



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

UNIVERSIDADE DE BRASÍLIA  
PÓS-GRADUAÇÃO EM GEOGRAFIA

**USO DE APRENDIZAGEM DE MÁQUINA E REDES NEURAIS CONVOLUCIONAIS  
PROFUNDAS PARA A CLASSIFICAÇÃO DE ÁREAS QUEIMADAS EM IMAGENS DE ALTA  
RESOLUÇÃO ESPACIAL**

**Petronio Diego Silva de Oliveira**  
Dissertação de Mestrado

Brasília – DF  
Outubro de 2019

UNIVERSIDADE DE BRASÍLIA  
PÓS-GRADUAÇÃO EM GEOGRAFIA

**USO DE APRENDIZAGEM DE MÁQUINA E REDES NEURAS CONVOLUCIONAIS  
PROFUNDAS PARA A CLASSIFICAÇÃO DE ÁREAS QUEIMADAS EM IMAGENS  
DE ALTA RESOLUÇÃO ESPACIAL**

Petronio Diego Silva de Oliveira

Orientador: Osmar Abílio de Carvalho Junior

Dissertação de Mestrado

Brasília – DF  
Outubro de 2019

UNIVERSIDADE DE BRASÍLIA  
PÓS-GRADUAÇÃO EM GEOGRAFIA

**USO DE APRENDIZAGEM DE MÁQUINA E REDES NEURAS CONVOLUCIONAIS  
PROFUNDAS PARA A CLASSIFICAÇÃO DE ÁREAS QUEIMADAS EM IMAGENS  
DE ALTA RESOLUÇÃO ESPACIAL**

Petronio Diego Silva de Oliveira

Dissertação de Mestrado submetida ao Departamento de Geografia da Universidade de Brasília, como parte dos requisitos necessários para a obtenção do Grau de Mestre em Geografia, área de concentração Gestão Ambiental e Territorial, opção Acadêmica.

Aprovado por:

---

**Osmar Abílio de Carvalho Júnior, Doutor (GEA – UnB)  
(Orientador)**

---

**Ruth Elias de Paula Laranja, Doutora (GEA – UnB)  
(Examinadora interna)**

---

**Potira Meirelles Hermuche, Doutora (CDS – UnB)  
(Examinadora externa)**

Brasília – DF, outubro de 2019

## Ficha catalográfica

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 / Petronio Diego Silva de Oliveira; orientador Osmar Abílio de Carvalho Júnior -- Brasília, 2019.  
34 p.

Dissertação de Mestrado -- Programa de Pós-graduação em Geografia –  
Universidade de Brasília, 2019

- |                           |                             |
|---------------------------|-----------------------------|
| 1. Incêndios florestais   | 2. Classificação de imagens |
| 3. Aprendizado de máquina | 4. Aprendizado profundo     |

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação e emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta dissertação de mestrado pode ser reproduzida sem a autorização por escrito do autor.

---

**Petronio Diego Silva de Oliveira**

## **AGRADECIMENTOS**

Agradeço ao meu orientador, Dr. Osmar Abílio de Carvalho Júnior, por estar disposto a ajudar mesmo quando ainda não era meu orientador. Aos professores Dr. Renato Fontes Guimarães pelo apoio conferido ao longo da dissertação e Dr. Roberto Arnaldo Trancoso Gomes, por conduzir com sabedoria temas acadêmicos e administrativos, além da presteza em ajudar, esclarecer, sanar dúvidas e vivência no decorrer do tempo. A todos, obrigado pela amizade.

À Isabella Alves, pela paciência, compreensão, apoio e dedicação ao nosso filho, o que me permitiu concentrar esforços no desenvolvimento e conclusão deste trabalho.

À minha família por sempre incentivar a buscar mais conhecimento e jamais me deixar abater.

Aos amigos do Instituto Brasília Ambiental Airton, Luciano, Elenice, Andrea, Clarine, Alisson, Natanael, Leandro Gregório e tantos outros que, direta ou indiretamente ajudaram, com incentivo, colaboração, compreensão e parceria em diversos momentos dessa caminhada.

Aos amigos do LSIE Hugo, Gabriela, Hermínio, Saiaka, Nathália e Felipe, por compartilhar o dia-a-dia da pesquisa, pelo auxílio mútuo e por tornar os momentos de estudo muito mais agradáveis e descontraídos. Um agradecimento especial ao Felipe, que com espírito de equipe e dedicação à pesquisa, contribuiu ativamente para o desenvolvimento do trabalho em inúmeras oportunidades.

Ao amigo Pablo, que com seu grande conhecimento, potencial inovador e iniciativa em auxiliar e difundir o conhecimento enormemente contribuiu e colaborou para a finalização desse trabalho.

