.5285/58f00d8814064b79a0c49662ad3af537>
- CONCIANI, Dhemerson E.; SANTOS, Lucas Pereira dos; SILVA, Thiago Sanna Freire; DURIGAN, Giselda; ALVARADO, Swanni T.. Human-climate interactions shape fire regimes in the Cerrado of São Paulo state, Brazil. **Journal For Nature Conservation**, [S.L.], 61, 126006-126015, jun. 2021.
- Comert, Resul & Matci, Dilek & Avdan, Ugur. Object Based Burned Area Mapping with Random Forest Algorithm. *International Journal of Engineering and Geosciences*. 4. 78-87. (2019). Doi:10.26833/ijeg.455595
- DaCamara C.C, Renata Libonati, Miguel M. Pinto and Alexandra Hurduc (May 2nd 2019). Near-and Middle-Infrared Monitoring of Burned Areas from Space, Satellite Information Classification and Interpretation, Rustam B. Rustamov, IntechOpen, DOI: 10.5772/intechopen.82444.
- Duro, D.C.; Franklin, S.E.; Dubé, M.G. A comparison of pixel-based and object-based image analysis with selected machine learning algorithms for the classification of agricultural landscapes using SPOT-5 HRG imagery. *Remote Sensing. Environment*. 2012, 118, 259–272.
- Fornacca, D.; Ren, G.; Xiao, W. Performance of Three MODIS Fire Products (MCD45A1, MCD64A1, MCD14ML), and ESA Fire_CCI in a Mountainous Area of Northwest Yunnan, China, Characterized by Frequent Small Fires. *Remote Sensing*. 2017, 9, 1131.
- Giglio, L., Justice, C., Boschetti, L., Roy, D. (2015). MCD64A1 MODIS/Terra+Aqua Burned Area Monthly L3 Global 500m SIN Grid V006 [Data set]. NASA EOSDIS Land Processes DAAC. <https://doi.org/10.5067/MODIS/MCD64A1.006>
- Ghimire B, J. Rogan, J. Miller. Contextual land-cover classification: incorporating spatial dependence in land-cover classification models using random forests and the Getis statistic. *Remote Sensing Letters*, 1 (2010), pp. 45-54.
- Giglio, L.; Loboda, T.; Roy, D.P.; Quayle, B.; Justice, C.O. An active-fire based burned area mapping algorithm for the MODIS sensor. *Remote Sensing. Environment*. 2009, 113, 408–420
- García, V. Caselles M.J.L. Mapping burns and natural reforestation using thematic Mapper data Geocarto Int., 6 (1991), pp. 31-37, 10.1080/10106049109354290
- Hantson, S. Pueyo, E. Chuvieco Global fire size distribution is driven by human impact and climate. *Glob. Ecol. Biogeogr.*, 24 (1) (2015), pp. 77-86
- Holden, Z.A.; Morgan, P.; Evans, J.S. A predictive model of burn severity based on 20-year satellite-inferred burn severity data in a large southwestern us wilderness area. *For. Ecol. Manag.* 2009, 258, 2399–2406.
- Humber, M.L.; Boschetti, L.; Giglio, L.; Justice, C.O. Spatial and temporal intercomparison of four global burned area products. *Int. J. Digital Earth*. 2019, 12, 460–484.
- Justice C., A. Belward, J. Morisette, P. Lewis, J. Privette, F. Baret Developments in the 'validation' of satellite sensor products for the study of the land surface *Int. J. Remote Sens.*, 21 (17) (2000), pp. 3383-3390
- Jeffrey T. Morisette, Jeffrey L. Privette, Christopher O. Justice A framework for the validation of MODIS land products *Remote Sensing of Environment*, 83 (1-2) (2002), pp. 77-96.
- Jacquemoud, S.; Verhoef, W.; Baret, F.; Bacour, C.; Zarco-Tejada, P.J.; Asner, G.P.; François, C.; Ustin, S.L. PROSPECT+SAIL models: A review of use for vegetation characterization. *Remote Sensing. Environment* (2009), 113, S56–S66.
