



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIAS E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA CARTOGRÁFICA E DE AGRIMENSURA
CURSO DE GRADUAÇÃO EM ENGENHARIA CARTOGRÁFICA E DE
AGRIMENSURA

JUAREZ ANTÔNIO DA SILVA JÚNIOR

**ANÁLISE DE ACURÁCIA PARA O MAPEAMENTO DE ÁREAS QUEIMADAS
UTILIZANDO IMAGENS SLSTR E MODIS NO CERRADO**

Recife
2021

JUAREZ ANTÔNIO DA SILVA JÚNIOR

**ANÁLISE DE ACURÁCIA PARA O MAPEAMENTO DE ÁREAS QUEIMADAS
UTILIZANDO IMAGENS SLSTR E MODIS NO CERRADO**

Trabalho de Conclusão de Curso
apresentado ao Curso de Engenharia
Cartográfica e de Agrimensura da
Universidade Federal de Pernambuco,
Centro de Tecnologia e Geociências,
como requisito parcial para obtenção do
grau de Bacharel em Engenharia
Cartográfica e de Agrimensura.

Orientador: Prof. Dr. Admilson da Penha Pacheco.

Recife

2021

Catálogo na fonte:
Bibliotecária Sandra Maria Neri Santiago, CRB-4 / 1267

S586a Silva Júnior, Juarez Antônio da.
Análise de acurácia para o mapeamento de áreas queimadas utilizando imagens SLSTR e MODIS no cerrado / Juarez Antônio da Silva Júnior. – 2021.
45 f.: il., figs., tabs.

Orientador: Prof. Dr. Admilson da Penha Pacheco.
TCC (Graduação) – Universidade Federal de Pernambuco. CTG. Departamento de Engenharia Cartográfica e de Agrimensura, 2021.
Inclui referências.

1. Engenharia cartográfica. 2. Incêndios florestais. 3. SLSTR. 4. MODIS. 5. Sensoriamento remoto. 6. Cerrado. I. Pacheco, Admilson da Penha (Orientador). II. Título.

UFPE

526.1 CDD (22. ed.)

BCTG/2022-135

JUAREZ ANTÔNIO DA SILVA JÚNIOR

**ANÁLISE DE ACURÁCIA PARA O MAPEAMENTO DE ÁREAS QUEIMADAS
UTILIZANDO IMAGENS SLSTR E MODIS NO CERRADO**

Trabalho de Conclusão de Curso
apresentado ao Curso de Engenharia
Cartográfica e de Agrimensura da
Universidade Federal de Pernambuco,
Centro de Tecnologia e Geociências,
como requisito parcial para obtenção do
grau de Bacharel em Engenharia
Cartográfica e de Agrimensura.

Aprovado em: 01/09/2021.

BANCA EXAMINADORA

Prof. Dr. Admilson P. Pacheco (Orientador)
Universidade Federal de Pernambuco

Prof. Dr. Lênio Soares Galvão (Examinador Externo)
Instituto Nacional de Pesquisas Espaciais

Prof. Msc. Weyller Diogo Albuquerque Melo (Examinador Interno)
Universidade Federal de Pernambuco

RESUMO

Os incêndios florestais são considerados um dos maiores perigos e questões ambientais em todo o mundo. No bioma Cerrado os incêndios florestais têm várias consequências, incluindo aumento da temperatura, diminuição das chuvas, esgotamento genético de espécies naturais e aumento do risco de doenças respiratórias. Recentemente, os sensores dos satélites de observação da Terra provaram ser eficazes para a detecção de incêndios florestais, embora a qualidade e a utilidade dos dados sejam frequentemente prejudicadas pela presença de nuvens. Uma solução alternativa prática é combinar conjuntos de dados de vários sensores. Esta pesquisa apresenta uma metodologia, que utiliza dados do sensor Radiômetro de Temperatura do Mar e da Superfície Terrestre (SLSTR) do Satélite Sentinel-3 e o Espectrorradiômetro de Imagem de Resolução Moderada (MODIS) do Satélite Terra para analisar acurácia temática de mapas de área queimada e sua sensibilidade sob diferentes resoluções espectrais, numa porção de 31759,6 Km² do Cerrado nos anos de 2016 a 2019. A metodologia utilizou treinamentos com o classificador Support Vector Machines (SVM). As peculiaridades espectrais de cada uma dessas plataformas utilizaram-se estatísticas de separabilidade Transformed Divergence Index (TD). A validação é realizada a partir de mapas de referência nacional de área queimada derivados de imagens Landsat. Os resultados mostraram que a banda do infravermelho próximo, para ambos os sensores, possui um papel imprescindível para a detecção da área queimada, apresentando altas estimativas de separabilidade. No geral, foi possível observar que os problemas de mistura espectral, data de registro e a resolução espacial de 500m foram os principais fatores que levaram a erros de comissão com variações entre 15% e 72% e erros de omissão entre 51% e 86% para ambos os sensores. Este estudo mostrou a importância dos sensores multiespectrais para o monitoramento de incêndios florestais, havendo uma complementação com outras plataformas para rastrear a queima de biomassa. Constatou-se, entretanto, que a resolução espectral e data da queima podem interferir gradualmente no processo de detecção.

Palavras-chave: incêndios florestais; SLSTR; MODIS; sensoriamento remoto; cerrado.

ABSTRACT

Forest fires are considered to be one of the greatest environmental hazards and issues in the world. In the Cerrado biome, forest fires have several consequences, including increased temperature, reduced rainfall, genetic depletion of natural species and increased risk of respiratory diseases. Recently, Earth observation satellite sensors have proven to be effective for detecting forest fires, although the quality and usefulness of the data is often undermined by the presence of clouds. A practical workaround is to combine datasets from multiple sensors. This research presents a methodology that uses data from the Sea and Earth Surface Temperature Radiometer (SLSTR) sensor from the Sentinel-3 Satellite and the Moderate Resolution Image Spectroradiometer (MODIS) from the Earth Satellite to analyze thematic accuracy of area maps burning and its sensitivity under different spectral resolutions, in a portion of 31759.6 km² of the Cerrado in the years 2016 to 2019. The methodology used training with the Support Vector Machines (SVM) classifier. For the spectral peculiarities of each of these platforms, Transformed Divergence Index (TD) separability statistics were used. Validation is carried out using national reference maps of the burned area derived from Landsat images. The results showed that the near infrared band, for both sensors, has an essential role in the detection of the burned area, presenting high separability estimates. In general, it was possible to observe that the problems of spectral mixing, registration date and the spatial resolution of 500 m were the main factors that led to commission errors with variations between 15% and 72% and omission errors between 51% and 86% for both sensors. This study showed the importance of multispectral sensors for monitoring forest fires, complementing them with other platforms to track biomass burning. It was found, however, that the spectral resolution and burning date can gradually interfere in the detection process.

Keywords: forest fires; SLSTR; MODIS; remote sensing; cerrado.

LISTA DE ILUSTRAÇÕES

Figura 1 –	Localização da área de estudo no sul do estado do Piauí e ao norte do bioma Cerrado	17
Figura 2 –	Esquema de classificação por <i>Support Vector Machine</i> (SVM)	21
Quadro 1 –	Matriz de confusão entre o produto de referência e as áreas classificadas queimadas / não queimada.	24
Figura 3 –	Valores de separabilidade para as bandas MODIS e SLSTR utilizadas	26
Figura 4 –	Relação entre a acurácia com os parâmetros (C e γ) do classificador SVM	28
Figura 5 –	Relação entre o RMSE e o número de iterações para os parâmetros para (C e γ) pré estabelecidos do classificador SVM	29
Figura 6 –	Distribuição espacial dos erros de omissão e comissão para os mapas de área queimada gerados pelo classificador SVM nas imagens SLSTR e MODIS	30
Figura 7 –	Regressões da proporção de área queimada em cada grade quadrada de 5 x 5 km dos mapas gerados pelos sensores MODIS e SLSTR e o mapa de referência derivado do Aq30m	35

LISTA DE TABELAS

Tabela 1 –	Características das imagens obtidas pelos sensores MOD09A1 e SLSTR utilizadas neste estudo	19
Tabela 2 –	Datas das imagens SLSTR e MODIS e os dados Aq30m	19

SUMÁRIO

1	INTRODUÇÃO	9
2	OBJETIVOS	12
2.1	OBJETIVOS ESPECÍFICOS	12
3	FUNDAMENTAÇÃO TEÓRICA	13
3.1	FOGO NO BIOMA CERRADO	13
3.2	CARTOGRAFIA E SENSORIAMENTO REMOTO DE ÁREAS QUEIMADAS	17
4	METODOLOGIA	17
4.1	ÁREA DE ESTUDO	17
4.2	DADOS E PRÉ PROCESSAMENTO	19
4.3	ANÁLISE DE SEPARABILIDADE	19
4.4	TREINAMENTO E CLASSIFICAÇÃO POR SUPPORT VECTOR MACHINES	20
4.5	VALIDAÇÃO (BDQUEIMADAS – AQ30M)	22
4.6	ANÁLISE DE ACURÁCIA	23
4.7	ANÁLISE DE REGRESSÃO POR PROPORÇÃO 5X5 Km	25
5	RESULTADOS	26
5.1	EFEITOS DOS PARÂMETROS DE AJUSTE NAS PRECISÕES DE CLASSIFICAÇÃO	28
5.2	ANÁLISE DE ACURÁCIA TEMÁTICA MODIS E SLSTR	30
5.3	PROPORÇÃO DE ÁREAS QUEIMADAS POR CÉLULAS 5x5 Km	35
6	CONCLUSÕES	37
	REFERÊNCIAS	39

1 INTRODUÇÃO

Entender como a biota responde aos eventos de fogo é de extrema relevância para o manejo e a conservação dos ecossistemas terrestres, especialmente em face das mudanças ambientais globais e do aumento das atividades antrópicas (FRIZZO *et al.* 2011). A queima de vegetação é um processo em escala global que afeta a distribuição dos principais ciclos biogeoquímicos e sistema climático (BOWMAN *et al.* 2009). O aumento na ocorrência e de frequência de secas extremas tem ocasionado o aumento no número de desastres associados a incêndios florestais em todo o planeta (ANDERSON *et al.* 2017). A queima além de alterar a umidade do solo, em função das mudanças na taxa de infiltração e na taxa de transpiração, pode alterar, por consequência o estoque de água no solo (REDIN, *et al.* 2011).

O Cerrado ocupa uma área de 2.036.448 km², cerca de 22% do território nacional, sendo o segundo maior bioma da América do Sul, observado nas regiões do Norte, Nordeste, Sudeste e Centro-Oeste. O Cerrado é o segundo maior bioma do Brasil e uma das savanas mais ricas em espécies do mundo (LEWINSOHN & PRADO, 2005). O Cerrado é formado pelas fisionomias: campo limpo, campo sujo, campo rupestre, cerrado, cerradão, matas secas, ciliares e galeria, e veredas (EMBRAPA, 2021).

Atualmente, o bioma Cerrado está sob a ameaça do aumento da pressão antrópica, o que tem levado à conversão acelerada de ecossistemas naturais em áreas de cultivo, pastagens e desenvolvimento de infraestrutura (ALENCAR *et al.* 2020). Essas mudanças no uso e cobertura da terra resultaram em vários impactos ambientais, incluindo perda e fragmentação de habitats naturais, aumentando o risco de extinção de espécies e afetando o ciclo hidrológico, processos biogeoquímicos e funcionamento do ecossistema (STRASSBURG *et al.* 2017). Os eventos de fogo são um fenômeno comum e determinante na vegetação do Cerrado, que muito contribuiu para a evolução de sua flora (SIMON *et al.* 2009). Essas mudanças no regime de fogo contribuem para aumentar a frequência e intensidade do fogo, afetando a resiliência do ecossistema.