## Resumo

Os incêndios florestais queimam enorme quantidade de áreas em todo o mundo, provocando danos ecológicos, econômicos, sociais e à saúde. O Bioma Cerrado com as peculiaridades de ser uma savana possui relação com incêndios, sendo afetada por esse tipo de ocorrência. O monitoramento desses eventos de fogo favorece a compreensão e entendimento das ocorrências, sendo o sensoriamento remoto ferramenta adequada para obtenção de dados relativos ao fogo em diferentes escalas. O uso de machine learning e deep learning em sensoriamento remoto possui diversas finalidades, sendo a classificação de imagens uma importante componente. Nesse estudo, três algoritmos de machine learning (Support Vector Machine, K-Nearest Neighbors e Random Forest) e a Convolutional Neural Network (CNN) foram testados para a classificação de imagens da frota SkySat da Planet com alta resolução espacial visando à identificação de áreas queimadas. A classificação foi feita por meio de cenas individuais, com coleta de amostras para treinamento e posterior classificação. Os resultados das classificações foram avaliados por meio da exatidão global, coeficiente Kappa e AUROC e confrontados entre si. A CNN obteve os melhores resultados sendo seguida pelo KNN, SVM e RF. Em relação à acurácia, não foi evidenciada grande diferença entre os métodos, sendo necessários novos estudos buscando avaliar diferentes classificações.

**Palavras-chave:** incêndios florestais, classificação de imagens, aprendizado de máquina, aprendizado profundo.

## Abstract

Forest fires burn huge number of areas around the world, causing ecological, economic, social and health damage. The Cerrado Biome with its peculiarities of being a savannah is related to fires, being affected by this type of occurrence. The monitoring of fire events favors the understanding of occurrences, and remote sensing is an adequate tool to obtain fire data at different scales. The use of machine learning and convolutional neural networks in remote sensing have several purposes, and image classification is an important component. In this study, three machine learning algorithms (Support Vector Machine, K-Nearest Neighbors and Random Forest) and a convolutional neural network - CNN were tested for the classification of images from the Planet's SkySat fleet with a high spatial resolution for the identification of burned areas. The classification was made in individual scenes, with sample collection for training and subsequent classification. The results of the classifications were evaluated by global accuracy, Kappa index and AUROC and compared to each other. CNN obtained the best results being followed by KNN, SVM and RF. Regarding accuracy, there was no evidence of great difference between the methods, and further studies are needed to evaluate different classifications.

**Keywords:** wildfires, image classification, machine learning, deep learning

## SUMÁRIO

1. INTRODUÇÃO .....	1
2. ÁREA DE ESTUDO.....	4
3. MATERIAL E MÉTODOS.....	6
4. RESULTADOS E DISCUSSÃO.....	10
5. CONCLUSÃO.....	15
6. REFERÊNCIAS BIBLIOGRÁFICAS.....	16

## LISTA DE FIGURAS

Figura 1: localização da área de estudo. ....	5
Figura 2: fluxo de processamento e classificação das imagens.....	6
Figura 3: comparação entre áreas queimadas obtidas pelas classificações. ....	14

## LISTA DE TABELAS

Tabela 1: data das imagens analisadas .....	7
Tabela 2: índice Kappa e Exatidão Global para KNN, RF e CNN .....	10
Tabela 3: valor de AUROC .....	11
Tabela 4: área classificada como queimada, em hectares .....	13
Tabela 5: compilado da área classificada como queimada, em hectares .....	13

## LISTA DE ABREVIATURAS

<b>OA</b>	Overall Accuracy
<b>AUROC</b>	Area Under Receiver Operator Curve
<b>BAI</b>	Burn Area Index
<b>CART</b>	Classifications and Regression Tree
<b>CNN</b>	Convolutinal Neural Network
<b>DF</b>	Distrito Federal
<b>DL</b>	Deep Learnig
<b>IBGE</b>	Instituto Brasileiro de Geografia e Estatística
<b>IBRAM</b>	Instituto do Meio Ambiente e dos Recursos Hídricos do Distrito Federal
<b>ICMBio</b>	Instituto Chico Mendes de Conservação da Biodiversidade
<b>KNN</b>	K Nearest Neighbors
<b>ML</b>	Machine Learning
<b>NIR</b>	Near Infrared
<b>RF</b>	Random Forest
<b>RGB</b>	Red, Green, Blue
<b>RN</b>	Redes Neurais
<b>ROC</b>	Receiver Operator Curve
<b>SVM</b>	Support Vector Machine
<b>UC</b>	Unidade de Conservação

## 1. INTRODUÇÃO

Os incêndios florestais afetam importante percentual da vegetação mundial (REQUIA *et al.*, 2019) e queimam no planeta todos os anos mais de 300 milhões de hectares, causando significativos impactos ecológicos, climatológicos e econômicos (GIGLIO *et al.*, 2006; 2013). Muitas das queimadas estão combinados com atividades de desmatamento, resultando em conversão e alteração de vegetações florestais e savânicas por áreas agropecuárias (COCHRANE *et al.*, 1999; NEPSTAD *et al.*, 1999).

O bioma Cerrado é o segundo maior do Brasil e sua área de abrangência traça uma diagonal na direção nordeste-sudoeste, estendendo-se desde o Pantanal Matogrossense até a faixa litorânea maranhense e interpondo-se entre os biomas Amazônia, Mata Atlântica, Pantanal e Caatinga. O Bioma Cerrado é considerado um *hotspot* para conservação por apresentar uma alta diversidade de espécies com elevado endemismo, aliado à forte pressão de monoculturas e agronegócio (MYERS *et al.*, 2000). O Cerrado é composto por três formações vegetais: (a) campestre, que engloba áreas com predomínio de espécies herbáceas e algumas arbustivas, mas sem a presença de árvores na paisagem; (b) savânicas, com presença de áreas com árvores e arbustos espalhados sobre um estrato gramíneo, sem a formação de dossel contínuo; e (c) florestais, com a formação de dossel contínuo ou descontínuo e predomínio de arbóreas (RIBEIRO e WALTER, 1998). Os fatores ambientais predominantes do bioma Cerrado são: clima com estações seca e chuvosas definidas, os solos com baixa fertilidade e a incidência de fogo (MIRANDA, 2010). Estudos feitos no Brasil Central mostram abundância de partículas de carvão em sedimentos antigos associados à vegetação de Cerrado, algumas anteriores a 20.000 AP (Antes do Presente), evidenciando o longo convívio do Cerrado com o fogo (FRANÇA *et al.* 2007). Há evidências de fogo nessa região que datam de 32.000 anos antes do presente (SALGADO-LABOURIAU e FERRAZ-VICENTINI, 1994). Portanto, esse bioma apresenta alta resiliência, recuperando-se após eventos de queimadas, tendo inclusive espécies que são adaptadas ao fogo (BRAGA, 2013).