- Kantola, T.; Vastaranta, M.; Yu, X.; Lyytikäinen-Saarenmaa, P.; Holopainen, M.; Talvitie, M.; Kaasalainen, S.; Solberg, S.; Hyyppä, J. Classification of Defoliated Trees Using Tree-Level Airborne Laser Scanning Data Combined with Aerial Images. *Remote Sensing*. 2010, 2, 2665-2679
- Key, C.H.; Benson, N.C. Landscape Assessment: Ground measure of severity, the Composite Burn Index; and Remote sensing of severity, the Normalized Burn Ratio; 2006; Other Government Series; RMRS-GTR-164-CD: LA 1-51; FIREMON: Fire Effects Monitoring and Inventory System.
- Key, N C.H.. Benson The Normalized Burn Ratio (NBR): A Landsat TM Radiometric Measure of Burn Severity. *US Geol. Surv. North. Rocky Mt. Sci. Center* (1999)
- KGANYAGO, Mahlatse; SHIKWAMBANA, Lerato. Assessment of the Characteristics of Recent Major Wildfires in the USA, Australia and Brazil in 2018–2019 Using Multi-Source Satellite Products. *Remote Sensing*, [S.L.], 12, 1803-1815, 3 jun. 2020.
- Lawrence, R.L.; Wood, S.D.; Sheley, R.L. Mapping invasive plants using hyperspectral

- imagery and breiman cutler classifications (randomforest). *Remote Sens. Environ.* 2006, 100, 356–362.
- Lasaponara, R. Estimating spectral separability of satellite derived parameters for burned areas mapping in the Calabria region by using SPOT-Vegetation data. *Ecol. Model* (2006), 196, 265–270.
- López-García, M.J.; Caselles, V. Mapping burns and natural reforestation using Thematic Mapper data. *Geocarto Int* (1991), 6, 31–37.
- Libonati, R.; DaCamara, C.C.; Setzer, A.W.; Morelli, F.; Melchiori, A.E. An Algorithm for Burned Area Detection in the Brazilian Cerrado Using 4 μ m MODIS Imagery. *Remote Sens.* 2015, 7, 15782-15803.
- Liaw, A.; Wiener, M. Classification and regression by random Forest. *R News* (2002), 2, 18–22.
- Mallinis G.; Mitsopoulos I.; Chrysafi I. Evaluating and comparing sentinel 2a and landsat-8 operational land imager (oli) spectral indices for estimating fire severity in a mediterranean pine ecosystem of greece. *GIScience & Remote Sensing* 2018, 55, 1–18.
- Mouillot F., M.G. Schultz, C. Yue, P. Cadule, K. Tansey, P. Ciaï, E. Chuvieco Ten years of global burned area products from spaceborne remote sensing—a review: analysis of user needs and recommendations for future developments *Int. J. Appl. Earth Obs. Geoinf.*, 26 (2014), pp. 64-79S.
- Martín M.P., E. Chuvieco Cartografía de grandes incendios forestales en la península Ibérica a partir de imágenes NOAA-AVHRR. *Teledetección Av. y Apl* (1998), pp. 248-251
- Martin P., I. Gómez, E. Chuvieco. Performance of a burned-area index (BAIM) for mapping Mediterranean burned scars from MODIS data *Proceedings of the 5th International Workshop on Remote Sensing and GIS Application to Forest Fire Management: Fire Effects Assessment* (2005), pp. 193- 197.
- Morisette, F. Baret, J.L. Privette, R.B. Myneni, J.E. Nickeson, S. Garrigues, ..., M. Kalacska Validation of global moderate-resolution LAI products: a framework proposed within the CEOS land product validation subgroup *IEEE Trans. Geosci. Remote Sensing.*, 44 (7) (2006), pp. 1804-1817
- Ngadze F, Mpakairi KS, Kavhu B, Ndaimani H, Maremba MS (2020) Exploring the utility of Sentinel-2 MSI and Landsat 8 OLI in burned area mapping for a heterogenous savannah landscape. *PLoS ONE* 15(5): e0232962. <https://doi.org/10.1371/journal.pone.0232962>.
