



Análise do Modelo Linear de Mistura Espectral na Avaliação de Incêndios Florestais no Parque Nacional do Araguaia, Tocantins, Brasil: Imagens EO-1/Hyperion e Landsat-7/ETM+
Analysis of the Linear Model of Spectral Mixing in the Evaluation of Forest Fires in the Araguaia National Park, Tocantins, Brazil: EO-1 / Hyperion and Landsat-7 / ETM + images

Juarez Antonio da Silva Junior & Admilson da Penha Pacheco

Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Departamento de Engenharia Cartográfica e de Agrimensura, Av. Prof. Moraes Rego, 1235, Cidade Universitária, 50670-901, Recife, PE, Brasil

E-mails: juarez.ufpe@gmail.com; pacheco3p@gmail.com

Recebido em: 26/05/2020 Aprovado em: 16/10/2020

DOI: http://dx.doi.org/10.11137/2020_4_440_450

Resumo

O sensoriamento remoto orbital é uma fonte de informação importante para os estudos de perturbações ambientais em áreas protegidas. Entretanto, a variabilidade e a aplicabilidade das diferentes resoluções espaciais e espectrais dos sistemas sensores são objetos de estudo no âmbito técnico-científico. O sensoriamento remoto hiperespectral gera informações com maior dimensionalidade e detalhamento no espectro de reflectância quando comparado ao sensoriamento remoto multiespectral. Neste trabalho, foi analisado o Modelo Linear de Mistura Espectral para avaliar a influência de *pixels* mistos na classificação de áreas queimadas no Parque Nacional do Araguaia, no estado de Tocantins, a partir da comparação entre imagens dos Satélites EO-1/Hyperion e Landsat-7/ETM+. A validação dos dados espaciais foi baseada no Banco de Dados do Programa de Monitoramento de Queimadas/Incêndios Florestais do INPE. O modelo gerado pelos sensores ETM+ e Hyperion apresentaram erro quadrático médio de 0,026 e 0,016, respectivamente. A imagem Fração Queimado (FQ) do sensor ETM+ não apresentou os resultados esperados, aparentemente devido às feições em superfície de baixa refletância, que contribuíram para que os valores dos parâmetros de acurácia fossem baixos em relação ao sensor Hyperion. Os resultados possibilitaram a geração de produtos com a distribuição espacial das áreas queimadas. Recomenda-se que estudos posteriores relacionados com a metodologia estabelecida e testada neste trabalho sejam avaliados em outros sistemas sensores de alta resolução espacial e espectral.

Palavras-chave: *Fogo; Hiperespectral; Multiespectral*

Abstract

Orbital remote sensing is an important source of information for the study of environmental disturbances in protected areas. However, the variability and applicability of the different spatial and spectral resolutions of the sensor systems are objects of study in the technical-scientific scope. The hyperspectral remote sensing generates information with greater dimensionality and detail in the reflectance spectrum when compared to the multispectral remote sensing. In this work, the Linear Spectral Mixing Model was analyzed to assess the influence of mixed pixels in the classification of burnt areas in the Araguaia / Tocantins / Brazil National Park, based on the comparison between images from the EO-1 / Hyperion and Landsat-7 Satellites / ETM +. The validation of spatial data was based on the Database of the Program for Monitoring Burns / Forest Fires at INPE. The model generated by the ETM + and Hyperion sensors showed an average square error of 0,026 and 0,016, respectively. The Burnt Fraction (FQ) image of the ETM + sensor did not present the expected results, apparently caused by features on a low reflectance surface, which contributed to the accuracy parameter values being low in relation to the Hyperion sensor. The results enabled the generation of products with the spatial distribution of the burned areas. It is recommended that further studies related to the methodology established and tested in this work be evaluated in other sensor systems with high spatial and spectral resolution.

Keywords: *Fire; Hyperspectral; Multispectral*

1 Introdução

Segundo Redin *et al.* (2011) e Anderson *et al.* (2019), o fogo é uma perturbação natural nas savanas e define a fisionomia e a estrutura da vegetação, influenciando frequentemente a diversidade de espécies. A atividade de fogo é determinada por uma ampla gama de fatores, entre eles: variáveis e condições climáticas de longo e curto prazo, biomassa de combustível, velocidade do vento e atividades antropogênicas. No Brasil, o fogo estrutura a composição das savanas do Cerrado, e o impacto do fogo na dinâmica da vegetação é bastante explorado, mas os fatores de variação no distúrbio do fogo nas paisagens ao longo do tempo ainda é um desafio a ser superado.

Entender como o Cerrado responde aos eventos de fogo é bastante importante, pois permite o manejo sustentável em áreas protegidas, que necessita de um processo de estudo contínuo, principalmente diante do atual cenário do país sobre discussões a respeito das mudanças ambientais e do aumento das atividades antrópicas desordenadas.

O Cerrado brasileiro está sendo cada vez mais afetado pelo desmatamento devido à expansão das terras cultivadas e das pastagens, conseqüentemente, aumentando e alterando o regime de incêndio natural na região (Paiva, 2019). O cerrado brasileiro é afetado significativamente por incêndios antrópicos a cada ano, o que torna a região uma das principais fontes de emissões pirogênicas (Libonati *et al.*, 2015). As queimadas sucessivas no Parque Nacional do Araguaia, Tocantins, têm sido objeto de preocupação ambiental nas últimas décadas.

O sensoriamento remoto multiespectral tem sido amplamente utilizado em vários países na detecção da frequência e distribuição espacial de grandes incêndios florestais (Addison & Oommen, 2018). A teledetecção permitiu avanços significativos no mapeamento da dinâmica do fogo, especialmente para localizar a ocorrência do fogo no tempo e no espaço, quantificando a extensão total da área queimada. Vários estudos têm utilizado o sensoriamento remoto para mapear áreas queimadas em escala global e regional, a partir de dados dos Satélites Landsat (Fernandez-Manso *et al.*, 2016; Chuvieco *et al.*, 2019).

O sensoriamento remoto hiperespectral tem mostrado uma diversidade de aplicações na superfície terrestre. Algumas têm sido vinculadas às temperaturas e emissões de incêndios, severidade do fogo, discriminação e quantificação de tipos combustíveis e recuperação da vegetação (Veraverbeke *et al.*, 2018). Muitas dessas

aplicações utilizam técnicas de processamento de análises avançadas de mistura espectral, que usam a seu favor a alta resolução espectral e dimensionalidade dos dados (Saulino *et al.*, 2020).

Uma das principais deficiências das classificações temáticas da cobertura do solo é a incapacidade de acomodar *pixels* mesclados espectralmente em coberturas do solo. Os *pixels* mistos ocorrem quando mais de um tipo de cobertura do solo está presente no campo de visada instantânea do sensor (Small, 2004).