O monitoramento dos incêndios é fundamental para a viabilização do controle do fogo, redução dos custos nas operações de combate e atenuação dos danos (BATISTA, 2004). Séries temporais de dados de sensoriamento remoto são uma importante ferramenta para o estabelecimento de um sistema de monitoramento contínuo de queimadas e compreender os processos ecológicos e de impactos humanos em diferentes escalas espaciais (DALDEGAN *et al.*, 2014). As imagens

orbitais permitem estudos de carga de material combustível, detecção de focos de calor e mensuração remota de área queimada, mas ainda apresentam resoluções espaciais e temporais muito grosseiras para serem adequadas para a vigilância ativa de incêndios (VALERO *et al.*, 2017). A análise do comportamento histórico dos incêndios permite estabelecer correlações entre as variáveis que influenciam a ocorrência e propagação do fogo, sendo importante para entender as causas naturais e antrópicas (RODRÍGUEZ e SOARES, 2004). Além disso, gera informações valiosas do ponto de vista do manejo do solo, dando suporte a alternativas estratégicas para a conservação da biodiversidade, do solo e a redução das emissões de carbono (ALVES e PÉREZ-CABELLO, 2017).

Nesse contexto, muitos trabalhos foram desenvolvidos com sensores de alta resolução temporal e de resolução espacial moderada, tais como System Pour L'Observation de la Terre (SPOT-VEGETATION) (VERBESSELT *et al.*, 2006), Advanced Very High Resolution Radiometer (AVHRR) (MORENO RUIZ *et al.*, 2012), Geostationary Operational Environmental Satellite (GOES) (KOLTUNOV *et al.*, 2016), e Moderate Resolution Imaging Spectroradiometer (MODIS) (SCHROEDER *et al.*, 2008; SILVA *et al.*, 2005; WARDLOW e EGBERT, 2008; ZHANG *et al.*, 2015). Recentemente, imagens provenientes de nanossatélites passaram a permitir a aquisição de imagens com alta resolução espacial e temporal, proporcionando inovação tecnológica no imageamento terrestre.

A constelação de satélites Planet, composta por aproximadamente 130 satélites, é capaz de cobrir toda a superfície terrestre todos os dias (o que equivale a uma capacidade de coleta diária de 340 milhões de km<sup>2</sup> / dia) com resolução espacial de 3 metros (PLANET LABS, 2019). Os nanossatélites Planet, ou PlanetScope, possuem uma dimensão de 10 cm x 10 cm x 30 cm, e são comumente chamados de “pombas”. Seu principal componente é um telescópio e um sensor de matriz de área CCD, e estes são complementados por painéis solares para geração de energia, um receptor GNSS para posição de satélite, um startracker para orientação de satélites, rodas de reação para controle de atitude e estabilização, uma antena para downlink e uplink, baterias e armazenamento on-board. Uma metade da matriz CCD de 6600 x 4400 pixels adquire dados vermelho-verde-azul e a outra metade NIR; ambos usam uma resolução radiométrica de 16 bits. Os satélites PlanetScope fornecem imagens de resolução espacial de cerca de 3 m e um tamanho de cenas individuais de aproximadamente 24 km x 7 km (KÄÄB *et al.*, 2017). As capacidades dos pequenos

satélites em termos de resolução espacial e espectral estão próximas do que os satélites maiores podem fornecer. Pequenos satélites oferecem também a possibilidade única de instalar constelações acessíveis para fornecer uma boa cobertura diária do globo e/ou nos permitir observar vários fenômenos dinâmicos através de seu potencial de aumentar a resolução temporal. Os exemplos mostram que pequenos sistemas baseados em satélite são adequados para monitorar fenômenos globais, regionais e locais (SANDAU *et al.*, 2010).

As técnicas de sensoriamento remoto para o mapeamento do fogo focam na identificação da variação de emissão de energia detectada no momento da combustão ou no mapeamento das cicatrizes de queimadas a partir da diferenciação da resposta espectral (ALMEIDA-FILHO e SHIMABUKURO, 2004; GIGLIO *et al.*, 2006). O mapeamento e a extensão temporal dos incêndios são importantes, pois o incêndio é um fator de perturbação proeminente que afeta a estrutura do ecossistema e o ciclo do carbono e dos nutrientes (ROY *et al.*, 2008). Na identificação das áreas queimadas, a técnica mais utilizada combina duas operações algébricas: índice espectral e diferença sazonal entre as imagens de pré- e pós-fogo. Portanto, muitas pesquisas recaem na avaliação de bandas e geração de índices espectrais para uma melhor distinção dos eventos de fogo (CHUVIECO, 1999; DIAZ-DELGADO *et al.*, 2003; FANG e YANG, 2014; LIBONATI *et al.*, 2010). Diferentes índices têm sido testados e propostos, no entanto os mais difundidos são: *Normalized Difference Vegetation Index* (NDVI) (ROUSE *et al.*, 1974), *Normalized Burn Ratio* (NBR) (KEY e BENSON, 1999).