O mapeamento espaço-temporal de áreas afetadas por incêndios pode apoiar a análise para entender melhor a ocorrência e frequência de eventos de incêndio e seus impactos na vegetação e fornecer informações para formuladores de políticas e bombeiros para garantir ações de prevenção / gestão de incêndio

eficientes e organizadas (PIROMAL *et al.* 2008). Nesse contexto, o sensoriamento remoto pode ser útil para monitorar e mapear a ocorrência de incêndios em escalas regionais e globais, com diferentes resoluções espaciais, temporais e espectrais (DALDEGAN *et al.* 2019).

O espectrorradiômetro de imagem de resolução moderada (MODIS) e o O sensor radiômetro de temperatura da superfície do mar e da terra (SLSTR) são alguns sensores de satélites de observação da Terra (EOS) mais comumente usados para detecção, monitoramento e avaliação de incêndios florestais em âmbito regional e escala global (WAIGL *et al.* 2017). A variação das resoluções espaciais e temporais dos sensores EOS é uma questão crítica para a detecção de incêndio. Mais importante ainda, a frequência e o tempo de revisão dos satélites geralmente afetam a eficácia do monitoramento de emergência. Uma solução alternativa prática é combinar vários sensores de diferentes resoluções espaciais e temporais para produzir estimativas rápidas e confiáveis sobre a localização e a extensão dos incêndios florestais em zonas tropicais. A redução do tempo necessário para identificar incêndios florestais pode levar ao aumento da consciência situacional, bem como à tomada de decisão mais rápida pelas equipes de controle de incêndio (CHIANG *et al.* 2019); reduzindo assim o potencial impacto negativo que um surto de incêndio poderia ter em áreas com alta biodiversidade e ecossistemas frágeis (por exemplo, os biomas Cerrado e Amazônia). Esses produtos, no entanto, não são adequados para a identificação de pequenas áreas queimadas devido à sua resolução espacial (GIGLIO *et al.* 2016).

Produtos de área queimada global do sensor de espectrorradiômetro de imagem de resolução moderada (MODIS) a bordo dos satélites Terra e Aqua fornecidos pela National Aeronautics and Space Administration (NASA) foram usados para estimar as emissões globais, com uma resolução espacial grosseira (500 m), com especificação de 15 dias disponíveis para download em todo o mundo (Andela *et al.* (2017), Chen *et al.* (2013), Zhang *et al.* (2016). Esses produtos, no entanto, não são adequados para a identificação de pequenas áreas queimadas devido à sua resolução espacial (GIGLIO *et al.* 2016). Apesar do aumento da frequência e intensidade dos eventos de fogo no bioma Cerrado, os produtos da área queimada e estudos conduzidos usando resolução espacial média e alta são limitados a estimativas locais (Daldegan *et al.* 2019) ou simplesmente a um ano específico (LONG *et al.* 2018). O mapeamento automático para áreas queimadas

usando resoluções espaciais de média e alta, computação em nuvem e dados gratuitos de sensoriamento remoto não está disponível e ainda é um desafio científico.

A validação de produtos de sensoriamento remoto fornece informações críticas para ajudar os usuários a determinar se os dados atendem às suas necessidades e melhorias no algoritmo de benchmark. O Grupo de Trabalho de Satélites de Observação da Terra sobre Calibração e Validação (<https://lpvs.gsfc.nasa.gov/>) define validação como “o processo de avaliar, por meios independentes, a qualidade dos produtos de dados derivados das saídas do sistema. Recomendações para validação de produtos globais de área queimada de resolução grosseira (Hawbaker *et al.* 2020) sugerem a coleta de dados de referência de imagens que: (1) têm maior resolução espacial e resolução espectral suficiente para identificar áreas queimadas, (2) abrangem o período de tempo dos produtos sendo validados e (3) permite o uso de imagens emparelhadas para separar áreas queimadas recentes de áreas queimadas mais antigas e evita confusão com outros tipos de mudança. A validação de produtos de área queimada de resolução grossa global seguindo esses protocolos normalmente usa pares de imagens Landsat para desenvolver dados de referência (PADILLA *et al.* 2017).

Os métodos usados para gerar produtos de área queimada a partir de imagens ópticas de satélite são numerosos e podem ser categorizados de acordo com vários aspectos, como abordagens baseadas em objeto ou pixel, o uso de uma cena pós-incêndio apenas (abordagem monotemporal) ou a integração adicional de dados de pré-incêndio ou séries temporais (abordagem multitemporal) e os algoritmos de classificação aplicados, como o Florestas Aleatórias (PACHECO E SILVA JÚNIOR, 2021), Máquinas de Vetores de Suporte (*Support vector Machine*) Pereira *et al.* (2017), K-ésimo Vizinho mais Próximo (OLIVEIRA, 2019). Mais recentemente, tem havido um grande esforço para automatizar o processo de classificação / mapeamento de alvos específicos usando algoritmos de Deep Learning (Lecun *et al.* 2015), como a *Deep Neural Network* (DNN), que inclui um algoritmo de aprendizagem baseado em uma rede neural artificial.

2 OBJETIVOS

Este estudo teve como objetivo estabelecer uma abordagem metodológica supervisionada para analisar a acurácia temática da detecção de áreas queimadas numa porção territorial do Cerrado, no período seco de 2016 a 2020, a partir de técnicas de aprendizado de Máquinas (*Machine Learning*) e imagens de mesma resolução espacial e diferentes resoluções espectrais dos Satélites Terra/MODIS e Sentinel 3/SLRTR), comparadas com produtos de mapeamento de queima oficiais.

2.1 OBJETIVOS ESPECÍFICOS

Os objetivos perseguidos neste trabalho são os seguintes:

- Avaliar a sensibilidade espectral de cada banda dos sensores SLSTR e MODIS na separação de áreas queimadas e não queimadas em cada um dos anos da série temporal de 2016-2020.
- Estimar as principais métricas de análise temática derivadas da matriz de confusão (erros de comissão, omissão e coeficiente de dados).

3 FUNDAMENTAÇÃO TEÓRICA

Nesta seção será apresentada um estado da arte trazendo uma revisão geral, sobre ecossistemas atingidos por incêndios florestais e sua relação com a cartografia e o sensoriamento remoto, os tópicos são: Fogo no Bioma Cerrado, Cartografia e sensoriamento remoto de áreas queimadas.

3.1 FOGO NO BIOMA CERRADO

As savanas brasileiras (ou Cerrado) são ecossistemas altamente inflamáveis com queimadas frequentes, que medeiam o combustível disponível para queimar reduzindo a dominância das árvores e a continuidade do leito de combustível das gramíneas que permitem a propagação do fogo (BUSTAMANTE *et al.* 2012). Nestes ecossistemas, as plantas podem acessar a água armazenada profundamente no solo durante a estação seca e manter a umidade foliar, transpiração e assimilação de carbono. No entanto, o Cerrado passou por mudanças rápidas no uso da terra nas últimas décadas como resultado da limpeza da terra para plantações e pecuária (SANO *et al.* 2010). Essas mudanças promovem uma substituição do ecossistema misto de madeira / grama por pastagens de raiz rasa e, conseqüentemente, uma mudança no ciclo hidrológico que influencia o clima local e a temporada de incêndios (MEYN *et al.* 2007). Por sua vez, na escala nacional no Brasil, onde ocorrem tipos de vegetação contrastantes, podemos esperar diferentes características sazonais na umidade do combustível e, por sua vez, o perigo de incêndio.

Além de concentrar mais da metade de toda a área queimada no Brasil nos últimos vinte anos, o Cerrado teve 41% do seu território atingido pelo fogo nesse período – mais de 825 mil quilômetros quadrados. Essa área corresponde a três estados de São Paulo e dois do Rio de Janeiro, somados. A maior parte desse território correspondia à vegetação nativa local, principalmente à formação savânica, característica da região. Isso faz do Cerrado o bioma brasileiro mais afetado pelo fogo nas últimas duas décadas, seguido da Amazônia e Mata Atlântica. Segundo os pesquisadores, mais da metade da área queimada no Brasil nos últimos vinte anos pegou fogo duas ou mais vezes. Isso significa que nessas áreas, as queimadas não são um fenômeno esporádico. Nesse quesito, o Cerrado também aparece no topo

do ranking e é o bioma com mais recorrência de fogo em uma mesma área. Segundo dados do MapBiomas, uma mesma área de quase 10 quilômetros quadrados pegou fogo todos os anos no Cerrado durante as últimas duas décadas. Apesar dessa alta biodiversidade o bioma Cerrado está na lista dos “hotspots” globais de biodiversidade. Estima-se a extinção de 397 espécies de plantas endêmicas até 2050 em função da perda de habitat pelo desmatamento (STRASSBURG *et al.* 2017).

O desmatamento juntamente com as mudanças climáticas tem aumentado a frequência de fogo. Bustamante *et al.* (2012) avaliando a área de pastos queimados no Cerrado entre os anos 2003-2008 também observaram um aumento significativo na extensão de pastagem queimadas, principalmente no ano de 2007. Além disso, no ano de 2017, as queimadas alcançaram número recorde no Brasil, com 272 mil focos, representando cerca de 46% a mais em relação ao ano anterior (INPE, 2021). Esse aumento na frequência de fogo tem sido associado a reduções da biomassa da vegetação arbórea, aumentos da biomassa de gramíneas e invasão de espécies exóticas. Assim, estudos têm se preocupado com o futuro dessas interações vegetação, fogo e clima (SILVÉRIO *et al.* 2013).

O cenário dos últimos anos se repetiu em 2020: até novembro, o bioma continuou sendo o mais afetado pelos incêndios em relação à área queimada. Ainda em 2020, o Instituto Nacional de Pesquisas Espaciais também identificou mais de 63 mil focos de incêndio na região. Com isso, o Cerrado fica atrás apenas da Amazônia em número de queimadas (INPE, 2021). Apesar de ser o segundo maior bioma da América do Sul, o Cerrado tem a menor porcentagem de áreas sobre proteção integral – apenas 8%, segundo o IBAMA. Uma das preocupações dos pesquisadores é a progressiva perda da biodiversidade local, que está relacionada a duas atividades econômicas comuns no Cerrado: a monocultura intensiva de grãos e, principalmente, a pecuária. Estima-se que 60% da área total do bioma seja destinada somente a essa atividade (IBAMA, 2002).

Diferentes instrumentos e plataformas de sensoriamento remoto tem sido utilizado nas últimas décadas para adquirir imagens para extrair indicadores para monitorar e mapear condições de risco de incêndio. Assim, uma revisão sobre o uso da cartografia e sensoriamento remoto de áreas queimadas tem um papel imprescindível na obtenção de informações operacionais ou potenciais imediatos na gestão espacial, e, portanto, são exploradas na seção seguinte.

3.2 CARTOGRAFIA E SENSORIAMENTO REMOTO DE ÁREAS QUEIMADAS

A análise espacial da paisagem por meio da cartografia é fundamental entender a estrutura, funcionalidade e dinâmica das variáveis bióticas, abióticas e humanas. Essas características fazem com que a cartografia assuma um caráter muito complexo, ao representar e conjugar diferentes tipos de dados e informações com características diversas e uma multiescalaridade peculiar a estes estudos (PEREIRA *et al.* 2015).