O Modelo Linear de Mistura Espectral (MLMLE) é amplamente utilizado na análise de imagens de sensoriamento (Shimabukuro & Ponzoni, 2019). É particularmente útil para imagens hiperespectrais devido ao fato de sua alta dimensionalidade permitir a recuperação de abundância de frações, mesmo quando o número de membros finais é grande (Raksuntorn & Du, 2008). Diante disso, os algoritmos de mistura espectral são ferramentas de análise para avaliações de gravidade de áreas queimadas por incêndio florestal (AQ), pois geram estimativas quantitativas de abundância das classes de cobertura do solo, sem a necessidade de uma calibração com dados de campo e com índices espectrais (Solans Vila & Barbosa, 2010).

Neste contexto, este artigo tem como objetivo analisar o Modelo Linear de Mistura Espectral (MLME) visando à avaliação da influência de *pixels* mistos na classificação de áreas queimadas por incêndio florestal (AQ) no Parque Nacional do Araguaia, Tocantins, Brasil, a partir da comparação entre imagens dos Satélites EO-1/Hyperion e Landsat-7/ETM+.

2 Materiais e Métodos

2.1 Área de Estudo

A área de estudo está localizada no município de Puim, estado do Tocantins (Figura 1). Esta área está integralmente inserida no Parque Nacional do Araguaia, abrangendo o polígono de coordenadas geográficas 10°24'3.87"S, 50° 5'36.33"O; 10°27'35.31"S, 50° 8'38.70" e área de 36,93 km².

O Parque Nacional do Araguaia, criado em 31 de dezembro de 1959, possui 5555,17 km², constituindo-se de uma extensa planície. Situado na faixa de transição entre a Amazônia e o Cerrado, apresenta uma biodiversidade rica desses dois biomas, com vários cenários naturais.

Análise do Modelo Linear de Mistura Espectral na Avaliação de Incêndios Florestais no Parque Nacional do Araguaia, Tocantins, Brasil: Imagens EO-1/Hyperion e Landsat-7/ETM+

Juarez Antonio da Silva Junior & Admilson da Penha Pacheco

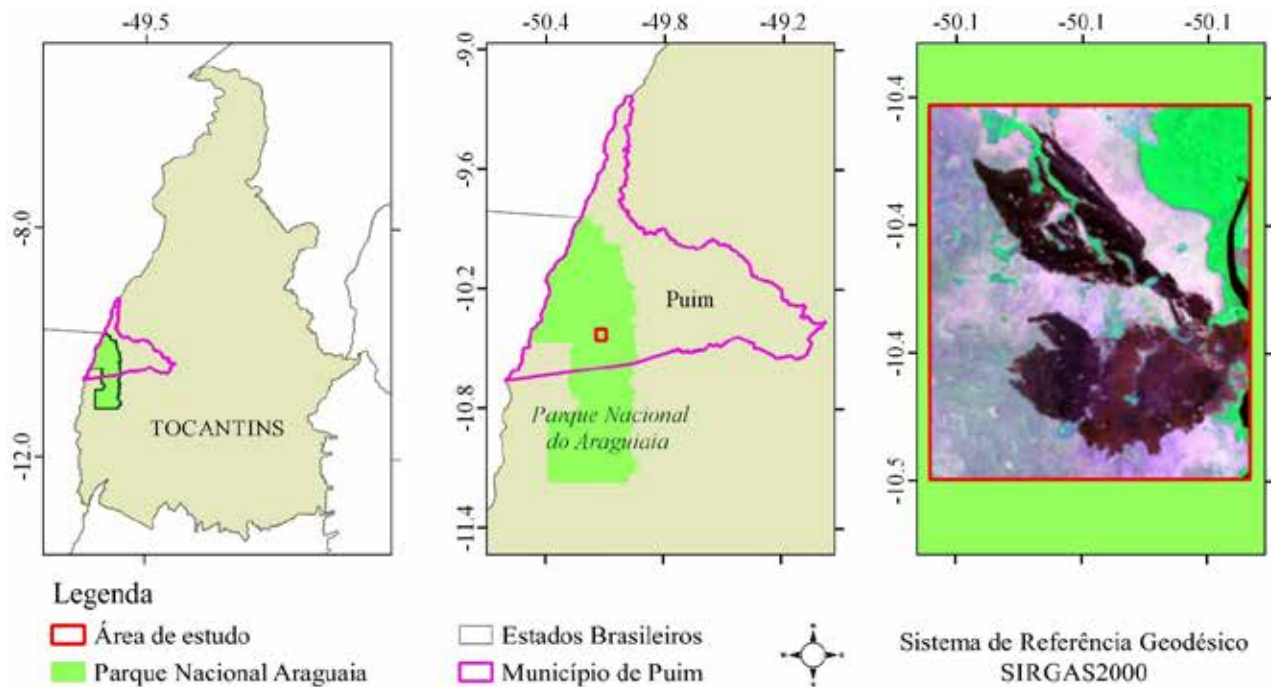


Figura 1 Localização da área de estudo.

2.2 Aquisição e Processamento dos Dados

Neste estudo utilizou-se uma cena do Satélite Landsat 7/ETM+ (ID: LE07_L1TP_223067_20010819_20170204_01_T1) e uma cena do Satélite Earth Observing One - EO1/Hyperion (ID: EO1H2230672001231111P0_1GST). Ambas as imagens apresentam resolução espacial de 30 m e são datadas de 13/09/2001, período de observação de focos de calor na referida área de estudo. Estas imagens foram obtidas gratuitamente no *site* do banco de dados (USGS, 2019).

O Hyperion permite a aquisição de imagens em 242 bandas espectrais (10 nm de largura cada) posicionadas nas faixas do visível (VIS), do infravermelho próximo (NIR) e do infravermelho de ondas curtas (SWIR). O sensor ETM+ é um radiômetro de varredura multiespectral fixo de oito bandas, entre elas uma pancromática (15 m), e detecta radiação filtrada espectralmente nas bandas do visível, infravermelho próximo, infravermelho de ondas curtas e termal, em uma faixa de 183 km de largura quando orbita a uma altitude de 705 km (Barsi *et al.*, 2016).

O Modelo Linear de Mistura Espectral (MLME) tem a capacidade envolver uma grande quantidade de bandas espectrais. Neste estudo utilizou-se no MLME o processamento de dados todas as bandas do sensor ETM+ (VIS, NIR e SWIR), com exceção da banda do infravermelho termal. Em relação ao sensor Hyperion,

utilizaram-se as 242 bandas espectrais no intervalo de 430 a 2400 nm.