Nos últimos anos, a aprendizagem profunda (deep learning) provou ser uma ferramenta nova e eficiente na classificação de imagens de sensoriamento remoto (ZHANG *et al.*, 2016), possuindo um alto crescimento em diversas áreas de trabalho como análise de imagem hiperespectral (HU, F. *et al.*, 2015), interpretação de imagens SAR (BELENGUER-PLOMER *et al.*, 2019) e interpretação de imagens de satélite de alta resolução (XING *et al.*, 2018). Essa técnica é caracterizada por redes neurais envolvendo geralmente mais de duas camadas ocultas, sendo por isso denominadas de profundas (ZHU *et al.*, 2017). Uma Rede Neural Convolutiva (ou Convolutional Neural Network - CNN) é uma variação das redes de Perceptrons de Múltiplas Camadas, tendo sido inspirada no processo biológico de processamentos de dados visuais. De maneira semelhante aos processos tradicionais de visão computacional, uma CNN é capaz de aplicar filtros em dados visuais, mantendo a relação de vizinhança entre os pixels da imagem ao longo do processamento da rede. A CNN é

uma arquitetura multicamada treinável composta de múltiplos estágios de extração de características. Cada estágio consiste de três camadas: (1) uma camada convolucional; (2) uma camada de não linearidade; e (3) uma camada de agrupamento. A arquitetura de uma CNN é projetada para aproveitar a estrutura bidimensional da imagem de entrada. Uma CNN típica é composta por um, dois ou três desses estágios de extração de características, seguidos por uma ou mais camadas tradicionais totalmente conectadas e uma camada classificatória final (ZHANG *et al.*, 2016). Estudos recentes indicam que as representações de características aprendidas pelas CNNs são altamente eficazes no reconhecimento de imagens em larga escala, detecção de objetos e segmentação semântica (ZHU *et al.*, 2017), e a depender da informação que se deseja, a extração pode ser baseada em pixel, baseada em objetos ou baseada na estrutura. No entanto, uma abordagem efetiva e universal ainda não foi relatada para otimizar esses recursos, devido às sutis relações entre os dados (ZHANG *et al.*, 2016).

Dessa forma, a presente pesquisa busca identificar, classificar e mensurar a área queimada por incêndios florestais por meio de algoritmo de aprendizagem de máquina e método de deep learning aplicado em imagens orbitais dos satélites Planet no período de janeiro a setembro de 2018.

## 2. ÁREA DE ESTUDO

O Distrito Federal (DF) localiza-se no Brasil Central contendo uma área de 5.760,78 km<sup>2</sup> e população estimada de 2.974,703 habitantes (IBGE, 2019) (**Figura 1**). O clima da região recebe a classe Aw segundo a classificação Köppen-Geiger (CARDOSO *et al.*, 2014). Possui 106 Unidades de Conservação (UCs), sendo 95 unidades do DF, sob responsabilidade do Instituto do Meio Ambiente e Recursos Hídricos do Distrito Federal – IBRAM, e 11 unidades de conservação federais, administradas pelo Instituto Chico Mendes de Conservação da Biodiversidade (ICMBio) – o que representa mais de 90% do seu território sob proteção ambiental. Nessas unidades estão presentes as diferentes fitofisionomias do Cerrado e exemplares de fauna e flora ameaçados pela crescente expansão urbana e pressão por abertura de novas áreas para habitação.