A aplicação de imagens de satélite ao mapeamento de áreas queimadas tem uma longa história em estudos de sensoriamento remoto, começando no início dos anos 1970 e 1980 e ainda é um tópico de pesquisa ativo que emprega técnicas avançadas que integram geo-estatística, métodos orientados a objetos e aprendizado de máquina. Durante esse período de mais de quatro décadas, uma ampla gama de técnicas e algoritmos foram desenvolvidos e aplicados no mapeamento de áreas queimadas (CHUVIECO *et al.* 2019). Muitas plataformas e instrumentos de sensores diferentes estão disponíveis para mapear e monitorar remotamente as características do fogo ativo e os efeitos pós-fogo. Em termos de controle remoto detecção das características do fogo ativo e efeitos pós-fogo, é possível dividir os sistemas de sensores disponíveis em passivos ou ativos e, em seguida, em sensores aéreos ou de satélite.

Para os métodos desenvolvidos e aplicados no mapeamento de áreas queimadas, Koutsias *et al.* (1999) propôs um esquema de classificação que identificou três grupos gerais, dependendo primeiro se imagens de satélite multitemporais ou de data única foram empregadas, a segunda saída foi uma estimativa direta de área queimada ou um produto intermediário aprimorado, e terceiro no tipo de métodos de classificação. Além da interpretação digital, os primeiros estudos de área queimada também usaram análise visual, lucrando com a capacidade do intérprete de considerar gradações de cores muito sutis, bem como textura e informações contextuais. Por exemplo, Indratmoko e Rizqihandari (2019) usaram análise visual de imagens Landsat OLI para criar perímetros de referência de fogo para validar a classificação de probabilidade máxima supervisionada de um grande incêndio no Mediterrâneo. A análise visual também foi usada para delinear manchas de fogo a partir de imagens de radar (BELENGUER-PLOMER *et al.* 2021; TANASE *et al.*;2019).

Por fim, o terceiro grupo de estudos refere-se às técnicas de classificação, se foram utilizados métodos supervisionados e não supervisionados. Isso depende do conhecimento prévio dos efeitos do fogo na região alvo. A classificação de máxima verossimilhança e os algoritmos de agrupamento de k-médias foram empregados em vários estudos para mapear diretamente a área queimada ou para avaliar outras técnicas de classificação (CARMO *et al.* 2012). Métodos baseados em regressão logística foram introduzidos para mapear áreas queimadas usando data múltipla Libonati *et al.* (2015) e data única (SILVA JÚNIOR e PACHECO, 2021). A principal consideração ao implementar as classificações de áreas queimadas foi expressar o problema de classificação de uma forma binária, ou seja, pixels queimados versus pixels não queimados. Outras abordagens, como a Análise de Mistura Espectral (SMA), foram aplicadas no mapeamento da área queimada utilizando imagens hiperespectrais (PACHECO e JUAREZ, 2020).


4 METODOLOGIA

Nesta seção será apresentada a área de estudo, dados utilizados e as etapas metodológicas do estudo.

4.1 ÁREA DE ESTUDO

A área de estudo é a extensão da quadrícula Landsat de órbita/ponto (221/66) de aproximadamente 904984 km², integralmente inserida no estado do Piauí e no bioma Cerrado e próxima ao bioma Caatinga (Figura 1).

Figura 1 - Localização da área de estudo no sul do estado do Piauí e ao norte do bioma Cerrado



Fonte: O autor (2021)

O Cerrado é a savana tropical mais rica do mundo, pois nele há cerca de 5% de toda a diversidade do planeta. O Cerrado abriga 30% dos diversos seres vivos identificados no Brasil, onde sua flora é composta por 12.385 espécies de plantas. E 4.400 delas são endêmicas (EMBRAPA, 2021). O Cerrado é o bioma com maior número de incêndios ativos detectados no Brasil, perdendo para o bioma Amazônia. Por exemplo, em 2020, 631821 incêndios foram detectados no Cerrado,

representando aproximadamente 28,16% do total de incêndios ativos observados no Brasil (INPE BDQUEIMADAS, 2021).

A maior parte dos incêndios ativos ocorrem entre junho e novembro, período com menor quantidade de precipitação recebida. Na estação seca, espera-se o aumento do risco de propagação e fuga do fogo, afetando áreas florestais próximas e causando degradação florestal, que é uma fonte importante para o programa REDD + (Redução de Emissões por Desmatamento e Degradação Florestal) uma vez que essas áreas permanecem como áreas florestais, mas com grande perda de ecossistema (INPE BDQUEIMADAS, 2021).

4.2 DADOS E PRÉ-PROCESSAMENTO

Com a finalidade de geração dos mapas temáticos de distribuição espacial da área queimada bem como a avaliação da acurácia temática e sensibilidade espectral ao fogo, foram utilizadas imagens de sensores orbitais de resolução grosseira, tais quais, o (SLSTR) e o (MODIS), a bordo dos satélites Sentinel-3 e Terra respectivamente.

O Radiômetro de Temperatura da Superfície do Mar e da Terra (SLSTR) é um radiômetro de temperatura de varredura dupla na órbita baixa da Terra (800-830 km de altitude) a bordo do satélite Sentinel-3 modo RBT-1B. Ele emprega a técnica de varredura ao longo da faixa de visão dupla (nadir e oblíquo para trás) para 9 canais no espectro infravermelho visível (VIS), térmico (TIR) e de ondas curtas (SWIR) (Tabela 1). As bandas de nível 1B de pré-processamento, inclui o cálculo de medições radiométricas para cada canal SLSTR e vários testes relativos à sinalização de superfície, nuvens, determinação das propriedades dos pixels, posição geográfica, resolução espacial de 500m e período de revisita de 1,9 dias no equador (Sentinel-3 SLSTR User Guide, ESA).

Neste estudo, as imagens do SLSTR foram disponibilizadas através da plataforma *Sentinel Data Hub* (<https://scihub.copernicus.eu/>) para os meses entre setembro e outubro para cada ano de 2016 a 2020 (Tabela 2). Os dados SLSTR no modo (1B-RBT) foram convertidas de radiâncias para refletâncias TOA (Topo da Atmosfera) através do software SNAP 2.0. Devido a problemas ruído encontradas na banda S4 para todos os anos, a mesma foi removida das análises.

Tabela 1 - Características das imagens obtidas pelos sensores MOD09A1 e SLSTR utilizadas neste estudo.

Bandas Espectrais	Resolução Espectral		Resolução Espacial
	MOD09A1	SLSTR	
Azul	459 - 479	-	500 m
Verde	545 - 565	530 - 570	
Vermelho	620 - 670	630 - 670	
Infravermelho Próximo 1	841 - 876	840 - 880	
Infravermelho Próximo 2	1230 - 1250	-	
SWIR1	1628 - 1652	1550 - 1670	
SWIR2	2105 - 2155	2200 - 2300	

Fonte: Adaptado de VERMOTE (2015) e Sentinel-3 SLSTR User Guide, ESA (2013).

Neste estudo, adicionalmente na mesma faixa temporal dos dados SLSTR (Tabela 2), foi utilizada 5 cenas do sensor MODIS, a partir do produto de refletância de superfície (MOD09A1) disponibilizado pelo Centro de Arquivo Ativo Distribuído do Laboratório *Nacional Oak Ridge* (ORNL DAAC) (Ferramenta de Subconjunto Global: *MODIS / VIIRS Land Products*: <https://modis.ornl.gov/cgi-bin/MODIS/global/subset.pl>). Estes dado apresenta resolução espacial de 500 m e fornece reflectância de superfície espectral das bandas MODIS/Terra 1–7 (Tabela 1) corrigidas para as condições atmosféricas (por exemplo, gases, aerossóis e espalhamento de Rayleigh) em intervalos de oito dias. Os critérios para escolher o pixel incluem nuvem e zênite solar. Quando várias aquisições atendem aos critérios, o pixel com o valor mínimo do canal 3 (azul) é usado (VERMOTE, 2015).

Tabela 2 – Datas das imagens SLSTR e MODIS e os dados Aq30m.

SLSTR	MODIS	Aq30m
26-10-2016	30-10-2016	26-10-2016
23-10-2017	31-10-2017	27-09-2017
16-09-2018	21-09-2018	22-09-2018
16-09-2019	15-10-2019	17-09-2019
21-10-2020	15-10-2020	21-10-2020

Fonte: O autor (2021)

4.3 ANÁLISE DE SEPARABILIDADE

Índices de separabilidade estatística são medidas estatísticas com a finalidade para quantificar a separabilidade das classes de pertinência e não pertinência sob diferentes bandas ou índices espectrais (JENSEN, 1996).

Várias estatísticas de separabilidade são utilizadas em sensoriamento remoto, por exemplo, o Jeffries-Matusita (JM), e Transformed Divergence Index

(TD). Neste estudo, foi utilizado a estatística de separabilidade (TD), onde numa escala de 0 a 2 particularmente, o maior valor, traz a informação de alta dissimilaridade entre as classes de queimado e não queimado e um valor abaixo de 1, baixa correspondência espectral entre as classes. A Transformed Divergence Index (TD) é uma forma comumente usada de medida de separabilidade projetada para prever as melhores combinações de canais para classificação multiespectral de características terrestres (HUANG *et al.* 2016). Esta estatística de separabilidade usa uma transformação saturante para reduzir a dimensionalidade dos conjuntos de dados e fornecer informações sobre o grau relativo em que as áreas queimadas podem ser classificadas com precisão perante as bandas espectrais dos sensores SLSTR e MODIS.

Ele também fornece uma visão sobre quais canais podem ser usados para obter os melhores resultados de classificação baseada na distância de covariância ponderada entre as médias de classe para determinar se as assinaturas de classe são separáveis (Li *et al.* 2016), através da equação 1:

$$TD = 2 \left[1 - \exp \left(-\frac{D}{8} \right) \right],$$

$$D = \frac{1}{2} \text{tr}[(C_1 - C_2)(C_1^{-1} - C_2^{-1})] + \frac{1}{2} \text{tr}[(C_1^{-1} - C_2^{-1})(\mu_1 - \mu_2)(\mu_1 - \mu_2)^T] \quad 1)$$


Onde TD é a divergência transformada entre a classe 1 e a classe 2, C1 é a matriz de covariância da classe 1, μ_1 é o vetor médio da classe 1, tr é a função de traço da matriz e T é a função de transposição da matriz. O cálculo de separabilidade foi realizado no software RStudio Desktop 1.4.1717 através do pacote 'spatialEco' (EVANS *et al.* 2021).

4.4 TREINAMENTO E CLASSIFICAÇÃO POR SUPPORT VECTOR MACHINE (SVM)

Os SVM são baseados na teoria de aprendizagem estatística e tem o objetivo de determinar a localização dos limites de decisão que produzem a separação ótima de classes (VAPNIK, 1995). No caso de um problema de reconhecimento de padrões de duas classes em que as classes são linearmente separáveis, o SVM seleciona entre o número infinito de limites de decisão linear

aquele que minimiza o erro de generalização. Assim, o limite de decisão selecionado será aquele que deixa a maior margem entre as duas classes, onde a margem representa a distância entre o hiperplano e os vetores de suporte. A análise SVM tenta posicionar a margem de forma que o espaço entre ela e os vetores de suporte sejam maximizados. A Figura 2 mostra uma visão geral simplificada do processo SVM (VAPNIK, 1995).