Para o sensor ETM+ a transformação de *pixels* em escala de número digital (DN) para refletância no topo da atmosfera (ToA) foi realizado de acordo com o procedimento descrito no guia do usuário Landsat-7 da referência (USGS, 2019).

O pré-processamento da imagem Hyperion foi realizado através da correção dos efeitos atmosféricos, utilizando o modelo empírico de correção. Assumindo-se que a superfície é horizontal e tem uma refletância lambertiana apresentada na Equação 1.

$$L_0(\lambda) = L_{sun}(\lambda) T(\lambda) R(\lambda) \cos(\theta) + L_{path}(\lambda) \quad (1)$$

Em que: (λ) = comprimento de onda; $L_0(\lambda)$ = brilho observado no sensor; $L_{sun}(\lambda)$ = Radiação solar acima da atmosfera; $T(\lambda)$ = transmitância atmosférica total; $R(\lambda)$ = refletância da superfície θ = ângulo de incidência; $L_{path}(\lambda)$ = radiação dispersa no caminho. O resultado final é chamado de refletância no topo da atmosfera (ToA).

2.3 Modelo Linear de Mistura Espectral

(MLME)

O Modelo Linear de Mistura Espectral (MLME) permite calcular as frações ou proporções de cada objeto dentro de um *pixel*, que pode assumir várias dimensões, dependendo da resolução espacial de cada sensor. Essas frações são calculadas aplicando modelos matemáticos. Seguindo essa abordagem, a resposta espectral de cada *pixel* em qualquer banda espectral do sensor pode ser considerada como uma combinação linear das respostas espectrais de cada componente presente na mistura. Assim, cada *pixel* da imagem pode assumir qualquer valor dentro da faixa de nível de cinza, contendo informações sobre a proporção (quantidade) e a resposta espectral de cada componente dentro da unidade de resolução no solo (Shimabukuro & Ponzoni, 2019).

Portanto, para qualquer imagem multiespectral gerada por qualquer sistema sensor, considerando-se o conhecimento da proporção de componentes, será possível estimar a resposta espectral de cada um desses componentes. Da mesma forma, se essa resposta for conhecida, a proporção de cada componente na mistura pode ser estimada. Nesse caso, o sistema de equações do modelo de mistura espectral linear pode ser formulado pela Equação 2.

$$R_i = \sum (a_{ij}|x_j) + e_i \quad (2)$$

Em que:

R_i = refletância espectral média para a i -ésima banda espectral, a_{ij} = refletância espectral do j -ésimo componente no *pixel* para a i -ésima banda espectral, x_j = valor do j -ésimo componente no *pixel*, e_i = erro para a i -ésima banda espectral, $j = 1, 2, \dots, n$ (n = número de componentes realizados para o problema) e $i = 1, 2, \dots, m$ (m = número de bandas espectrais para o sistema sensor)

De acordo com (Shimabukuro & Ponzoni, 2019), as imagens das frações dos membros finais (*endmembers*) são definidas em níveis de cinza variando entre 0 e 1, correspondendo a proporções em porcentagem [0,100%] de *pixels* sem presença de mistura espectral. O erro quadrático médio (RMS) para cada *pixel* é calculado para uma diferença entre a violação observada e a implementação direta do modelo linear usando os vetores de membro final e como a fração do membro final. Essa característica ajudará na análise de diferentes sensores com diversas resoluções espaciais (Shimabukuro *et al.*, 2009).

Neste estudo foram geradas três imagens frações: vegetação, solo e sombra. A fração sombra realça a estrutura os corpos d'água, sombra e áreas queimadas, sendo o último o foco deste estudo, bem como a mudança da nomenclatura de fração sombra para a fração queimado (FQ) no processamento e análise dos resultados do MLME.

Uma vez que este componente traz as proporções por *pixels* da mistura espectral na cicatriz queimada.

2.3.1 Binarização da Fração Queimado (FQ)

As análises de avaliação da (FQ) nos *pixels* foi realizada a partir da binarização dos dados com base na (presença / ausência) de (AQ) de acordo com o modelo de mistura e classificação de imagens propostos por (Routh *et al.*, 2018). Dessa forma, a estrutura de dados viabilizou a obtenção de resultados significativos a partir de uma classificação em vários níveis de proporção de *pixels* ausentes de mistura espectral de áreas queimadas por incêndio.

Essa categorização binária considerou a classificação em três níveis de proporção FQ de *pixels* misturados: a) proporção de *pixels* acima de 70% de FQ, b) proporção de *pixels* acima de 80% de FQ e c) proporção de *pixels* acima de 90% FQ. O critério da binarização seguiu a Equação 3.

$$g(x,y) = \begin{cases} AQ_{sef}(x,y) > i \\ ANQ_{sef}(x,y) < i \end{cases} \quad (3)$$

Em que: $f(x,y)$ é a imagem FQ, i é a proporção em porcentagem da componente *queimado* no *pixel* e $g(x,y)$ é a imagem limiarizada tomando valores de 1 quando o *pixel* for classificado como AQ e 0 quando o *pixel* for classificado como não queimado ANQ.

Diante disso, fica preservada a separação das classes, o que é essencial para uma análise mais precisa da característica de mudança, uma vez que a escolha do limiar influi diretamente na qualidade do produto final. A classificação por proporções de mistura espectral também foi empregada por (Villa *et al.*, 2011) em imagens AVIRIS (Airborne visible/infrared imaging spectrometer).

Esta classificação seguiu o exemplificado na Figura 2, em (a) os *pixels* com FQ acima de 70% foram considerados como *pixels* com baixa proporção de mistura, e por isso, foram categorizados com valor 1. Para os *pixels* com proporção abaixo de 70%, são considerados como *pixels* com problemas de mistura, então em (b) foram categorizados como “não queimado” e em (c) este *pixel* recebe o valor 0.

2.4 Validação

Para a validação dos dados espaciais foi utilizado como referência o produto do mapeamento realizado pelo Programa de Monitoramento de Queimadas/Incêndios Florestais do INPE, disponível gratuitamente em (<http://queimadas.dgi.inpe.br/queimadas/aq30m/>). Este monitoramento utiliza imagens de baixa (300 a 1000 m) e média (10 a 50 m) resolução espacial. Os produtos são disponibilizados em formato vetorial e estimam

operacionalmente e em modo automático a superfície queimada, gerando mapas digitais, comparações temporais, e produtos de apoio à gestão e avaliação do impacto do uso do fogo na vegetação. Dessa forma, possibilita a detecção e quantificação regular da área queimada por meio de imagens de satélites à extensão da vegetação queimada no País.