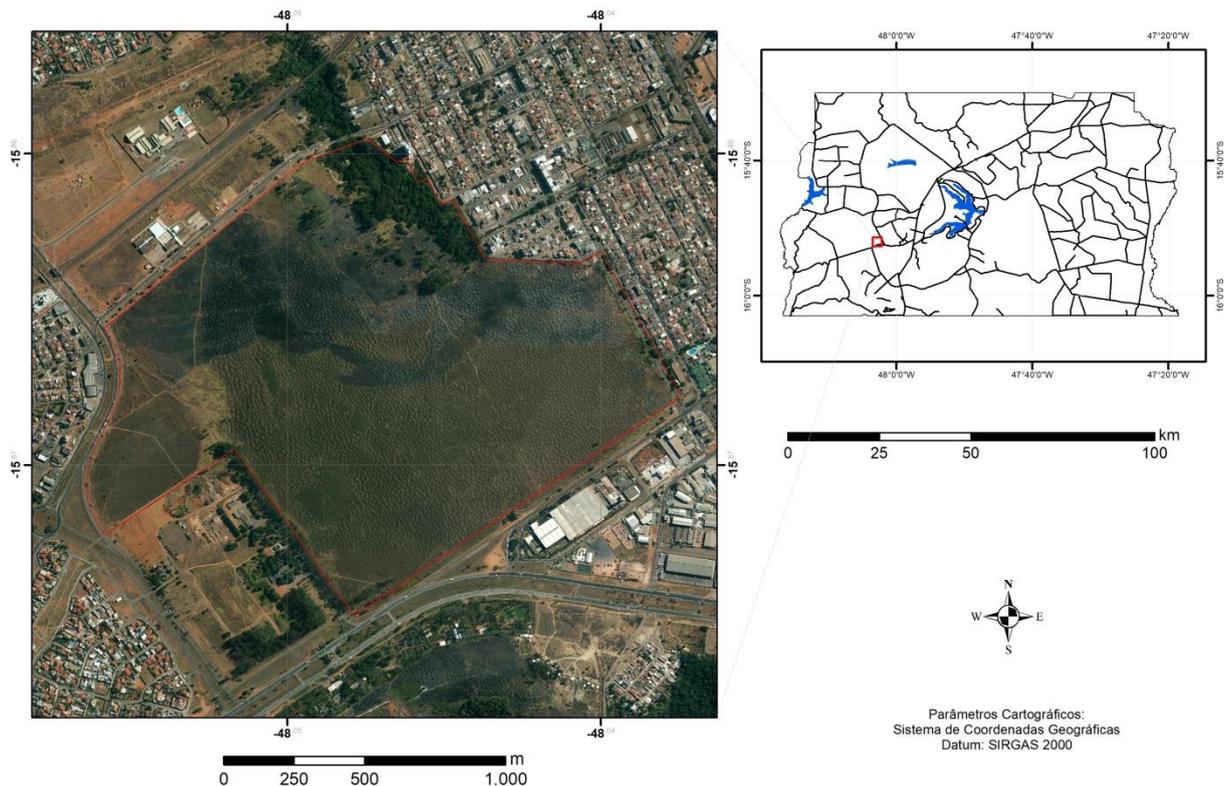


Figura 1: localização da área de estudo.

O Parque Ecológico Boca da Mata situado no quadrante sudoeste do DF é um importante remanescente de campo de murundu e também de áreas úmidas (*wetlands*) do DF, apresentando características de vegetação savânica, campestre e plantios de eucalipto. Possui histórico de ser intensamente afetada por incêndios florestais, tendo anualmente mais da metade de sua área incendiada (IBRAM, 2019). A unidade de conservação é cercada por forte urbanização, tendo desde áreas residenciais a indústrias, passando por instituições de ensino e órgãos governamentais.

Dentre os fatores que contribuem para a vulnerabilidade a ocorrências de incêndios florestais no Cerrado, podemos citar, além de componente climática (temperatura e umidade), a topografia (elevação e declividade), cobertura do solo, densidade populacional, distância de estradas e zonas urbanas e suprimento de água acessível (BEM, DE *et al.*, 2019). Esses fatores devem ser levados em consideração para analisar e categorizar risco de perigo de incêndios florestais, sobretudo em unidades de conservação. Muitas das unidades de conservação, inclusive, já levam em consideração o fogo na elaboração dos seus planos de manejo, avaliando e acompanhando o fogo em caso de ocorrências naturais (raios), só realizando o combate em caso de necessidade (SANTOS *et al.*, 2004).

### 3. MATERIAL E MÉTODOS

O trabalho seguiu o fluxo seguinte, apresentado na Figura 2.

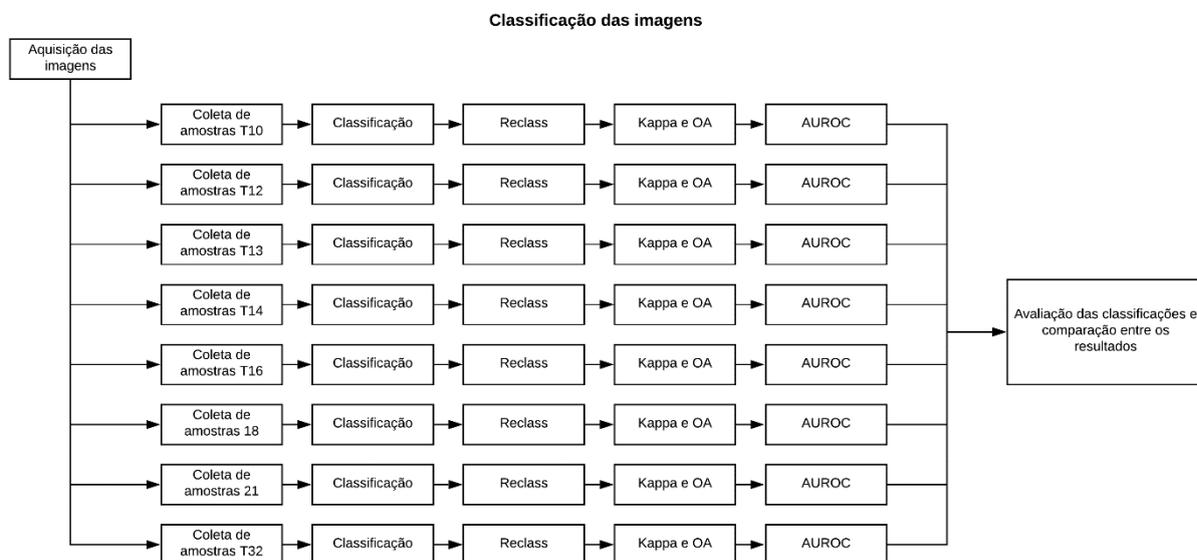


Figura 2: fluxo de processamento e classificação das imagens.