Figura 2 - O hiperplano ideal (linha vermelha) é aquele com a maior margem de separação entre as duas classes ou grupos. Os símbolos na margem (vazados) são os vetores de suporte. Durante a fase de treinamento, o SVM encontra o hiperplano ou limite de decisão ideal. Durante a fase de teste, o limite de decisão pode ser aplicado para classificar novos exemplos (figuras não vazadas). O hiperplano ideal é descrito por um vetor de peso e um deslocamento.



Fonte: O autor (2021)

Os pontos de dados mais próximos do hiperplano são usados para medir a margem; portanto, esses pontos de dados são denominados 'vetores de suporte' (VAPNIK, 1995). Se as duas classes não forem linearmente separáveis, o SVM tenta encontrar o hiperplano que maximize a margem e, ao mesmo tempo, minimize uma quantidade proporcional ao número de erros de classificação (PAL E MATHER, 2005). No geral, o SVM trabalha considerando cada pixel como vetor em um sistema multidimensional, onde cada classe possui um pixel como vetor de suporte para estabelecer o limite da classe.

Quando os dados não se adequam a um hiperplano óbvio é preciso mudar o ponto de vista para um espaço dimensional superior. Dessa forma, o SVM permite que os usuários escolham uma função do kernel que melhor se adapte aos dados

com os quais estão trabalhando. Em estudos de classificação de áreas queimadas, de acordo com (Dragozi *et al.* 2014) e (Pereira *et al.* 2017), o kernel da Função de Base Radial (RBF) do classificador SVM é comumente usados e apresenta um bom desempenho. Portanto, neste estudo, foi utilizado o kernel RBF para implementar o algoritmo SVM, embora exista dois parâmetros que precisam ser configurados ao aplicar o classificador SVM com kernel RBF: os parâmetros ótimos de custo (C) e o parâmetro de largura do kernel (γ) também chamado de “gamma” (SHEYKHMUSA *et al.* 2020). O parâmetro C decide o tamanho do erro de classificação permitido para dados de treinamento não separáveis, o que torna possível o ajuste da rigidez dos dados de treinamento. O parâmetro de largura do kernel (γ) afeta a suavização da forma do hiperplano de divisão de classes (HOSSEINI *et al.* 2021). Valores maiores de C podem levar a um modelo de sobreajuste, enquanto o aumento do valor de γ afetará a forma do hiperplano de divisão de classes, o que pode afetar os resultados de precisão da classificação (NOI E KAPPAS, 2015).

Para realizar a classificação, é necessária uma etapa de treinamento para permitir que o classificador aprenda o processo por meio de exemplos que indicam a correspondência entre uma amostra de treinamento e uma classe (MARTINS *et al.* 2016). Seguindo o estudo de (Li *et al.* 2014) e (Noi e Kappas, 2018) para encontrar os parâmetros ideais para SVM, cinco valores de C (1, 5, 10, 50, 100), e quatro valores de γ (0.1, 1, 5, 10), foram testados. A melhor combinação C e γ pré-estabelecido, será avaliado com número de iterações 1 a 1000, e por fim, será realizado a classificação SVM para todo o conjunto de dados MODIS e SLSTR, utilizando os melhores valores dos hiperparâmetros treinados. A seleção das amostras de treinamento foi realizada no software QGIS 3.10 (QGIS, 2021). Os testes de hiperparâmetros e classificação foi realizado no software RStudio Desktop 1.4.1717 através do pacote ‘e1071’ (MEYER, 2021).

4.5 VALIDAÇÃO (BDQUEIMADAS - AQ30M)

A validação dos dados de sensoriamento remoto geralmente é baseada em medições obtidas em campanhas de campo, que são vistas como referência no local. Em muitos casos, o processo de validação é realizado por produtos de sensoriamento remoto fornecidos por instituições oficiais ou por sensores com alta resolução espectral e espacial.

Neste trabalho, o produto de validação de referência foi a área queimada anual nos anos de 2016 a 2020 da base de dados disponibilizado pelo Instituto Nacional de Pesquisas Espaciais (INPE) por meio do Banco de dados de queimadas do INPE (BDQueimadas - Aq30m) disponível em (<http://queimadas.dgi.inpe.br/queimadas/aq30m/>). Os dados foram disponibilizados em formato de polígonos vetoriais cobrindo integralmente a área de estudo.

Este monitoramento utiliza imagens da série Landsat com 30 m de resolução espacial, onde 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.

O período das imagens utilizadas MODIS, SLSTR em conformidade com os dados (Aq30m) foi cuidadosamente escolhido sendo mais curto possível, como mostra a tabela 2, já que este parâmetro depende do ciclo de imageamento dos satélites, evitando possíveis inconsistências espaciais devido a mudanças na cicatriz queimada, cobertura da terra. Porém, problemas com nuvens foi a principal causa para intervalos temporais diferentes do recomendado pela literatura (Libonati *et al.* 2015) de 29 dias.

4.6 ANÁLISE DE ACURÁCIA

A qualidade de um dado mapa temático que é derivado de dados de sensoriamento remoto é geralmente avaliada por 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 matrizes de confusão (STORY E CONGALTON, 1986). A abordagem de tabulação cruzada é a forma mais comum de avaliar a precisão temática. Neste contexto, foi realizada a comparação e análise da qualidade dos mapas de áreas queimadas obtidos pelas imagens SLSTR e MODIS nos anos de 2016 a 2020.

O polígono da área queimada obtido pelo mapa do BDQueimadas foi utilizado como referência espacial neste estudo. A análise baseada em pixels foi baseada em uma matriz de confusão (Quadro 1). Seguindo a terminologia apresentada por (Fawcett *et al.* 2014), os dados de referência (classe verdadeira) serão referidos como positivos ou negativos (queimados ou não queimados). Se a instância for positiva (queimada) e classificada como positiva (queimada), será

contada como verdadeiro positivo (a); se for classificado como negativo (não queimado), será contado como falso positivo (b). Por outro lado, se a instância for negativa (não queimada) e for classificada como negativa (não queimada), será contada como verdadeiro negativo (d); se for classificado como positivo (queimado), será contado como falso negativo (c) (Quadro 1).

Quadro 1 – Matriz de confusão entre o produto de referência e as áreas classificadas queimadas / não queimada.

		Referência		
		Queimado	Não Queimado	
Mapeado	Queimado	a	b	a + b
	Não Queimado	c	d	c + d
		a + c	b + d	a + b + c + d

Fonte: Adaptado (LIBONATI *et al.* 2015)

As métricas usadas para avaliar a precisão do produto foram os Erros de Comissão (EC) e o Erro de Omissão (EO) e o Coeficiente de Dados (DC) (DICE, 1945).

O erro de omissão (EO), definido como a fração de pixels queimados no mapa de referência que não foram classificados como tal no mapa classificado (equação 2).

$$EO = \frac{c}{a + c} \quad (2)$$

O erro de comissão (EC), definido como a fração de pixels classificados como queimados no mapa classificado, mas na verdade são pixels não queimados no mapa de referência (equação 3).

$$CE = \frac{b}{a + b} \quad (3)$$

O Coeficiente de Dados (DC) que é uma medida de similaridade entre o classificador e o mapa de referência em termos do número de pixels queimados comuns (equação 4).

$$DC = \frac{2}{2 + \frac{EO}{1-EO} + \frac{EC}{1-EC}} \quad (4)$$

O DC mede a semelhança entre os dois conjuntos de dados; a quanto maior seu valor, maior será a precisão da categoria queimada. O EC refere-se à área queimada mapeada pelo classificador, mas não classificada como queimada nos dados de referência, e EO à área queimada nos dados de referência não mapeados pelo classificador (LIZUNDIA-LOIOLA *et al.* 2021). O EO e EC fornecem informações sobre a confiabilidade e o poder de discriminação do classificador desenvolvido. Para estas estatísticas, uma classificação incoerente exibe um valor de tendência igual a 0%, enquanto uma tendência maior (chegando a 100%) indica que os eventos foram bem classificados. Variando entre 0 e 1, DC mede a fração de sobreposição de pixels classificados como queimados para aqueles realmente queimados no mapa de referência (LIBONATI *et al.* 2015).


4.7 ANÁLISE DE REGRESSÃO POR PROPORÇÃO 5km x 5km

Um certo grau de erro de omissão e comissão é devido apenas à presença de pixels mistos (Boschetti *et al.* 2004), e a matriz de confusão não faz distinção entre esses erros inevitáveis e erros devido a erros de classificação (GIGLIO *et al.* 2018). Por esse motivo, a matriz de confusão e as métricas de precisão derivadas foram complementadas por uma avaliação de precisão de escala regional com base em métricas de regressão. A proporção de células de grade de resolução de 5 km detectadas como queimadas pelos produtos MODIS e SLSTR é comparada à proporção de área detectada pelos dados de referência; a inclinação e o deslocamento da linha de regressão são uma indicação da acurácia da detecção da área queimada, enquanto o coeficiente de determinação (r^2) é uma indicação da precisão (GIGLIO *et al.* 2018).

5 RESULTADOS

Inicialmente avalia-se a separação entre áreas queimadas e não queimadas em diferentes bandas do MODIS e SLSTR conforme mostrado na Figura 3. Observa-se que diferentes bandas têm diferentes desempenhos de separabilidade

Figura 3 - Valores de separabilidade para as bandas MODIS e SLSTR utilizadas.



Fonte: O autor (2021)

Observar-se que para as bandas do visível, houve menor poder discriminatório, com estimativas de separabilidade abaixo de 1 (exceto para banda do vermelho do MODIS), embora para a banda do verde do SLSTR, as estimativas de separabilidade foram um pouco maiores.

Já o infravermelho próximo, como esperado, apresentou alta estimativa de separabilidade em ambos os sensores, com valores acima de 1,5, inclusive na banda IVP2 do MODIS. O alto poder discriminatório do infravermelho próximo é consistente com os estudos de Veraverbeke *et al.* (2011), Smith *et al.* (2007), Pereira (2009) e (PACHECO *et al.* 2021). Esta região espectral tem sido amplamente considerada como a melhor região para detectar e mapear áreas queimadas (Schepers *et al.* 2014), já que esta faixa é fortemente refletida pela remoção ou queima da vegetação, o que implica numa queda significativa da refletância. Dessa forma, os valores de separabilidade apresentados na figura 3, eram esperados para ambos os sensores, uma vez que no infravermelho próximo,

tanto numericamente quanto visualmente, apresenta um padrão abrupto na vegetação pós incêndio. Resumidamente, a refletância de superfícies queimadas é o resultado de uma mistura de solo exposto, vegetação não queimada, cinzas, e carvão que estão presentes na superfície após um incêndio. No infravermelho próximo, a combustão da vegetação influencia significativamente a assinatura espectral pós-incêndio, geralmente diminuindo a refletância, aumentando assim a diferença em relação às condições não queimadas (SILVA JUNIOR e PACHECO, 2021).