2.5 Avaliação da Qualidade

A etapa de avaliação da exatidão dos produtos gerados pela FQ do MLME buscou verificar a acurácia da detecção de AQ em relação aos perímetros de referência dos produtos Banco de Dados de Queimadas (BDQueimadas) do Instituto Nacional de Pesquisas Espaciais disponível em (INPE, 2019).

Os processos de classificação são afetados por erros, de forma que há um elemento de incerteza em relação aos resultados produzidos por dados orbitais. Portanto, a qualidade dos dados de sensoriamento remoto e de seus produtos derivados precisam ser caracterizadas quantitativamente para facilitar as informações críticas sobre a confiabilidade do produto aos usuários finais (Chuvienco *et al.*, 2008). A precisão dos resultados é geralmente obtida através da tabulação cruzada em relação aos conjuntos de dados de referência, contabilizando as coincidências e desacordos espaço-temporais. A abordagem é amplamente usada em projetos de mapeamento de áreas queimadas (Tanase *et al.*, 2020).

O processo de avaliação da exatidão foi baseado em *pixels* e consistiu na intersecção dos mapas de referência com os mapas extraídos pela metodologia através das Matrizes de Confusão (Pereira *et al.*, 2017). Dessa forma,

foram calculadas diferentes medidas de verificação. Entre elas: Acurácia Global (AG), Erro de Omissão (EO), Erro de Comissão (EC), Viés Estatístico (BIAS), Coeficiente de Dice (DICE) e Índice de Sucesso Crítico (CSI). A Tabela 1 mostra os elementos, da Matriz de Confusão, utilizados para os cálculos dos parâmetros estatísticos (Congalton *et al.*, 1983).

2.5.1 Coeficiente Kappa

O Coeficiente Kappa (Equação 4), avalia a precisão de uma classificação em uma comparação entre os valores estimados e de referência considerando o efeito da mudança entre as classes. O coeficiente Kappa foi introduzido na comunidade de sensoriamento remoto no início dos anos 80 (Congalton *et al.*, 1983) e tornou-se uma medida amplamente usada para avaliar a precisão da classificação.

$$K = \frac{p_0 - p_e}{1 - p_e} \quad (4)$$

Em que: p_0 = precisão da concordância observada na linha i e na coluna i :

p_e = estimativa da concordância casual no total marginal da linha i ; e total marginal da coluna i .

2.5.2 Correlação de Pearson (CP)

A correlação de Pearson é uma medida de associação linear entre duas variáveis para medir os níveis de correlação (Equação 5):

$$\frac{cov(X, Y)}{\sqrt{var(X) * var(Y)}} \quad (5)$$

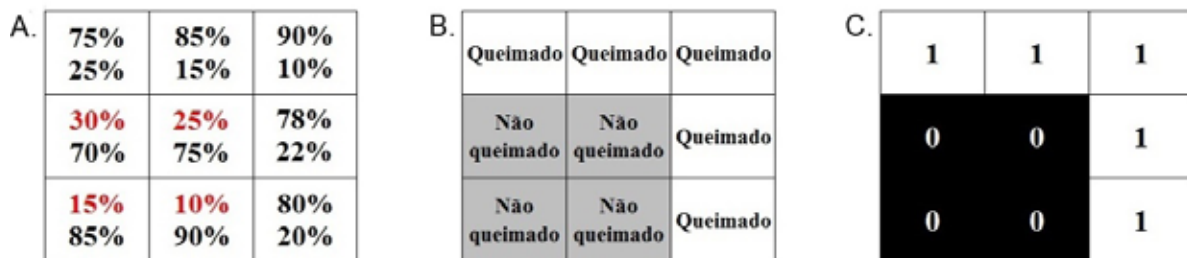


Figura 2 A. Representação de FQ (%) e B. Classificação categórica C. Classificação por binarização.

Mapa de Referência				
		Queimado	Não queimado	Total
Mapa Classificado pelo usuário	Queimado	A	B	A + B
	Não queimado	C	D	C + D
	Total	A + C	B + D	A + B + C + D

Tabela 1 Tabela de Matriz de Confusão entre o produto de referência e área queimada (AQ).

Segundo (Pearson, 1997), o coeficiente de correlação de Pearson é a covariância das duas variáveis divididas $cov(X,Y)$ pela raiz do produto de seus desvios-padrão $\sqrt{var(X)*var(Y)}$. Os resultados variam entre +1 e -1, em que 1 é correlação linear positiva total, 0 não é correlação linear e -1 é correlação linear negativa total.

3 Resultados e Discussão

Nesta sessão são analisados e discutidos os comportamentos espectrais nos sensores multiespectrais e hiperespectrais para classes queimadas e não queimadas e seus respectivos padrões visuais.

3.1 Análise Espectral na Área Queimada

A Figura 3 mostra as imagens fração queimado (FQ) normalizadas para os sensores Hyperion e ETM+. Pode-se observar que os níveis de cinza mais claros são referentes a *pixels* com alta proporção de FQ não misturados, enquanto os níveis de cinza próximo a zero (0) representam as feições com baixo ou ausente percentual de *pixels* puros de AQ. Essas imagens também permitiram diferenciar algumas variações de níveis de cinza dentro da cicatriz de fogo, principalmente no sensor Hyperion, o que se presume estar relacionada ao nível de gravidade da queimada.

Este mesmo comportamento também foi encontrado em (Quintano *et al.*, 2017), em que os autores observaram que as oscilações nos valores de *pixels* na FQ são diretamente proporcionais à resolução espectral do sensor e à temperatura da superfície. Podendo, dessa forma, identificar cicatrizes queimadas mais frias e quentes, ou menos, ou mais severas dentro da área atingida pelo fogo.

Segundo (Kruse *et al.*, 2003), na área de estudo acontece uma intensa atividade de queimada na vegetação sazonalmente no segundo semestre do ano. Dessa forma, a sensibilidade na interação dos menores comprimentos de onda no sensor Hyperion com os particulados emitidos da queima e a fumaça podem causar atenuação nas relações sinal-ruído do sensor.

A FQ_{ETM+} possibilitou distinção na ocupação do solo no entorno da AQ, é possível identificar variações de níveis de cinza e representativo escurecimento na imagem FQ, principalmente, em feições de mata ciliar. Nestas feições, os *pixels* aparecem com baixa proporção de *pixels* puros, ou seja, com valores próximos a zero, o que não é visto com constância na imagem (FQ_{HYP}). Nos histogramas da Figura 4, este comportamento é ressaltado através da elipse azul (Figura 4A).