#### 3.1 Imagens do Sensor Planet

As imagens do satélite Planet (Planet Labs) foram obtidas no período entre janeiro a setembro de 2018, contendo resolução espacial de 3 metros e quatro bandas espectrais, nos comprimentos de onda do azul, verde, vermelho e infravermelho (RGB e NIR). As imagens foram disponibilizadas ortoretificadas, corrigidas radiométricamente e atmosféricamente com dados em reflectância de superfície terrestre.

A pesquisa utilizou o maior número de imagens ao longo do período que recobrissem totalmente a área alvo e contivesse até 10% de cobertura de nuvens, evitando erros de comissão provenientes da detecção errada de sombra de nuvens que possui resposta semelhante à área queimada na faixa do infravermelho próximo (ZHANG *et al.*, 2015). No período de estudo, foram obtidas 47 imagens (**Tabela 1**), das quais foram detectadas áreas queimadas em oito, nas datas de 21/06 – T32, 20/07 – T21, 29/07 – T18, 11/08 – T16, 13/08 – T14, 14/08 – T13, 15/08 – T12 e 30/08 – T10.

Tabela 1: data das imagens analisadas

Mês	Dia	Quantidade
Fevereiro	15	1
Março	5,28	2
Abril	22, 25, 29	3
Maio	3, 7, 10, 16, 21, 31	6
Junho	2, 8, 14, 21, 22, 23, 24, 25, 29, 30	10
Julho	4, 8, 12, 13, 20, 22, 23, 29, 30	9
Agosto	11, 12, 13, 14, 15, 19, 30, 31	8
Setembro	1, 3, 7, 8, 9, 23, 25, 29	8
Total		47

### 3.2 Métodos de Classificação das Áreas de Fogo

Na presente pesquisa foram comparadas os classificadores Random Forest (RF); K Nearest Neighbors (KNN); Support Vector Machine (SVM); e a rede neural convolucional profunda (CNN).

O KNN é o classificador mais simples dentre os classificadores supervisionados, pois requer apenas um parâmetro, que é o “K” vizinho mais próximo. Sua utilização também é atraente pelo fato de não exigir pré-processamento dos dados e nem pressupostos relativos à distribuição dos dados de treinamento (SAMANIEGO *et al.*, 2008). Ele assume que todas as amostras correspondem a pontos em um espaço n-dimensional, onde n é o número de descritores utilizados para representar as amostras. Para classificar ele reconhece a chamada "vizinhança" da nova amostra, quer dizer, os pontos já conhecidos mais próximos. Para calcular a proximidade das amostras podemos usar medidas de distância, dentre elas a mais simples e também usada neste trabalho é a distância euclidiana. Após calcular a distância entre a nova amostra e a outras já conhecidas, o algoritmo classifica a nova amostra como sendo pertencente à classe a qual ela tenha k vizinhos mais próximos (SOUSA, 2013). O KNN possui aplicação em diversos campos da pesquisa, sendo utilizado para extração de feições baseadas na textura (ZHANG *et al.*, 2017), na classificação de imagens de alta resolução (SAMANIEGO; BÁRDOSSY; SCHULZ, 2008) e detecção de mudanças (TAN *et al.*, 2016). Com relação a incêndios florestais, tem uso na modelagem de padrões de ocorrência de fogo (OLIVEIRA *et al.*, 2012).

O RF consiste em uma combinação de classificadores de árvore em que cada classificador é gerado usando um vetor aleatório amostrado independentemente do vetor de entrada, e cada árvore lança um voto unitário para a classe mais popular para

classificar um vetor de entrada (PAL, 2005). É uma técnica desenvolvida por (BREIMAN, 2001), como forma de melhorar a árvore de classificação e regressão (classification and regression tree – CART) através da combinação de um grande número de conjuntos de árvores de decisão. Cada árvore contribui com um único voto, e a classificação final é determinada pela maioria dos votos de todas as árvores da floresta (SOTHE *et al.*, 2017). O RF já foi utilizado em pesquisas relativas a incêndios florestais, com foco em predição de sua ocorrência (TEHRANY *et al.*, 2019), determinação da severidade de queima (COLLINS *et al.*, 2018) e caracterização do regime de fogo (OLIVEIRA *et al.*, 2012), mas até então não para a classificação de área queimada (RAMO e CHUVIECO, 2017).

O SVM, em sua forma original, é um classificador que busca encontrar um hiperplano de separação entre duas classes distintas, e pode efetivamente resolver problemas de classificação linear e não linear. No caso de classificação não linear, uma função kernel transforma o conjunto de dados não linearmente separável em um espaço de alta dimensionalidade, onde o problema pode ser resolvido linearmente. Os hiperplanos criados são usados para definir as regiões onde ocorrem cada uma das classes, sendo assim, quando recebemos uma nova amostra, ela será classificada de acordo com o posicionamento da mesma em relação ao hiperplano divisor (SOUSA, 2013). As funções kernel mais comumente utilizadas são Radial Basis, Sigmóide e Polinomial. Esse classificador já foi empregado com sucesso em estudos de classificação de imagens de alta resolução espacial visando a identificação de áreas queimadas (DRAGOZI *et al.*, 2014; PETROPOULOS *et al.*, 2011), mapeamento de distúrbios em ecossistemas (ZHAO *et al.* 2015) e classificação de imagens hiperespectrais (PENG *et al.*, 2015).