- Oliveira, A.s.; Soares-Filho, B.s.; Oliveira, U.; HOFF, R. van Der; Carvalho-Ribeiro, S.M.; OLIVEIRA, A.R.; SCHEEPERS, L.C.; Vargas, B.A.; RAJÃO, R.G.. Costs and effectiveness of public and private fire management programs in the Brazilian Amazon and Cerrado. *Forest Policy And Economics*, [S.L.], 127, p. 102447-102450, jun. 2021.
- Oliveira, S.; Oehler, F.; San-Miguel-Ayanz, J.; Camia, A.; Pereira, J.M. Modeling spatial patterns of fire occurrence in mediterranean europe using multiple regression and random forest. *For. Ecol. Manag.* 2012, 275, 117–129.
- Pereira, J.M.C.; Sá, A.C.L.; Sousa, A.M.O.; Silva, J.M.N.; Santos, T.N.; Carreiras, J.M.B. Spectral Characterisation and Discrimination of Burnt Areas. In *Remote Sensing of Large Wildfires in the European Mediterranean Basin*; Springer-Verlag: Berlin, Germany, 1999; pp. 123–138.
- Padilla, M.; Stehman, S.V.; Ramo, R.; Corti, D.; Hantson, S.; Olive, P.; Alonso-Canas, I.; Bradley, A.V.; Tansey, K.; Mota, B.; et al. Comparing the accuracies of remote sensing global burned area products using stratified random sampling and estimation. *Remote Sens. Environ.* 2015, 160, 114–121.
- Pereira, J.M.C. A comparative evaluation of NOAA/AVHRR vegetation indexes for burned surface detection and mapping. *IEEE Trans. Geosci. Remote Sens.* 1999, 37, 217–226.
- Pleniou, M.; Koutsias, N. Sensitivity of spectral reflectance values to different burn and vegetation ratios: A multi-scale approach applied in a fire affected area. *ISPRS J. Photogramm. Remote Sensing* 2013, 79, 199–210.
- Ramo, R.; Chuvieco, E. Developing a Random Forest Algorithm for MODIS Global Burned Area Classification. *Remote Sensing.* 9, 1193. 2017. <https://doi.org/10.3390/rs9111193>
- Rodriguez-Galiano, V. F., Ghimire, B., Rogan, J., Chica-Olmo, M., & Rigol-Sanchez, J. P. (2012). An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67, 93–104. doi:10.1016/j.isprsjprs.2011.11.002
- Rodrigues, M.; Riva, J. An insight into machine-learning algorithms to model human-caused wildfire occurrence. *Environ. Model. Softw.* 2014, 57, 192–201.
- Ramo, R.; Chuvieco, E. Developing a Random Forest Algorithm for MODIS Global Burned Area Classification. *Remote Sensing.* 2017, 9, 1193

- Roy D.P., P.E. Lewis, C.O. Justice Burned area mapping using multi-temporal moderate spatial resolution data—a bi-directional reflectance model-based expectation approach Remote Sensing. Environment., 83 (1–2) (2002), pp. 263-286
- Rodriguez-Galiano, V.F.; Ghimire, B.; Rogan, J.; Chica-Olmo, M.; Rigol-Sanchez, J.P. An assessment of the effectiveness of a random forest classifier for land-cover classification. ISPRS J. Photogramm. Remote Sens. 2012, 67, 93–104.
- Roy D. P, Haiyan Huang, Luigi Boschetti, Louis Giglio, Lin Yan, Hankui H. Zhang, Zhongbin Li, Landsat-8 and Sentinel-2 burned area mapping - A combined sensor multi-temporal change detection approach, Remote Sensing of Environment, Volume 231, 2019, ISSN 0034-4257, <https://doi.org/10.1016/j.rse.2019.111254>.