Nas regiões espectrais do visível e infravermelho próximo, o sensor ETM+ é dividido em quatro bandas espectrais, enquanto o Hyperion apresenta 70 bandas. Desta forma, o sensor hiperespectral apresenta respostas mais distintas para cada tipo de feição, possibilitando distinguir melhor o comportamento nos *pixels* afetados por mistura espectral, mesmo em feições que apresentam comportamentos espectrais semelhantes. Isto é exemplificado na Figura 4B, a qual mostra as assinaturas espectrais em alvos de AQ para o Hyperion e ETM+. Esta característica justifica a alta frequência de *pixels* de FQ com valores próximos a 1 no corpo hídrico da imagem ETM+, mostrado na seta vermelha na Figura 4B e na elipse vermelha da Figura 4A.

A área queimada e a água apresentam alta absorção da luz solar e isto gerou confusões na amostragem de proporções de FQ no algoritmo MLME para o sensor




Figura 3 A. Fração Queimado para o sensor Hyperion; B. Fração Queimado para o Sensor ETM+.

Análise do Modelo Linear de Mistura Espectral na Avaliação de Incêndios Florestais no Parque Nacional do Araguaia, Tocantins, Brasil: Imagens EO-1/Hyperion e Landsat-7/ETM+

Juarez Antonio da Silva Junior & Admilson da Penha Pacheco

ETM+. Este comportamento retorna a discussão sobre o uso de sensores Multiespectrais para classificar membros finais em paisagens opticamente complexas. (Rogan *et al.*, 2001) identificaram um comportamento inverso, mas em áreas sombreadas. Mostrando a capacidade benéfica da FQ ao separar a sombra induzida pelo terreno da variação espectral de uma cena afetada pelo fogo, utilizando imagens ETM+ e o algoritmo *Multiple Endmember Spectral Mixture Analysis* (MESMA). Pereira *et al.* (2017) revelaram que a

área recém-queimada, na faixa do visível, confunde-se com a água e zonas úmidas e, além disso, as alterações espectrais induzidas pelo fogo nessa faixa podem parecer ambíguas ou contraditórias causando incoerência na aplicação de classificação de imagens e modelos de mistura espectral.

A Figura 5 apresenta uma comparação visual dos mapas binarizados de proporções de FQ na área de estudo. Como pode ser observado, os mapas ($FQ_{ETM+90\%}$) apresentaram menor separação de *pixels* classificados




Figura 4 A. Histograma da imagem FQ do sensor Hyperion e ETM+; B. Assinatura espectral de um *pixel* de AQ para os sensores Hyperion e ETM+.

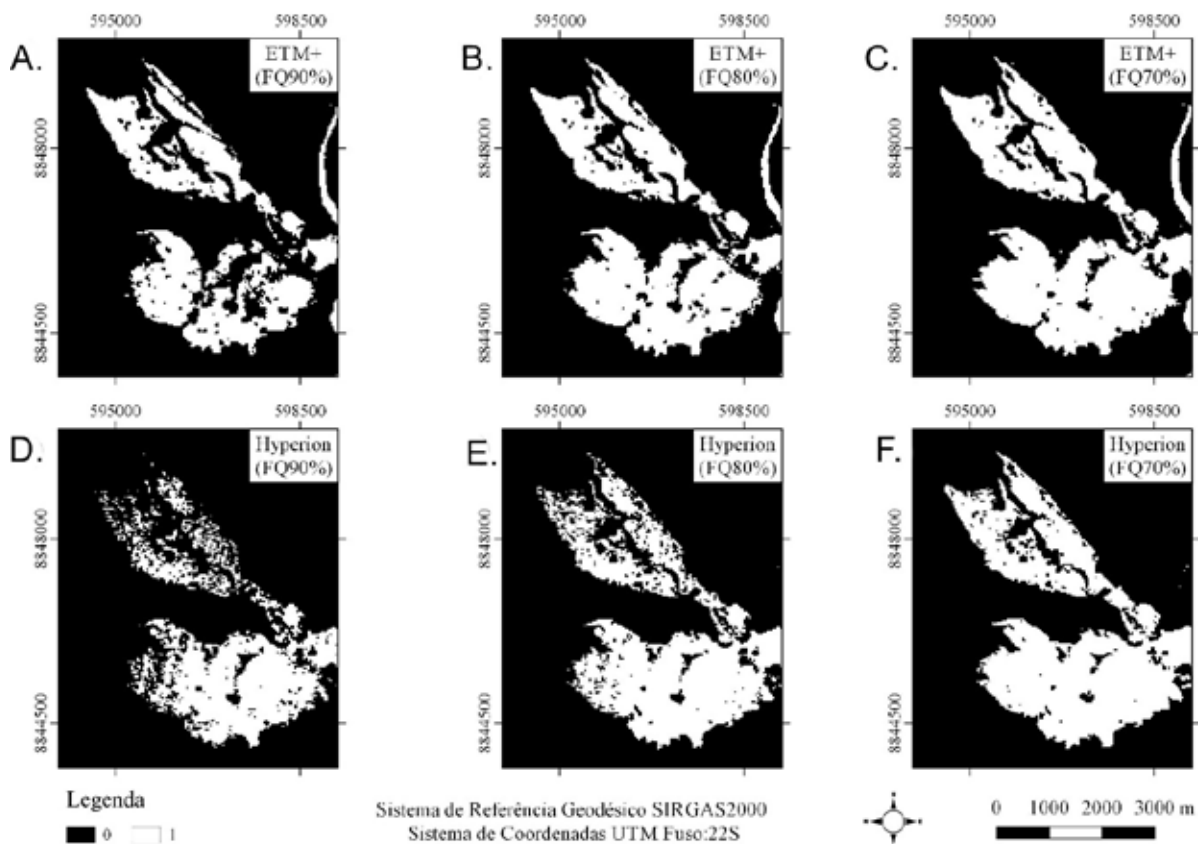


Figura 5 Mapas com imagens de proporção de (FQ) binarizadas para os sensores Hyperion e ETM+.

como AQ. Os mapas de ($FQ_{ETM+70\%}$) e ($FQ_{ETM+80\%}$) não apresentaram variações importantes, porém, a feição do corpo hídrico ficou preservada nas três proporções. Nos mapas do sensor Hyperion, assim como ETM+, na proporção de 90%, houve maior frequência de *pixels* classificados como ANQ, embora na parte resultante do rio foi corretamente classificada como ANQ em todas as proporções.

3.2 Análise do Erro de Omissão (EO) e Comissão (EC)

A Figura 6 apresenta um comportamento crescente de erro de omissão com a diminuição da proporção de FQ especialmente para o sensor ETM+, embora a $FQ_{70\%}^i$ apresentou individualmente o maior valor da série. Ainda, nesta proporção, o erro apresentado foi caracterizado devido à disparidade de 3,7 km² entre o mapeamento de referência somado com 0,75 km² sem classificação. Isso resultou em um Erro de Omissão de 27%. Já o erro de comissão, mostrou-se pelos baixos valores em ambos os sensores.