Para o MODIS, na faixa do SWIR, apresentou maior desempenho de separabilidade em relação ao SLSTR e as bandas do visível, potencializando assim, a sua capacidade em detectar áreas queimadas, embora as estimativas terem se concentrado para valores abaixo de 1,2. No geral, a refletância no SWIR1 diminui após a queima, devido à remoção da vegetação retentora de água pelo fogo (TANASE et al. 2020). Para bandas de comprimento de onda mais longas (isto é, SWIR2), a refletância espectral de vegetação seca não queimada (proporção da vegetação verde absorvendo radiação devido ao conteúdo de água) e superfícies queimadas podem ser igualmente altas, aumentando a estimativa de separabilidade (valores altos de TD). O poder de separabilidade de bandas de onda SWIR no algoritmo de detecção de mudança temporal também foi amplamente explorado como um indicador de gravidade de queima, embora a sensibilidade dessas bandas tenha sido encontrada para variar geograficamente (ROY et al. 2005).

Em relação as bandas do visível, conforme declarado na literatura, Elhag et al. (2020), Tanase et al. (2020), Libonati et al. (2015) e Schepers et al. (2014), os comprimentos de onda do visível tem um desempenho muito baixo na distinção entre áreas queimadas e não queimadas. Diferenças no desempenho de separabilidade entre incêndios florestais foram observadas por (Lasaponara, 2006 e PACHECO et al. 2020). Lasaponara (2006), sugere que essas observações podem ser devido aos diferentes tipos de cobertura da terra afetados pelo fogo.

5.1 EFEITOS DOS PARÂMETROS DE AJUSTE NAS PRECISÕES DE CLASSIFICAÇÃO

Os resultados do teste para encontrar os melhores parâmetros do classificador SVM de combinação C e γ da função RBF, bem como o número de interações em relação ao erro quadrático, no processo de pré-classificação da área queimada, são mostrados nas figuras 4 e 5. Este tipo de análise de ajustamento do modelo de classificação é importante pois permite conhecer e alterar simultaneamente a flexibilidade dos limites de classificação do modelo SVM.

Figura 4 - Relação entre a acurácia com os parâmetros (C e γ) do classificador SVM obtido do subconjuntos de dados de amostras de treinamento



Fonte: O autor (2021)

Os resultados obtidos na figura 4 mostram que a acurácia é fracamente influenciada pela variável C e muito sensível ao parâmetro γ . Pois, como pode ser visto, com a diminuição do γ (aumento da complexidade) a precisão do treinamento aumenta monotonamente até 100%, ou seja, até a modelo de precisão perfeita.


Considerando as dependências apresentadas na figura 4, pode-se supor que a seleção de valores adequados e ótimos dos coeficientes γ e C consiste nas quais a acurácia de validação é a mais alta com o modelo de treinamento o mais eficaz possível. Nesse caso, entre as configurações de maior acurácia de aprendizado, o melhor valor de acerto foi obtido para o parâmetro γ igual a 0,1

e parâmetro C igual a 5, portanto esses valores dos parâmetros foram considerados ótimos e foram utilizados como parâmetros de entrada no processo de classificação.

Dessa forma, o comportamento do conjunto de dados demonstrado entra em conformidade com a teoria Mountrakis e Ogole (2011), Bahari; Ahmad; Aboobaider, (2014), um gamma muito grande, o raio da área de influência dos vetores de suporte inclui apenas o próprio vetor de suporte e nenhuma regularização com C, será capaz de evitar o sobreajuste. Isso produz limites mais segmentados que são mais estreitos em torno dos vetores de suporte; o preditor é, portanto, mais provável de se ajustar a todos eles.

Em seguida, foi ajustado as métricas de avaliações finais do modelo iterativamente de 1 a 1000 vezes.

Figura 5 - Relação entre o RMSE e o número de iterações para os parâmetros para (C e γ) pré estabelecidos do classificador SVM obtido de diferentes subconjuntos de dados de amostra de treinamento




Fonte: O autor (2021)

A figura 5 mostra claramente que o maior número de iteração resultou nas menores estimativas de erro para ambos os conjuntos de dados, dessa forma, mais iterações abrange um espaço de busca mais amplo e reduzirão as chances de sobreajuste, embora cause um aumento no tempo de execução. Diante disso, foi escolhido um número de iterações em que há baixa variação ou estabilização do de erro do treinamento, e como mostra a figura 5, 1000 iterações adequaram-se aos dados, onde não há melhora no desempenho do algoritmo após este número.

5.2 ANÁLISE DE ACURÁCIA TEMÁTICA MODIS E SLSTR

Após a classificação SVM e a comparação com os dados de referência, a Figura 6 mostra a distribuição espacial do EO e EC para a classificação de áreas queimadas e não queimadas dos sensores SLSTR e MODIS.

Figura 6 - Distribuição espacial dos erros de omissão e comissão para os mapas de área queimada gerados pelo classificador SVM nas imagens SLSTR e MODIS



Fonte: O autor (2021)

Observa-se na figura 6 que o MODIS obteve melhores erros de comissão e omissão do que o SLSTR. Para o MODIS a maior estimativa de erro de comissão foi encontrada para o ano de 2019 (56%), chegando a 568,6 Km² de área incorretamente classificada como queimado, enquanto para 2018, que apresentou a menor estimativa (15%) com superestimação de 92,2Km². Para o SLSR os maiores erros de comissão também foram encontrados os anos de 2019 (72%) embora o ano

de 2017 apresentou um valor ligeiramente próximo (71%). Diante disso, ambas superestimaram aproximadamente 885Km² de área queimada. Em discordância com o sensor MODIS, em 2016, o S3 apresentou o menor erro de comissão para este ano (41%) com área erroneamente mapeadas de 400,4Km².

Os erros de omissão se sobressaíram aos erros de comissão, o que já era esperado, já que os dados de referência foram datados no mesmo dia e após a detecção MODIS e SLTR, e além das a resolução espacial mais fina (30m), onde áreas queimadas menores de 5ha, não foram detectadas pelos sensores de resolução mais grossa (500m). Os mapas gerados pelo sensor SLSTR apresentaram os maiores erros de omissão chegando a valores acima de 80%, para os anos de 2016 e 2020, com aproximadamente 2872,60 Km² de áreas sem a sua correta atribuição de temática. O MODIS apresentou valores ligeiramente menores de erro de omissão em relação ao SLSTR, com destaque para o ano de 2016 (51%), embora tenha apresentado um aumento significativo no ano de 2018 (75%) chegando a 1554,63Km² de subestimação.

Esses resultados contrastam das análises utilizando imagens de resolução mais fina. Na literatura, Pulvirenti *et al.* (2020) propôs um algoritmo automatizado baseado em índices espectrais para dados Sentinel-2 sobre áreas florestais e obteve um erro médio de comissão de 6,3% e erro de omissão de 12,7%. Da mesma forma, Smiraglia *et al.* (2020) obteve erro de comissão = 33% e erro de omissão = 24% ao explorar também os índices espectrais. Além disso, Seydi *et al.* (2021) mapearam áreas queimadas com um algoritmo de floresta aleatório (provou ser o algoritmo que fornece maior precisão) com EC = 8,7% e EO = 9,2%. Embora estudos utilizando imagens de resolução grosseira apresentem resultados semelhantes. Libonati *et al.* (2015) através de um modelo automático de classificação utilizando imagens MODIS no Cerrado, obteve erro de aproximadamente EC= 80% e erro de omissão = 30%, enquanto Ramo *et al.* (2021) na vegetação esparsa pós incêndio obteve EC= 99,2% e EO= 95,5%. Santana *et al.* (2020) utilizando imagens MODIS e seus produtos derivados em todos os biomas brasileiros, encontrou um EC de 42.01%, EO de 78.03%. Já Pacheco e Silva Júnior (2020) no estado do Maranhão, obtiveram valores de omissão e comissão de aproximadamente 80%. A tabela 4 mostra os valores de Coeficiente de Dados.

Os erros encontrados na classificação das áreas queimadas foram causados por diversos fatores, sendo um deles a semelhança espectral das áreas queimadas

com outros elementos da superfície, principalmente corpos escuros. Este problema se potencializa quando se leva em consideração os diferentes números de bandas entre o SLSTR e o MODIS. Isso ficou bastante evidente na classificação com imagens SLSTR, uma vez que, para este sensor, apenas cinco bandas (verde, vermelha, infravermelho próximo e de ondas curtas) foram utilizadas na classificação, ou seja, menos recursos para detecção de feições, o que também favoreceu o aumento de pixels de alarmes falsos e superestimações em relação ao MODIS, levando em consideração os resultados encontrados. As cenas MOD09A1 disponibilizam a banda do azul e dois intervalos de comprimento de onda presentes no infravermelho próximo, onde provavelmente influenciaram a presença de menor erro de comissão em relação ao SLSTR. Como dito anteriormente, a o infravermelho próximo é amplamente conhecido devido a sua característica de refletir em fortemente o sinal espectral detecção de mudança na vegetação e a deposição de carvão, além de possuírem alta separabilidade entre áreas queimadas e não queimadas como mostrado na Figura 6.

A precisão espacial das imagens MODIS e SLSTR foi um agente importante na redução do desempenho dos dados, quando comparado com imagens de resolução mais fina (Landsat). Os erros de omissão, sendo representado por pixels erroneamente classificados como áreas não queimadas, apresentou valores significativos e bem distribuídos para os mapas gerados em ambos os sensores.

Feições de incêndio com área menor que 5ha mapeadas pelas imagens Landsat, foram identificados como uma das variáveis para a discrepância espacial na comparação entre 30m com 500m. Áreas não queimadas dentro de um polígono de incêndio são comuns e podem alterar significativamente a refletância diferencial na resolução de 500m, de modo que pequenos fragmentos não queimados na resolução de 30 m, inseridos na área queimada, podem ser considerados como queimados na resolução de 500 m, resultando em erros de estimativa maiores.

O mesmo comportamento acontece em pixels isolados de áreas queimadas do produto de referência, pois um tamanho do pixel muito grande, pode haver subestimação de área queimada decetadas em pixels de resolução mais fina, uma vez que podem ser atenuadas pela cobertura do solo no inserida na grade de 25 ha (para o caso do MODIS e SLSTR).

Os resultados encontrados neste trabalho confirmam as descobertas de estudos anteriores no bioma Cerrado sobre a subestimação das áreas queimadas

do sensoriamento remoto global devido à omissão de pequenos incêndios frequentemente encontrada, principalmente, próximas a áreas agrícolas.

Tabela 4 - Valores de Coeficiente de Dados (DC) após validação dos mapas de área queimadas MODIS e SLSTR

Período	MODIS	SLSTR
2016	0,43	0,22
2017	0,41	0,29
2018	0,38	0,33
2019	0,43	0,3
2020	0,56	0,26

Fonte: O autor (2021)

O coeficiente de dados apresentou valores concordantes aos erros, com as menores estimativas para o sensor SLSTR, embora é importante observar, que o MODIS também apresentou baixas estimativas, com um pequeno aumento para o ano de 2016 (0,61) em total disparidade com o mesmo ano para o sensor SLSTR, que apresentou a menor estimativa do conjunto de dados (0,22). No geral, o MODIS obteve um DC médio de 0,48 e o SLSTR de 0,28.

A variabilidade temporal entre o imageamento da queima entre o SLSTR, MODIS e os dados de referência, também podem causar erros significativos de omissão e comissão, uma vez que a vegetação do bioma Cerrado possui uma alta capacidade de regeneração pós fogo e consequentemente menor sinal espectral da vegetação queimada é recebida pelo sensor, quando o imageamento ocorre após muitos dias do início da queima. Ou seja, cicatrizes de queimaduras de menor intensidade são provavelmente devido a queimaduras para as quais a vegetação se recuperou rapidamente em poucos meses. Resumidamente, o sinal espectral resultante do escurecimento da superfície devido à deposição de carvão vegetal é uma consequência bastante específica da queima da vegetação. No entanto, tem vida relativamente curta. É atenuado pela dispersão do vento, ou lavado pela chuva, em um período de algumas semanas a alguns meses após o incêndio.