- Roy D.P., P.E. Lewis, C.O. Justice Burned area mapping using multi-temporal moderate spatial resolution data—a bi-directional reflectance model-based expectation approach. Remote Sensing. Environment., 83 (1–2) (2002), pp. 263-286
- Story, M.; Congalton, R.G. Accuracy assessment: A user’s perspective. Photogramm. Eng. Remote Sens. 1986, 52, 397–399. [Google Scholar]
- Su, Z.; Hu, H.; Wang, G.; Ma, Y.; Yang, X.; Guo, F. Using GIS and random forests to identify fire drivers in a forest city, Yichun, China. Geomat. Nat. Hazards Risk, 2018, 9, 1207–1229.
- Schepers, L.; Haest, B.; Veraverbeke, S.; Spanhove, T.; Vanden Borre, J.; Goossens, R. Burned Area Detection and Burn Severity Assessment of a Heathland Fire in Belgium Using Airborne Imaging Spectroscopy (APEX). Remote Sensing. 2014, 6, 1803-1826.
- Smith, A.M.S.; Drake, N.A.; Wooster, M.J.; Hudak, A.T.; Holden, Z.A.; Gibbons, C.J. Production of Landsat ETM+ reference imagery of burned areas within Southern African savannahs: Comparison of methods and application to MODIS. Int. J. Remote Sens. 2007. 28, 2753–2775.
- SHIMABUKURO, Yosio Edemir; DUTRA, Andeise Cerqueira; ARAI, Egidio; DUARTE, Valdete; CASSOL, Henrique Luís Godinho; PEREIRA, Gabriel; CARDOZO, Francielle da Silva. Mapping Burned Areas of Mato Grosso State Brazilian Amazon Using Multisensor Datasets. **Remote Sensing**, [S.L.], 12, 3827-3440, 21 nov. 2020.
- Veraverbeke, S.; Harris, S.; Hook, S. Evaluating spectral indices for burned area discrimination using MODIS/ASTER (MASTER) airborne simulator data. Remote Sensing. Environment 2011, 115, 2702–2709.
- Vermote, E., Franch, B., Claverie, M. (2016). VIIRS/NPP Surface Reflectance 8-Day L3 Global 1km SIN Grid V001 [Data set]. NASA EOSDIS Land Processes DAAC. Accessed 2021-01-07 from <https://doi.org/10.5067/VIIRS/VNP09A1.001>
- Van der Werf, J.T G.R.. Randerson, L. Giglio, T.T.van Leeuwen, Y. Chen, B.M. Rogers, et al. Global fire emissions estimates during 1997-2016 Earth Syst. Sci. Data., 9 (2017), pp. 697-720
- TANASE, Mihai A.; BELENGUER-PLOMER, Miguel A.; ROTETA, Ekhi; BASTARRIKA, Aitor; WHEELER, James; FERNÁNDEZ-CARRILLO, Ángel; TANSEY, Kevin; WIEDEMANN, Werner; NAVRATIL, Peter; LOHBERGER, Sandra. Burned Area Detection and Mapping: intercomparison of sentinel-1 and sentinel-2 based algorithms over tropical africa. **Remote Sensing**, [S.L.], 12, 334-345, 20 jan. 2020.
- Trigg S.N., D.P. Roy A focus group study of factors that promote and constrain the use of satellite-derived fire products by resource managers in southern Africa J. Environ. Manag., 82 (1) (2007), pp. 95-110
- Vermote, E., Franch, B., Claverie, M. (2016). VIIRS/NPP Surface Reflectance Daily L2G Global 1km and 500m SIN Grid V001. NASA EOSDIS Land Processes DAAC. <https://doi.org/10.5067/VIIRS/VNP09GA.001>
- Veraverbeke, S.; Harris, S.; Hook, S. Evaluating spectral indices for burned area discrimination using MODIS/ASTER (MASTER) airborne simulator data. Remote Sens. Environ 2011, 115, 2702–2709.
- Zhang, H.K.; Roy, D.P. Using the 500 m MODIS land cover product to derive a consistent continental scale 30 m Landsat land cover classification. Remote Sens. Environ. 2017, 197, 15–34.