Os maiores valores EC foram registrados para $FQ_{90\%}$, em que, nesta proporção, 4515 *pixels*, ou seja, os *pixels* que seriam da classe *queimado* foram classificados como *não queimado* e vice-versa.

3.3 Análise do Viés Estatístico (BIAS)

Os mapas de $FQ_{70\%}$ para ambos os sensores apresentaram pequenas variações de BIAS (0,94~0,96), e somente o sensor Hyperion registrou a maior correlação de Pearson (CP = 0,91). Para os mapas de proporção $FQ_{80\%}$, os sensores obtiveram o mesmo valor de Correlação de Pearson (CP = 0,8), entretanto, o BIAS para o sensor Hyperion registrou menor valor (0,82) em relação ao ETM+ (0,88).

As proporções $FQ_{80\%}$ e $FQ_{70\%}$ apresentaram boas relações com o mapa de referência, porém, esses mapas podem ter sido superestimados devido à diminuição de exigência proporcional da FQ.

Para os mapas de $FQ_{90\%}$, os valores de CP e BIAS apresentam uma diminuição gradativa em relação aos mapas $FQ_{80\%}$ e $FQ_{90\%}$ nos dois sensores em análise, além disso, houve estabilização entre os valores para o sensor ETM+ (0,72 para ambos os parâmetros). Enquanto o sensor Hyperion, ainda nesta proporção, apresentou (BIAS = 0,63) e (CP = 0,72).

No geral, ambos os sensores apresentaram valores bastante próximos, havendo a necessidade de observação de outros parâmetros como o Índice DICE e o CSI apresentados na Figura 7.

3.4 Análise de Coeficiente de Dice (DICE) e Índice de Sucesso Crítico (CSI)

O gráfico *dotplot* na Figura 8 mostra que os parâmetros CSI e DICE tendem a crescer quando a precisão da FQ tende a diminuir para ambos os sensores. Para o Hyperion, essa afirmação se torna mais efetiva, quando o CSI alcança um valor máximo de 0,87 na proporção de menor exigência $FQ_{70\%}$. Para o ETM+, como mencionado anteriormente, o CSI apresentou diminuição gradativa, passando de 0,76 para 0,62 ao longo do aumento da proporção de FQ.

No caso do coeficiente de DICE, no sensor ETM+, os mapas de $FQ_{80\%}$ e $FQ_{90\%}$ mostram uma diminuição gradativa dos valores, justificada pelo número de *pixels* falsos positivos detectados, passando de 2333 para 3841, respectivamente, enquanto o ($FQ_{70\%}$) obteve 1674. O sensor Hyperion apresentou valores mais consistentes de coeficiente de DICE corroborando a diminuição de *pixels*

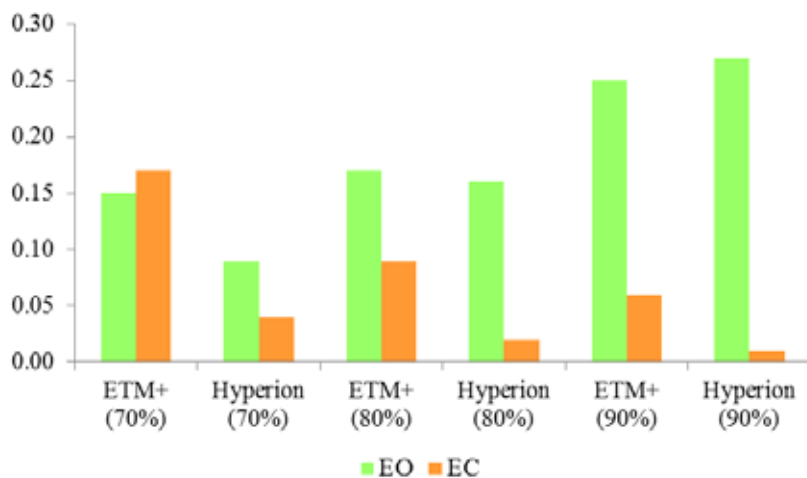


Figura 6 Gráficos de barras para os erros de omissão (EO) e comissão (EC).

verdadeiros positivos com o aumento da proporção, na qual, para o FQ_{70%} foi de 10,328, FQ_{80%} de 9246 e FQ_{90%} de 7186. Os parâmetros DICE e CSI apresentaram um comportamento diretamente proporcional, correspondente a resultados encontrados por (Pereira *et al.*,2017) em imagens hiperespectrais.

3.5 Acurácia Global e Índice Kappa

No geral, como mostra a Tabela 2, relativamente, as grandes acurácias globais (AG) são encontradas quando AG > 60%. Dessa forma, todos os valores produziram boas estimativas. o sensor ETM+ apresentou valores de AG menores em relação ao Hyperion, em todas as proporções, em que ambos os sensores apresentam um comportamento crescente de Acurácia global com a diminuição de proporção de FQ.

O Índice Kappa apresentou o mesmo comportamento da AG, com maiores valores para o sensor hiperespectral, embora houvesse estabilização de valores em ambos os sensores quando a proporção alcançou 90%.

Avalia-se que a aplicação da metodologia proposta por imagens orbitais de diferentes resoluções espectrais foi eficiente na mensuração de áreas queimadas por incêndio, permitindo optar por quais especificações devem ser levadas em consideração, com base na necessidade do usuário. Além disso, foi verificada a validade de mapas gerados pelo MLME com base na classificação de áreas queimadas e não queimadas. Os dados de referência do Programa BDQueimadas foi bastante útil em permitir a análise da acurácia da classificação, por meio das Matrizes de Confusão de uma imagem multiespectral (ETM+) e hiperespectral (Hyperion) de resolução espacial (30 m) e temporal (19/08/2001) únicas.