Além disso, a baixa resolução espacial das imagens geradas pelos sensores SLSTR e MODIS tende a perder incêndios que têm uma recuperação rápida da vegetação, além de problemas de mistura espectral comumente encontrada nas bordas das cicatrizes, portanto, os eventos de recuperação rápida correspondem à principal fonte de erros de omissão em imagens Landsat. Isto é verdadeiro quando se compara as datas de imageamento (tabela 2) e a distribuição espacial dos erros


de omissão e comissão (figura 3) embora algumas disparidades singulares são importantes salientar. A primeira delas é para o ano de 2016, que apesar do mesmo dia da gravação da cena para o SLSTR e o Landsat, houve maior estimativa de erro de comissão e omissão em comparação a cena MODIS, que por sua vez, foi gravado 4 dias após a data do produto de validação. O mesmo comportamento também aconteceu para os de 2020. Já em 2017, para ambos os sensores, os altos erros de omissão e comissão podem ser justificados pela descontinuidade temporal com os dados Landsat, onde houve disparidade de aproximadamente (26~34) dias após a queima detectada pelo Aq30m. Ou seja, a área queimada detectada pelo SLSTR e o MODIS pode não ter sido detectada pelos dados Landsat, acarretando detecções superestimadas e omitidas. A baixa estimativa de erro de comissão encontrada para o ano de 2018 para o sensor MODIS, pode estar atrelada a diferença de 1 dia após a queima gravada pelo Landsat, ou seja, menor números de pixels superestimados, porém o alto valor de omissão pode ser atribuído a menor resolução espacial, principalmente encontrada em pequenos incêndios. Já em 2019, houve um comportamento incomum, mesmo com a proximidade temporal, os dados SLSTR apresentados altas estimativas de erro de omissão e comissão em relação ao MODIS, com diferença de 28 dias. Este comportamento pode estar relacionado a condições atmosféricas como (sombras, nuvens cirros, aerossóis), que interferiram na visibilidade e detecção da área queimada no mosaico SLSTR, diferentemente do MODIS, onde provavelmente houve maior persistência espectral do sinal da cicatriz da vegetação, apesar dos produtos serem conhecidos por contaminação atmosférica.

No geral, as classificações apresentam baixas estimativas de coeficiente DC conforme resumido na Tabela 5, ou seja, houve uma aderência descontínua com os dados de referência para a classe de presença de área queimada, já que este parâmetro é bastante sensível a falsos alarmes e pixels ausentes. Os valores encontrados do coeficiente DC permitiu resumir parcialmente a variabilidade anual nos erros de comissão / omissão dos mapas anuais de áreas queimada SLSTR e MODIS. Onde para toda a série de dados, o MODIS obteve um erro de omissão e comissão médio de 60% e 34% e o SLSTR de 60% e 76% respectivamente.

5.3 PROPORÇÃO DE ÁREAS QUEIMADAS POR CÉLULAS 5x5 Km

Considerando os coeficientes de determinação das linhas de regressão estimadas, é possível observar as maiores forças de relacionamento foi vista para o MODIS em relação ao SLSTR, com destaque para os anos de 2016 e 2019, ambas com precisão de ($r^2 = 0,49$). Isso mostra maior adequação espacial do MODIS com os dados de referência, principalmente para cicatrizes maiores e mais densas ($>25 \text{ km}^2$) compensando os erros de omissão e comissão.

Figura 7 - Regressões da proporção de área queimada em cada grade quadrada de 5 x 5 km dos mapas gerados pelos sensores MODIS e SLSTR e o mapa de referência derivado do Aq30m durante a temporada de incêndios de 2016 a 2020. Todas as regressões lineares foram significativas para $p < 0,05$, teste t de Student)



Fonte: O autor (2021)

Para o SLSTR, as precisões ficaram concentradas entre 0,3~0,39, o maior coeficiente de determinação foi encontrado para o ano de 2017 ($r^2 = 0,39$), em conformidade com as menores estimativas de EC e EO mostradas na Figura 6.

As inclinações das linhas de regressão são semelhantes em ambos os sensores. Embora para o MODIS, as inclinações apresentaram-se um pouco maior e

somado as intercepções positivas, indicam que, para o tamanho de células de 5 km², o mapa gerado pelo MODIS mapeia corretamente uma proporção maior da paisagem queimada na área de estudo.

As áreas queimadas detectadas pelo MODIS, aproximadamente 89% das quadrículas apresentaram valores inferiores a 5 km², já para o SLSTR foi de 77%, indicando padrões de área queimada correspondente a pequenas cicatrizes em maior número, e provavelmente acarretando numa diminuição de aderência espacial com os dados Landsat.

6 CONCLUSÕES

Este estudo relaciona a aplicabilidade dos dados Sentinel-3 e Terra para detectar e monitorar a ocorrência dos incêndios florestais no Cerrado bem como a sua distribuição espacial. A metodologia empregada pode ser útil para mapear regiões de vegetação nativa afetadas pelo fogo e os impactos por ela gerados, além de melhorar os métodos de monitoramento dos recursos naturais do Cerrado, podendo estender-se para outros biomas. Neste trabalho foi possível a realizar também a análise de acurácia temática para o levantamento das cicatrizes dos incêndios gerados por dados de Sensoriamento Remoto auxiliando na manutenção de um banco de informações e o controle de qualidade de dados espaciais.

Em suma, foi possível verificar que o classificador SVM (*Support Vector Machines*), caracterizado por sua autoadaptabilidade, ritmo de aprendizado eficiente e o ajuste de requisitos limitados de treinamento conforme a mudança dos hiperparâmetros, apresentou-se bastante confiável no processamento inteligente de dados adquiridos por Sensoriamento Remoto. Consistindo desta forma numa grande motivação e promessa para avanços futuros para classificação de sistemas binários. Ressalta-se, entretanto, que interferências causadas por fumaça e outras condições atmosféricas adicionam uma considerável variabilidade às características espectrais dos pixels queimados. Isto muitas vezes resultam em eventos de queima espúrios se houver presença de sinal de fogo ativo na vizinhança espacial causando confusões no algoritmo.

Considera-se recomendável o uso de imagens MODIS SLSTR para monitoramento em pequenas escalas, onde ambas, podem garantir e melhorar as análises futuras em áreas extensas nos diferentes tipos de Cerrado. Uma vez que a mais de duas décadas de observações, os dados de longa série temporal do MODIS, juntamente com as novas tecnologias e alta resolução temporal fornecidas pelo recente Sentinel-3, podem fornecer uma visão incomparável da história dos incêndios no Brasil. Em relação aos erros encontrados, como já mencionados anteriormente, foram causados pela data produto de validação ligeiramente diferentes aos dados analisados, resolução espacial e diferentes números de bandas, e dessa forma, muitos desses erros podem ser minimizados. Especificamente, uma das formas é o (1) uso de um produto de referência com datas próximas ao evento de queima, (2) a seleção de imagens\produtos orbitais

com especificações técnicas semelhantes aos dados SLSTR e o MODIS (como por exemplo o Fire_CCI e o MCD064A1), (3) técnicas avançadas de pré processamento e fotointerpretação. Para estudos futuros, é interessante o uso e a aprimoração de técnicas para as bandas termais e de saturação de incêndio do SLSTR e o MODIS, que podem potencializar a detecção de áreas queimadas e tornar possível a identificação imediata de fogo ativo.

Este estudo abre a possibilidade da utilização de múltiplos dados de Observação da Terra para avaliar perturbações ambientais, aumentando o leque de possibilidades de implementação desses dados quando, por exemplo, não há cena ou banda específica para um determinado período ou problemas com cobertura de nuvens. Além disso, este trabalho mostrou a sensibilidade da resolução espectral e temporal para a detecção de áreas queimadas quando imagens de mesma resolução espacial são empregadas, com base nos resultados obtidos por parâmetros estatísticos de acurácia temática.

Por fim, a influência do fogo abrange uma ampla gama de escalas temporais e espaciais, bem como as interpretações de fatores causais, por isso, as respostas ecológicas é um desafio tanto para a pesquisa quanto para o manejo. No entanto, classificar as medidas por meio de Processamento Digital de Imagens de Sensoriamento Remoto como características de fogo ativo ou pós-incêndio ainda é desafiador, pois os efeitos do fogo variam temporalmente e com topografia e vegetação, embora múltiplas fontes atuais de dados de sensoriamento remoto continuam a acumular e técnicas cada vez mais sofisticadas estão sendo empregadas. Portanto, as pesquisas permanecem em como inferir as características do fogo ativo e o pós-incêndio para o aperfeiçoamento da detecção de áreas queimadas sob as diferentes especificações e limitações dos dados de sensoriamento remoto.

REFERÊNCIAS

ANDELA, N.; MORTON, D. C.; GIGLIO, L.; CHEN, Y.; WERF, G. R. van Der; KASIBHATLA, P. S.; DEFRIES, R. S.; COLLATZ, G. J.; HANTSON, S.; KLOSTER, S.. A human-driven decline in global burned area. *Science*, [S.L.], v. 356, n. 6345, p. 1356-1362, 29 jun. 2017. **American Association for the Advancement of Science (AAAS)**. <http://dx.doi.org/10.1126/science.aal4108>.

ALENCAR, Ane; SHIMBO, Julia Z.; LENTI, Felipe; MARQUES, Camila Balzani; ZIMBRES, Bárbara; ROSA, Marcos; ARRUDA, Vera; CASTRO, Isabel; RIBEIRO, João Fernandes Márcico; VARELA, Victória. Mapping Three Decades of Changes in the Brazilian Savanna Native Vegetation Using Landsat Data Processed in the Google Earth Engine Platform. **Remote Sensing**, [S.L.], v. 12, n. 6, p. 924, 13 mar. 2020. MDPI AG. <http://dx.doi.org/10.3390/rs12060924>.

ANDERSON, L.O.; Cheek, D.; Aragao, L.E.; Andere, L.; Duarte, B.; Salazar, N.; Lima, A.; Duarte, V.; Arai, E. Development of a Point-based Method for Map Validation and Confidence Interval Estimation: A Case Study of Burned Areas in Amazonia. *J. Remote Sens. GIS* 2017, 06.

BELENGUER-PLOMER, Miguel A.; TANASE, Mihai A.; CHUVIECO, Emilio; BOVOLO, Francesca. CNN-based burned area mapping using radar and optical data. **Remote Sensing Of Environment**, [S.L.], v. 260, p. 112468, jul. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2021.112468>.

BAHARI, Nurul Iman Saiful; AHMAD, Asmala; ABOOBAIDER, Burhanuddin Mohd. Application of support vector machine for classification of multispectral data. *Iop Conference Series: Earth and Environmental Science*, [S.L.], v. 20, p. 012038, 23 jun. 2014. IOP Publishing. <http://dx.doi.org/10.1088/1755-1315/20/1/012038>.

BOWMAN, D.M.J.S.; BALCH, J.K.; ARTAXO, P.; BOND, W.J.; CARLSON, J.M.; COCHRANE, M.A.; D'ANTONIO, C.M.; DEFRIES, R.S.; DOYLE, J.C. & HARRISON, S.P. Fire in the Earth System. *Science*, 324: 481–484, 2009.