O DL, ou aprendizagem profunda, é a tendência de crescimento mais rápido na análise de big data e foi considerada uma das dez tecnologias inovadoras de 2013. Caracteriza-se por redes neurais (RNs) envolvendo geralmente mais de duas camadas ocultas, por isso, elas são chamados de deep (profundas) (ZHU *et al.*, 2017). As redes neurais convolucionais profundas (Convolutional Neural Network – CNN) são redes com arquitetura em vários estágios, inspiradas no cérebro humano, compostas, geralmente pela camada de entrada, camadas convolucionais, pooling, e fully connected, além da camada de saída. São reconhecidas como a abordagem de DL mais bem sucedida e com ampla utilização, sendo a metodologia majoritária nas tarefas de reconhecimento e detecção (HU, F. *et al.*, 2015). Desde 2014, a comunidade

de sensoriamento remoto tem concentrando sua atenção para DL, e esses algoritmos obtiveram sucesso significativo em muitas tarefas de análise de imagem, incluindo classificação de uso e cobertura da terra, classificação de cena e detecção de objetos (MA *et al.*, 2019). As redes neurais, base de algoritmos de aprendizagem profunda – Deep Learning (DL), são usadas há muitos anos.

Devido ao aspecto modular dos algoritmos de Deep Learning, existe uma grande variedade de arquiteturas disponíveis na literatura. Neste trabalho, escolheu-se utilizar uma arquitetura de rede convolucional com conexões residuais baseada na arquitetura elaborada por Pinheiro *et al.* (2016) e aplicada na classificação de imagens de sensoriamento remoto por Kemker *et al.* (2018) (KEMKER *et al.*, 2018). Este tipo de arquitetura reduz perda de informação espacial ao longo de múltiplas convoluções (ZHANG *et al.* 2018), fator essencial para classificações de imagens de sensoriamento remoto.

### **3.3 Amostragem**

Para a classificação por machine learning foram coletadas em média 45 amostras por classe, sendo que cada amostra continha cerca de 330 pixels, em cada uma das imagens onde foi detectada a presença de fogo. As classes adotadas foram: área queimada, mata de galeria/formações florestais, formações campestres, campo de murundu, gramíneas, área urbana, asfalto e solo exposto. Com as amostras, procedeu-se a classificação RF, KNN e SVM com a finalidade de separar as classes informadas para treinamento.

Após a classificação, os resultados foram reclassificados, agrupando-se as classes mata de galeria/formações florestais, formações campestres, campo de murundu, gramíneas, área urbana, asfalto e solo exposto, recebendo somente o rótulo de área queimada e área não queimada, mantendo a análise somente relativa a classe área queimada.

Para o deep learning foi feita classificação seguiu o proposto por De Bem *et al.*, (2018) binária em queimada e não queimada. Cada uma das suas imagens foi recortada passando uma janela de 200 x 200 pixels, com um passo de 180 pixels (dando um overlap de 10 pixels em cada lado). Isso gerou um total de 12 sub-imagens pra cada imagem. Como foram 8 tempos, o total foi de 96 amostras. O mesmo foi feito com a classe de queimadas. O treinamento foi realizado em 200 epochs.

### 3.4 Análise de Acurácia

A análise de acurácia da classificação utilizou a exatidão global (Overall Accuracy – OA), o coeficiente Kappa e a Área sob a curva ROC – AUROC. Para tanto, a verdade de campo foi produzida em formato vetorial por meio de análise visual e do Burned Area Index – BAI aplicado nas imagens, que posteriormente foi convertido para o formato raster e utilizado para o cálculo das métricas de precisão.

## 4. RESULTADOS E DISCUSSÃO

### 4.1 Resultados da Classificação

As classificações por machine learning apresentaram acurácia moderada, tendo como coeficiente Kappa médio de 0,52 conforme Landis e Koch (1977) O KNN obteve melhores resultados, apresentando maior acurácia em cinco das oito vezes que foi utilizado para classificação. Em segundo lugar aparece o SVM, que foi melhor em quatro oportunidades e o terceiro lugar ficou com o RF, que obteve o melhor resultado apenas em uma oportunidade e empatando em outra. Os valores obtidos são apresentados na **Tabela 2**.

Tabela 2: índice Kappa e Exatidão Global para KNN, RF e CNN

T	KNN		RF		SVM		CNN	
	Kappa	OA	Kappa	OA	Kappa	OA	Kappa	OA
T10	0,43	0,81	0,49	0,81	0,50	0,83	0,74	0,90
T12	0,90	0,96	0,89	0,96	0,90	0,96	0,95	0,98
T13	0,93	0,97	0,91	0,96	0,91	0,97	0,96	0,98
T14	0,85	0,99	0,76	0,98	0,83	0,99	0,81	0,98
T16	0,19	0,84	0,20	0,86	0,15	0,83	0,23	0,89
T18	0,38	0,96	0,15	0,96	0,39	0,96	0,60	0,98
T21	0,56	0,97	0,51	0,97	0,59	0,97	0,81	0,99
T32	0,49	0,96	0,46	0,95	0,47	0,95	0,83	0,99

Destaca-se que houve discordância entre algumas classificações, onde se tem o Overall elevado com o coeficiente Kappa baixo. Esse comportamento foi observado tanto na classificação por machine learning quanto da análise de acurácia da classificação pela CNN. Considerando que foram utilizadas as mesmas amostras e a mesma imagem a ser classificada, infere-se que essa diferença se deu por característica intrínseca aos classificadores.