No geral, ambos os produtos mostraram a mesma tendência em relação aos parâmetros de acurácia analisados. Dessa forma, foi visto que, conforme a diminuição da proporção da FQ, os parâmetros de acurácia aumentavam ou estabilizavam. Este comportamento pode estar relacionado à perda de *pixels* nas bordas, nas quais ocorre maior frequência de *pixels* misturados. Pereira *et al.* (2017) revelaram que isso é comum na comparação de imagens

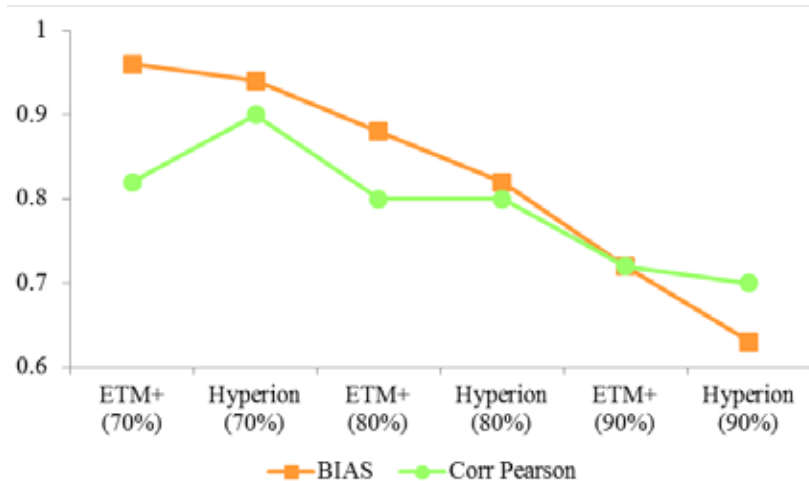


Figura 7 Gráficos de linhas para os parâmetros Viés Estatístico (BIAS) e Correlação de Pearson (CP).




Figura 8 Gráfico Dotplot para os parâmetros Coeficiente de Dice (DICE) e Índice de Sucesso Crítico (CSI)

Análise do Modelo Linear de Mistura Espectral na Avaliação de Incêndios Florestais no Parque Nacional do Araguaia, Tocantins, Brasil: Imagens EO-1/Hyperion e Landsat-7/ETM+

Juarez Antonio da Silva Junior & Admilson da Penha Pacheco

e dados de referência coletados em diferentes resoluções espectrais, cujas irregularidades dos alvos pós-limiarização são determinantes para maiores números de *pixels* de falsos negativos.

Outro fator deste resultado se relaciona ao mapeamento de referência conter pequenas feições de queima fora da camada principal da cicatriz, na qual, essas feições, não foram detectadas pelo mapeamento gerado pelas FQ. No geral, o sensor ETM+ apresentou valores semelhantes aos parâmetros de avaliação do mapeamento com o sensor Hyperion, porém, mais baixos, conforme é mostrado nas as Figuras 6,7 e 8 e Tabela 2.

O principal causador deste resultado pode estar relacionado aos *pixels* de corpos hídricos que o modelo identificou como áreas queimadas. Em contrapartida, para o Hyperion, nos mapas de proporções FQ_{80%} e FQ_{90%}, houve maior perda de *pixels* dentro da região queimada devido à alta frequência de mistura de *pixels* causada pelo solo degradado pós-incêndio, que pode ter aumentado os valores de erro de omissão.

Os parâmetros erro de omissão e comissão foram relativamente moderados e os parâmetros Coeficiente de Pearson, BIAS, DICE e CSI foram próximo a 1 para ambos os sensores. Isso significa que uma classificação com base em proporções da FQ, para ambos os sensores, pode ser abordada com confiança. Salienta-se que, para imagens multiespectrais, áreas sombreadas e corpos hídricos devem ser evitados quando se desejam realizar verificações de AQ. A aplicação do MLME em imagens multiespectrais e hiperespectrais apresentam-se como uma ferramenta importante na identificação e classificação de diferentes elementos da cobertura terrestre.

Os estudos mostraram que todas as verificações estão subordinadas ao processo de binarização da FQ adotado para separar a AQ e a ANQ. Um bom fracionamento entre as classes evita subestimar ou superestimar feições importantes no mapeamento. Além disso, a qualidade deste

procedimento não se resume em apenas verificação visual do operador, parâmetros de acurácia gerados pela Matriz de Confusão, auxiliam na compreensão dos erros ocorridos na classificação individualmente. Essas possibilidades podem aumentar a precisão no mapeamento de AQ.

4 Conclusões

A eficiência do mapeamento de área queimada, que utiliza sensoriamento remoto óptico, não depende apenas da resolução espaço-espectral da imagem utilizada ou da complexidade do algoritmo de membros finais de *pixels*, mas também dos aspectos do tempo de atividade de queimada na superfície e dissimilaridades nos espectros de refletância.

O uso de métodos de modelos de estimativas precisas de abundância final do *pixel* é recomendável quando se objetiva agrupar *pixels* em classes com precisão considerável, tanto em sensores multiespectrais e hiperespectrais. As imagens de mesmo dia de aquisição trouxeram resultados confiáveis, uma vez que a vegetação do Cerrado possui um rápido poder de regeneração e o substrato queimado tem relação proporcional com o tempo inicial da queimada.

A experiência realizada neste estudo gerou resultados promissores na representação de áreas queimadas. Recomenda-se a aplicação do método em estudos na composição das imagens fração para comparação com outros sensores hiperespectrais de maior resolução espacial como AVIRIS e Hymap.

Um dos principais resultados deste trabalho é a divulgação de metodologias de implementação mais efetiva do uso de dados hiperespectrais para a qualidade de produtos geoespaciais e monitoramento de queimadas em todo o Brasil, beneficiando uma ampla gama de usuários, incluindo órgãos governamentais, grupos de pesquisa, ecologistas, bombeiros e ONGs.

Sensores (prop%)	Acurácia Global (%)	Índice Kappa
ETM+ (70%)	92.58	0.81
Hyperion (70%)	96.23	0.9
ETM+ (80%)	91.72	0.78
Hyperion (80%)	94.03	0.84
ETM+ (90%)	88.72	0.69
Hyperion (90%)	89.1	0.7

Tabela 2 Valores dos parâmetros de Acurácia global e Índice Kappa.