BUSTAMANTE, Mercedes M. C.; NOBRE, Carlos A.; SMERALDI, Roberto; AGUIAR, Ana P. D.; BARIONI, Luis G.; FERREIRA, Laerte G.; LONGO, Karla; MAY, Peter; PINTO, Alexandre S.; OMETTO, Jean P. H. B.. Estimating greenhouse gas emissions from cattle raising in Brazil. *Climatic Change*, [S.L.], v. 115, n. 3-4, p. 559-577, 17 maio 2012. **Springer Science and Business Media LLC**. <http://dx.doi.org/10.1007/s10584-012-0443-3>.

CHUVIECO, Emilio; MOUILLLOT, Florent; WERF, Guido R. van Der; MIGUEL, Jesús San; TANASE, Mihai; KOUTSIAS, Nikos; GARCÍA, Mariano; YEBRA, Marta; PADILLA, Marc; GITAS, Ioannis. Historical background and current developments for mapping burned area from satellite Earth observation. **Remote Sensing Of Environment**, [S.L.], v. 225, p. 45-64, maio 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2019.02.013>.

CARMO, Cleber Nascimento do; ALVES, Mariane Branco; HACON, Sandra de Souza. Impact of biomass burning and weather conditions on children's health in a

city of Western Amazon region. **Air Quality, Atmosphere & Health**, [S.L.], v. 6, n. 2, p. 517-525, 10 nov. 2012. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11869-012-0191-6>.

CHEN, Weitao; LI, Xianju; HE, Haixia; WANG, Lizhe. Assessing Different Feature Sets' Effects on Land Cover Classification in Complex Surface-Mined Landscapes by ZiYuan-3 Satellite Imagery. **Remote Sensing**, [S.L.], v. 10, n. 2, p. 23, 23 dez. 2017. MDPI AG. <http://dx.doi.org/10.3390/rs10010023>.

CHEN, Yang; MORTON, Douglas C; JIN, Yufang; COLLATZ, G James; KASIBHATLA, Prasad s; WERF, Guido R van Der; DEFRIES, Ruth s; RANDERSON, James T. Long-term trends and interannual variability of forest, savanna and agricultural fires in South America. **Carbon Management**, [S.L.], v. 4, n. 6, p. 617-638, dez. 2013. Informa UK Limited. <http://dx.doi.org/10.4155/cmt.13.61>

CHIANG, Shou-Hao; ULLOA, Noel Ivan. Mapping and Tracking Forest Burnt Areas in the Indio Maiz Biological Reserve Using Sentinel-3 SLSTR and VIIRS-DNB Imagery. **Sensors**, [S.L.], v. 19, n. 24, p. 5423, 9 dez. 2019. MDPI AG. <http://dx.doi.org/10.3390/s19245423>.

DALDEGAN, Gabriel Antunes; ROBERTS, Dar A.; RIBEIRO, Fernanda de Figueiredo. Spectral mixture analysis in Google Earth Engine to model and delineate fire scars over a large extent and a long time-series in a rainforest-savanna transition zone. **Remote Sensing Of Environment**, [S.L.], v. 232, p. 111340, out. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2019.111340>.

DRAGOZI, Eleni; GITAS, Ioannis; STAVRAKOUDIS, Dimitris; THEOCHARIS, John. Burned Area Mapping Using Support Vector Machines and the FuzCoC Feature Selection Method on VHR IKONOS Imagery. **Remote Sensing**, [S.L.], v. 6, n. 12, p. 12005-12036, 3 dez. 2014. MDPI AG. <http://dx.doi.org/10.3390/rs61212005>.

EMBRAPA. **Embrapa cerrados**. 2. ed. rev. atual. Brasília, DF: Embrapa Informação Tecnológica, 2021. Disponível em: <https://www.embrapa.br/cerrados>

ELHAG, Mohamed; YIMAZ, Nese; BAHRAWI, Jarbou; BOTEVA, Silvena. Evaluation of Optical Remote Sensing Data in Burned Areas Mapping of Thasos Island, Greece. **Earth Systems And Environment**, [S.L.], v. 4, n. 4, p. 813-826, dez. 2020. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s41748-020-00195-1>.

EVANS J.S; Murphy A. M; RAM K. **Package 'spatialEco' (2021)**. Disponível online: <https://cran.r-project.org/web/packages/spatialEco/spatialEco.pdf>

FAWCETT, Stanley E.; WALLER, Matthew A.; MILLER, Jason W.; SCHWIETERMAN, Matthew A.; HAZEN, Benjamin T.; OVERSTREET, Robert E.. A Trail Guide to Publishing Success: tips on writing influential conceptual, qualitative, and survey research. **Journal Of Business Logistics**, [S.L.], v. 35, n. 1, p. 1-16, mar. 2014. Wiley. <http://dx.doi.org/10.1111/jbl.12039>.

FRIZZO, T. I. M.; BONIZÁRIO, C.; BORGES, M. P. & VASCONCELOS, H. L.. Revisão dos efeitos do fogo sobre a fauna de formações savânicas do Brasil. *Oecologia Australis* 15(2): 365-379, 2011.

GIGLIO, Louis; SCHROEDER, Wilfrid; JUSTICE, Christopher O.. The collection 6 MODIS active fire detection algorithm and fire products. **Remote Sensing Of Environment**, [S.L.], v. 178, p. 31-41, jun. 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2016.02.054>.

GITAS, Ioannis Z.; MITRI, George H.; VENTURA, Gemma. Object-based image classification for burned area mapping of Creus Cape, Spain, using NOAA-AVHRR imagery. **Remote Sensing Of Environment**, [S.L.], v. 92, n. 3, p. 409-413, ago. 2004. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2004.06.006>.

HAWBAKER, Todd J.; VANDERHOOF, Melanie K.; SCHMIDT, Gail L.; BEAL, Yen-Ju; PICOTTE, Joshua J.; TAKACS, Joshua D.; FALGOUT, Jeff T.; DWYER, John L.. The Landsat Burned Area algorithm and products for the conterminous United States. **Remote Sensing Of Environment**, [S.L.], v. 244, p. 111801, jul. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2020.111801>.

HOSSEINI, Mehdi; MCNAIRN, Heather; MITCHELL, Scott; ROBERTSON, Laura Dingle; DAVIDSON, Andrew; AHMADIAN, Nima; BHATTACHARYA, Avik; BORG, Erik; CONRAD, Christopher; DABROWSKA-ZIELINSKA, Katarzyna. A Comparison between Support Vector Machine and Water Cloud Model for Estimating Crop Leaf Area Index. **Remote Sensing**, [S.L.], v. 13, n. 7, p. 1348, 1 abr. 2021. MDPI AG. <http://dx.doi.org/10.3390/rs13071348>.

HUANG, Haiyan; ROY, David; BOSCHETTI, Luigi; ZHANG, Hankui; YAN, Lin; KUMAR, Sanath; GOMEZ-DANS, Jose; LI, Jian. Separability Analysis of Sentinel-2A Multi-Spectral Instrument (MSI) Data for Burned Area Discrimination. **Remote Sensing**, [S.L.], v. 8, n. 10, p. 873, 22 out. 2016. MDPI AG. <http://dx.doi.org/10.3390/rs8100873>.

IBAMA – **Roteiro Metodológico de Planejamento: Parque Nacional, Reserva Biológica e Estação Ecológica**. Brasília, 2002. INEA – INSTITUTO ESTADUAL DO AMBIENTE.

INPE. **Banco de Dados de queimadas (2021)**. Disponível em: <http://www.inpe.br/queimadas/bdqueimadas>

INDRATMOKO, Satria; RIZQIHANDARI, Nurrokhmah. Burn Area Detection Using Landsat 8 OLI TIRS. **Iop Conference Series: Earth and Environmental Science**, [S.L.], v. 338, p. 012035, 24 nov. 2019. IOP Publishing. <http://dx.doi.org/10.1088/1755-1315/338/1/012035>.

JENSEN, J.R. (1996) **Introductory Digital Image Processing: A Remote Sensing Perspective**. 2nd Edition, Prentice Hall, Inc., Upper Saddle River, NJ.

KOUTSIAS et al., 1999 N. Koutsias, M. Karteris, A. Fernandez-Palacios, C. Navarro, J. Jurado, R. Navarro, A. Lobo. Burned land mapping at local scale E. Chuvieco

(Ed.), **Remote Sensing of Large Wildfires in the European Mediterranean Basin**, Springer-Verlag, Berlin Heidelberg (1999), pp. 157-187.

LEWINSOHN, Thomas M.; PRADO, Paulo Inacio. How Many Species Are There in Brazil? **Conservation Biology**, [S.L.], v. 19, n. 3, p. 619-624, jun. 2005. Wiley. <http://dx.doi.org/10.1111/j.1523-1739.2005.00680.x>.

LI, Guiying; LU, Dengsheng; MORAN, Emilio; HETRICK, Scott. Land-cover classification in a moist tropical region of Brazil with Landsat Thematic Mapper imagery. **International Journal Of Remote Sensing**, [S.L.], v. 32, n. 23, p. 8207-8230, 9 ago. 2011. Informa UK Limited. <http://dx.doi.org/10.1080/01431161.2010.532831>.

LIBONATI, Renata; DACAMARA, Carlos; SETZER, Alberto; MORELLI, Fabiano; MELCHIORI, Arturo. An Algorithm for Burned Area Detection in the Brazilian Cerrado Using 4 μ m MODIS Imagery. **Remote Sensing**, [S.L.], v. 7, n. 11, p. 15782-15803, 24 nov. 2015. MDPI AG. <http://dx.doi.org/10.3390/rs71115782>.

LONG, Tengfei; ZHANG, Zhaoming; HE, Guojin; JIAO, Weili; TANG, Chao; WU, Bingfang; ZHANG, Xiaomei; WANG, Guizhou; YIN, Ranyu. 30 m Resolution Global Annual Burned Area Mapping Based on Landsat Images and Google Earth Engine. **Remote Sensing**, [S.L.], v. 11, n. 5, p. 489, 27 fev. 2019. MDPI AG. <http://dx.doi.org/10.3390/rs11050489>.

MEYER; Murphy A. M; RAM K. **Package 'e1071' (2021)**. Disponível online: <https://cran.r-project.org/web/packages/e1071/vignettes/svmdoc.pdf>

MIRANDA, Sabrina do Couto de; BUSTAMANTE, Mercedes; PALACE, Michael; HAGEN, Stephen; KELLER, Michael; FERREIRA, Laerte Guimarães. Regional Variations in Biomass Distribution in Brazilian Savanna Woodland. **Biotropica**, [S.L.], v. 46, n. 2, p. 125-138, mar. 2014. Wiley. <http://dx.doi.org/10.1111/btp.12095>.

MEYN, Andrea; WHITE, Peter S.; BUHK, Constanze; JENTSCH, Anke. Environmental drivers of large, infrequent wildfires: the emerging conceptual model. **Progress In Physical Geography: Earth and Environment**, [S.L.], v. 31, n. 3, p. 287-312, jun. 2007. SAGE Publications. <http://dx.doi.org/10.1177/0309133307079365>.

MOUNTRAKIS, Giorgos; IM, Jungho; OGOLE, Caesar. Support vector machines in remote sensing: a review. **Isprs Journal Of Photogrammetry And Remote Sensing**, [S.L.], v. 66, n. 3, p. 247-259, maio 2011. Elsevier BV. <http://dx.doi.org/10.1016/j.isprsjprs.2010.11.001>.