5 Referências

- Addison, P.; Oommen, T. 2018. Utilizing satellite radar remote sensing for burn severity estimation. *International Journal of Applied Earth Observing Geoinformation*, 73: 292–299.
- Anderson, L.; Marchezini, V.; Morello, T. F. & Cunningham, H. A. 2019. Conceptual model of disaster risk management and warning system associated with wildfires and public policy challenges in Brazil. *Territorium (Coimbra)*, 1: 43-61.
- Barsi, J. A.; Markham, B. L.; Czapla-Myers, J. S.; Helder, D. L.; Hook, S. J.; Schott, J. R. & Haque, M. O. 2016. Landsat-7 ETM+ radiometric calibration status. In: PROCEEDINGS VOLUME 9972, EARTH OBSERVING SYSTEMS XXI; 99720C, Disponível em: <<https://doi.org/10.1117/12.2238635>>. Acesso em: 18/05/2010.
- Chuvieco, E.; Mouillot, F.; Van Der Werf, G. R.; San Miguel, J.; Tanasse, M.; Koutsias, N. & Giglio, L. 2019. Historical background and current developments for mapping burned area from satellite Earth observation. *Remote Sensing of Environment*, 225: 45-64.
- Chuvieco, E.; Opazo, S.; Sione, W.; Del Valle, H.; Anaya, J.; Di Bella, C.; Cruz, I.; Manzo, L.; López, G. & Mari, N.; 2008. Global burned land estimation in latin america using modis composite data. *Ecological Applications*, 18: 64–79.
- Congalton, R.; Oderwald, R. & Mead, R. 1983. Assessing Landsat classification accuracy using discrete multivariate statistical techniques. *Photogrammetric Engineering and Remote Sensing*, 49(12):1671–1678.
- Fernandez-Manso, A.; Quintano, C. & Roberts, D. A. (2016). Burn severity influence on post-fire vegetation cover resilience from Landsat MESMA fraction images time series in Mediterranean forest ecosystems. *Remote Sensing of Environment*, 184:112–123. doi:10.1016/j.rse.2016.06.015
- INPE. 2019. Instituto Nacional de Pesquisas Espaciais. Dados pontuais de focos de calor. Programa de Monitoramento de Focos de Calor. Disponível em: <<http://sigma.cptec.inpe.br/queimadas/>>. Acesso em: 17/08/2019.
- Kruse, F. A.; Boardman, J.W. & Huntington, J.F. 2003. Comparison of airborne hyperspectral data and EO-1 Hyperion for mineral mapping. *IEEE Transactions on Geoscience and Remote Sensing*, 41: 1388–1400.
- Libonati, R.; DaCamara, C. C.; Setzer, A. W.; Morelli, F. & Melchiori, A. E. 2015. An algorithm for burned area detection in the Brazilian Cerrado using 4 µm MODIS imagery. *Journal Remote Sensing*, 7: 15782-15803.
- Paiva, Y. R. Y. 2019. Burned area and fuel load mapping in a protected area situated in the Brazilian Cerrado, using linear spectral unmixing model. In: Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto, 2019, Santos. Anais eletrônicos... São José dos Campos, INPE, 2019.
- Pearson, K. 1997. Mathematical Contributions to the Theory of Evolution. XI. On the Influence of Natural Selection on the Variability and correlation of organs. *Philosophical Transactions of the Royal Society of London. Series A, Containing Papers of a Mathematical or Physical Character*, Volume 200: 1-66.
- Pereira, A. A.; Pereira, J. M. C.; Libonati, R.; Oom, D.; Setzer, A.W.; Morelli, F.; Machado-Silva, F. & De Carvalho, L. M. T. 2017. Burned Area Mapping in the Brazilian Savanna Using a One-Class Support Vector Machine Trained by Active Fires. *Remote Sensing*, 9, 1161: 1-21.
- Quintano, C.; Fernandez-Manso, A & Roberts, D. A. 2017. Burn severity mapping from Landsat fraction images and Land Surface Temperature. *Remote Sensing of Environment*, 190: 83–95.
- Raksuntorn, N. & Du, Q. 2008. A New Linear Mixture Model for Hyperspectral Image Analysis. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM. Boston, MA, USA. Volume 5.
- Redin, M.; Santos, G. F.; Miguel, P.; Denega, L. G. Lupatini, M.; Doneda, A. & Sousa, E. L. 2011. Impactos da queima sobre atributos químicos, físicos e biológicos do solo. *Ciência Florestal*, Santa Maria, 21 (2): 381-392.
- Rogan, J.; Janet, F. 2001. “Mapping Wildfire Burn Severity in Southern California Forests and Shrublands Using Enhanced Thematic Mapper Imagery”. *Geocarto International*, 16(4): 91-1001.
- Routh, D.; Seegmiller, L.; Bettigole, C.; Kuhn, C.; Oliver, C.D.; Glick, H.B. 2018. Improving the Reliability of Mixture Tuned Matched Filtering Remote Sensing Classification Results Using Supervised Learning Algorithms and Cross-Validation. *Remote Sensing*, 10 (11): 1-19.
- Saulino, L.; Rita, A.; Migliozi, A.; Maffei, C.; Allevato, E.; Garonna, A.P. & Saracino, A. 2020. Detecting Burn Severity across Mediterranean Forest Types by Coupling Medium-Spatial Resolution Satellite Imagery and Field Data. *Remote Sensing*, 12, 741: 1-21.
- Shimabukuro, Y. E. & Ponzoni, F. J. 2019. *Spectral Mixture for Remote Sensing: Linear Model and Applications*. Springer Remote Sensing/Photogrammetry. São Paulo: Oficina de Textos. 77 p.
- Shimabukuro Y. E.; V. Duarte; E. Arai; R. M. Freitas; A. Lima; D. M. Valeriano; I. F. Brown & M. L. R. Maldonado 2009. Fraction images derived from Terra Modis data for mapping burnt areas in Brazilian Amazonia, *International Journal of Remote Sensing*, 30:6, 1537-1546.
- Solans Vila, J.P. & Barbosa, P. 2010. Post-fire vegetation regrowth detection in the Deiva Marina region (Liguria-Italy) using Landsat TM and ETM+ data. *Ecological Modelling*, 221: 75–84
- Small, C. 2004. The Landsat ETM+ spectral mixing space. *Remote Sensing of Environment*, 93(1-2): 1–17.
- Tanase, M.A.; Belenguer-Plomer, M.A.; Roteta, E.; Bastarrika, A.; Wheeler, J.; Fernández-Carrillo, Á.; Tansey, K.; Wiedemann, W.; Navratil, P.; Lohberger, S.; Siegert, F. & Chuvieco, E. 2020. Burned Area Detection and Mapping: Intercomparison of Sentinel-1 and Sentinel-2 Based Algorithms over Tropical Africa. *Remote Sensing*, 12, 334: 1-15.
- USGS. 2019 UNITED STATES GEOLOGICAL SURVEY. Landsat 7 Data Users Handbook. U.S. Geological Survey. Disponível em: <<https://www.usgs.gov/media/files/landsat-7-data-users-handbook/>>. Acesso em: 17/08/2019.
- Veraverbeke, S.; Dennison, P.; Gitas, I.; Hulley, G.; Kalashnikova, O.; Katagis, T... & Stavros, N. 2018. Hyperspectral remote sensing of fire: State-of-the-art and future perspectives. *Remote Sensing of Environment*, 216, 105–121.
- Villa, A. J.; Chanussot, J. A.; Benediktsson & C. Jutten, 2011. “Spectral Unmixing for the Classification of Hyperspectral Images at a Finer Spatial Resolution,” in *IEEE Journal of Selected Topics in Signal Processing*, 5(3): 521-533.