NOOJIPADY, Praveen; MORTON, C Douglas; MACEDO, N Marcia; VICTORIA, C Daniel; HUANG, Chengquan; GIBBS, K Holly; BOLFE, L Edson. Forest carbon emissions from cropland expansion in the Brazilian Cerrado biome. **Environmental Research Letters**, [S.L.], v. 12, n. 2, p. 025004, 1 fev. 2017. IOP Publishing. <http://dx.doi.org/10.1088/1748-9326/aa5986>.

NOI, Phan Thanh; KAPPAS, Martin. Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery. **Sensors**, [S.L.], v. 18, n. 2, p. 18, 22 dez. 2017. MDPI AG. <http://dx.doi.org/10.3390/s18010018>.

OLIVEIRA, Petronio Diego Silva de. **Uso de aprendizagem de máquina e redes neurais convolucionais profundas para a classificação de áreas queimadas em imagens de alta resolução espacial**. 2019. viii, 23 f., il. Dissertação (Mestrado em Geografia)—Universidade de Brasília, Brasília, 2019.

PACHECO, Admilson da Penha; SILVA JUNIOR, Juarez Antonio da. Análise Espaço-Temporal de Áreas de Queimadas no Estado do Maranhão a partir de Imagens MODIS e Classificação Random Forest. *Anuário do Instituto de Geociências*, [S.L.], v. 44, p. 1-12, 4 mar. 2021. Instituto de Geociências - UFRJ. http://dx.doi.org/10.11137/1982-3908_2021_44_36119.

PACHECO, Admilson da Penha; SILVA JUNIOR, Juarez Antonio da; RUIZ-ARMENTEROS, Antonio Miguel; HENRIQUES, Renato Filipe Faria. Assessment of k-Nearest Neighbor and Random Forest Classifiers for Mapping Forest Fire Areas in Central Portugal Using Landsat-8, Sentinel-2, and Terra Imagery. *Remote Sensing*, [S.L.], v. 13, n. 7, p. 1345, 1 abr. 2021. MDPI AG. <http://dx.doi.org/10.3390/rs13071345>.

PAL, M.; MATHER, P. M.. Support vector machines for classification in remote sensing. **International Journal Of Remote Sensing**, [S.L.], v. 26, n. 5, p. 1007-1011, mar. 2005. Informa UK Limited. <http://dx.doi.org/10.1080/01431160512331314083>.

PADILLA, Marc; OLOFSSON, Pontus; STEHMAN, Stephen V.; TANSEY, Kevin; CHUVIECO, Emilio. Stratification and sample allocation for reference burned area data. **Remote Sensing Of Environment**, [S.L.], v. 203, p. 240-255, dez. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2017.06.041>.

PULVIRENTI, Luca; SQUICCIARINO, Giuseppe; FIORI, Elisabetta; FIORUCCI, Paolo; FERRARIS, Luca; NEGRO, Dario; GOLLINI, Andrea; SEVERINO, Massimiliano; PUCA, Silvia. An Automatic Processing Chain for Near Real-Time Mapping of Burned Forest Areas Using Sentinel-2 Data. **Remote Sensing**, [S.L.], v. 12, n. 4, p. 674, 18 fev. 2020. MDPI AG. <http://dx.doi.org/10.3390/rs12040674>.

PEREIRA, Allan; PEREIRA, José; LIBONATI, Renata; OOM, Duarte; SETZER, Alberto; MORELLI, Fabiano; MACHADO-SILVA, Fausto; CARVALHO, Luis de. Burned Area Mapping in the Brazilian Savanna Using a One-Class Support Vector Machine Trained by Active Fires. **Remote Sensing**, [S.L.], v. 9, n. 11, p. 1161, 14 nov. 2017. MDPI AG. <http://dx.doi.org/10.3390/rs9111161>.

PIROMAL, Rodrigo Alexandre Sbravatti; RIVERA-LOMBARDI, Roberto Javier; SHIMABUKURO, Yosio Edemir; FORMAGGIO, Antonio Roberto; KRUG, Thelma. Utilização de dados MODIS para a detecção de queimadas na Amazônia. **Acta Amazonica**, [S.L.], v. 38, n. 1, p. 77-84, 2008. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0044-59672008000100009>.

QGIS.org, 2021. **QGIS Geographic Information System. QGIS Association.**
<http://www.qgis.org>

RAMO, Ruben; ROTETA, Ekhi; BISTINAS, Ioannis; VAN WEES, Dave; BASTARRIKA, Aitor; CHUVIECO, Emilio; WERF, Guido R. van Der. African burned area and fire carbon emissions are strongly impacted by small fires undetected by coarse resolution satellite data. **Proceedings Of The National Academy Of Sciences**, [S.L.], v. 118, n. 9, p. 340-350, 22 fev. 2021. Proceedings of the National Academy of Sciences. <http://dx.doi.org/10.1073/pnas.2011160118>.

REDIN, M; SANTOS, SANTOS, G. F; MIGUEL, P.: DENEGA, L. G. LUPATINI, M.; DONEDA, A.; SOUSA, E. L. Impactos da queima sobre atributos químicos, físicos e biológicos do solo. *Ciência Florestal*, Santa Maria, 21 (2): 381-392, 2011.

ROY, D.P.; JIN, Y.; LEWIS, P.e.; JUSTICE, C.O.. Prototyping a global algorithm for systematic fire-affected area mapping using MODIS time series data. **Remote Sensing Of Environment**, [S.L.], v. 97, n. 2, p. 137-162, jul. 2005. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2005.04.007>.

SANTANA, Nickolas Castro; CARVALHO JÚNIOR, Osmar Abílio de; GOMES, Roberto Arnaldo Trancoso; GUIMARÃES, Renato Fontes. Accuracy and spatiotemporal distribution of fire in the Brazilian biomes from the MODIS burned-area products. **International Journal Of Wildland Fire**, [S.L.], v. 29, n. 10, p. 907, 2020. CSIRO Publishing. <http://dx.doi.org/10.1071/wf19044>.

SIMON, M. F.; GREYER, R.; QUEIROZ, L. P. de; SKEMA, C.; PENNINGTON, R. T.; HUGHES, C. E.. Recent assembly of the Cerrado, a neotropical plant diversity hotspot, by in situ evolution of adaptations to fire. **Proceedings Of The National Academy Of Sciences**, [S.L.], v. 106, n. 48, p. 20359-20364, 16 nov. 2009. Proceedings of the National Academy of Sciences. <http://dx.doi.org/10.1073/pnas.0903410106>.

SCHEPERS, Lennert; HAEST, Birgen; VERAVERBEKE, Sander; SPANHOVE, Toon; BORRE, Jeroen Vanden; GOOSSENS, Rudi. Burned Area Detection and Burn Severity Assessment of a Heathland Fire in Belgium Using Airborne Imaging Spectroscopy (APEX). **Remote Sensing**, [S.L.], v. 6, n. 3, p. 1803-1826, 27 fev. 2014. MDPI AG. <http://dx.doi.org/10.3390/rs6031803>.

SILVÉRIO, Divino V.; BRANDO, Paulo M.; BALCH, Jennifer K.; PUTZ, Francis E.; NEPSTAD, Daniel C.; OLIVEIRA-SANTOS, Claudinei; BUSTAMANTE, Mercedes M. C.. Testing the Amazon savannization hypothesis: fire effects on invasion of a neotropical forest by native cerrado and exotic pasture grasses. **Philosophical Transactions Of The Royal Society B: Biological Sciences**, [S.L.], v. 368, n. 1619, p. 20120427, 5 jun. 2013. The Royal Society. <http://dx.doi.org/10.1098/rstb.2012.0427>.

SENTINEL-3 TEAM. **Sentinel-3 User Handbook** (2013), p. 117

SANO, Edson E.; ROSA, Roberto; BRITO, Jorge L. S.; FERREIRA, Laerte G.. Land cover mapping of the tropical savanna region in Brazil. **Environmental Monitoring**

And Assessment, [S.L.], v. 166, n. 1-4, p. 113-124, 6 jun. 2009. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s10661-009-0988-4>.

SHEYKHMOUSA, Mohammadreza; MAHDIANPARI, Masoud; GHANBARI, Hamid; MOHAMMADIMANESH, Fariba; GHAMISI, Pedram; HOMAYOUNI, Saeid. Support Vector Machine Versus Random Forest for Remote Sensing Image Classification: a meta-analysis and systematic review. **Ieee Journal Of Selected Topics In Applied Earth Observations And Remote Sensing**, [S.L.], v. 13, p. 6308-6325, 2020. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/jstars.2020.3026724>.

STORY, M.; CONGALTON, R.G. Accuracy assessment: A user's perspective. *Photogramm. Eng. Remote Sens.* 1986, 52, 397–399.

TANASE, Mihai A.; VILLARD, Ludovic; PITAR, Diana; APOSTOL, Bogdan; PETRILA, Marius; CHIVULESCU, Serban; LECA, Stefan; BORLAF-MENA, Ignacio; PASCU, Ionut-Silviu; DOBRE, Alexandru-Claudiu. Synthetic aperture radar sensitivity to forest changes: a simulations-based study for the romanian forests. *Science Of The Total Environment*, [S.L.], v. 689, p. 1104-1114, nov. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.scitotenv.2019.06.494>.

VAPNIK, V. (1998). **Statistical learning theory**. New York: Wiley.

VERMOTE, E. (2015). MOD09A1 MODIS/Terra Surface Reflectance 8-Day L3 Global 500m SIN Grid V006 [Data set]. **NASA EOSDIS Land Processes DAAC**. <https://doi.org/10.5067/MODIS/MOD09A1.006>

SEYDI, Seyd Teymoor; AKHOONDZADEH, Mehdi; AMANI, Meisam; MAHDAVI, Sahel. Wildfire Damage Assessment over Australia Using Sentinel-2 Imagery and MODIS Land Cover Product within the Google Earth Engine Cloud Platform. **Remote Sensing**, [S.L.], v. 13, n. 2, p. 220, 10 jan. 2021. MDPI AG. <http://dx.doi.org/10.3390/rs13020220>.

SILVA JUNIOR, Juarez Antonio; PACHECO, Admilson da Penha. Avaliação de incêndio em ambiente de Caatinga a partir de imagens Landsat-8, índice de vegetação realçado e análise por componentes principais. **Ciência Florestal**, [S.L.], v. 31, n. 1, p. 417-439, 15 mar. 2021. Universidade Federal de Santa Maria. <http://dx.doi.org/10.5902/1980509843818>.

SILVA JUNIOR, Juarez Antonio da; PACHECO, Admilson da Penha. 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+. **Anuário do Instituto de Geociências**, [S.L.], v. 43, n. 4, p. 440-450, 18 dez. 2020. Instituto de Geociências - UFRJ. http://dx.doi.org/10.11137/2020_4_440_450.

SMIRAGLIA, Daniela; FILIPPONI, Federico; MANDRONE, Stefania; TORNATO, Antonella; TARAMELLI, Andrea. Agreement Index for Burned Area Mapping: integration of multiple spectral indices using sentinel-2 satellite images. **Remote Sensing**, [S.L.], v. 12, n. 11, p. 1862, 8 jun. 2020. MDPI AG. <http://dx.doi.org/10.3390/rs12111862>.