Foi possível constatar que entre nos tempos 10 (30/08/2018) e 12 (15/08/2018)

houve uma nova entrada de fogo, porém não foi classificada como tal, levando a crer que o tempo entre a ocorrência do fogo e o imageamento influencia na capacidade de classificação dos algoritmos. Não foi possível precisar qual o intervalo máximo entre a incidência de fogo e a passagem do sensor que não prejudique a classificação, mas, empiricamente, infere-se que esse valor não seja maior que 10 dias. Passando desse tempo, o algoritmo tendeu a subestimar a área que efetivamente foi queimada e classificá-la em categoria diferente como, por exemplo, asfalto ou área urbana.

Deve-se levar em consideração a severidade da queima, visto que é ela quem vai determinar a velocidade de recuperação da vegetação. Queimas severas tendem a consumir todo o material combustível, dificultando rebrotas e, conseqüentemente, a recomposição da vegetação. Queimas brandas ou com menor tempo de residência do fogo permitem recuperação mais rapidamente.

A rede convolucional obteve bons resultados para o índice Kappa, com média entre os tempos de 0,74, considerado substancial. Isso pode ser explicado pelo fato de que no tempo T16, apesar da exatidão global ter sido elevada (0,89), o Kappa calculado foi baixo (0,23).

Como houve comportamento atípico entre os valores de acurácia global e Índice Kappa, procedeu-se à análise por meio de curvas ROC (Receiver Operating Characteristic) ou Característica Operacional do Receptor. A análise pelo método da área sob a curva ROC (AUROC) combina sensibilidade e especificidade, sendo uma medida do desempenho geral do classificador, com valores variando ente 0 e 1. Quanto mais próxima de 1 for a área, melhor o desempenho do classificador (PARKet al. 2004). Para esse parâmetro, apresentados na **Tabela 3**, a média global obteve o valor de 0,88. Dentre os classificadores avaliados, a CNN obteve os melhores resultados, com média de 0,98, enquanto os algoritmos de ML tiveram média de 0,84.

Tabela 3: valor de AUROC

T	AUROC			
	KNN	RF	SVM	CNN
<b>T10</b>	0,68	0,72	0,71	0,95
<b>T12</b>	0,95	0,94	0,95	1,00
<b>T13</b>	0,96	0,94	0,95	1,00
<b>T14</b>	0,91	0,82	0,89	1,00
<b>T16</b>	0,83	0,82	0,76	0,92
<b>T18</b>	0,69	0,57	0,71	0,99
<b>T21</b>	0,90	0,83	0,92	1,00
<b>T32</b>	0,95	0,94	0,94	0,99

Diferentes técnicas de aprendizado supervisionado têm sido empregadas para a classificação de cenas (como RF, SVM), e a abordagem com CNN frequentemente mostra resultados mais precisos (JI *et al.*, 2018). Tendência semelhante foi encontrada com a comparação de algoritmos de classificação (SVM e CNN) aplicados em imagens hiperespectrais, onde a CNN apresentou resultados mais precisos para a classificação (HU *et al.*, 2015b). De modo geral, redes neurais profundas têm maior poder de generalização, com casos em que a CNN apresenta resultados cerca de 30 % melhores quando comparados com resultados produzidos por outros classificadores, como o SVM (HEYDARI; MOUNTRAKIS, 2019).

Entretanto, os classificadores machine learning são amplamente utilizados, visto que são mais fáceis de serem implementados e apresentam resultados com bom nível de acurácia. Dentre eles, o RF é de grande agilidade, permitindo análises em menor tempo. O KNN é bastante simples, de fácil entendimento, mas tem alto custo computacional. O SVM é um algoritmo consolidado, apresentando resultados confiáveis com grande precisão (SAYAD *et al.*, 2019).

Ressalta-se que o tamanho da imagem analisada pela rede é menor que a imagem analisada por meio da aprendizagem de máquina. Isso se deveu ao fato dos parâmetros de entrada da rede. Contudo, a área classificada permite que se façam avaliações de ambos os métodos AM e DL, posto que há sobreposições. Assim, considerando a área do parque, temos que os quatro algoritmos de classificação (KNN, RF, SVM e CNN) retornaram áreas queimadas, que puderam ser avaliadas entre si, como apresentado na **Tabela 4**. É possível perceber, analisando individualmente, variações entre as áreas, mas que não destoam entre si. Compilando todas as imagens classificadas individualmente (merge), temos que as áreas totais são bastante coincidentes, permitindo concluir que os métodos de classificação são aderentes entre si conforme apresentado na **Tabela 5**. A análise visual da compilação das áreas queimada está representada na **Figura 3**.

Tabela 4: área classificada como queimada, em hectares

	Área queimada (hectares)			
	KNN	RF	SVM	CNN
<b>T10</b>	34,58	54,59	40,71	63,40
<b>T12</b>	82,00	77,60	80,67	79,00
<b>T13</b>	82,08	74,90	79,07	81,08
<b>T14</b>	10,55	8,01	10,18	17,21
<b>T16</b>	37,67	45,92	44,57	40,00
<b>T18</b>	5,41	3,23	5,97	7,21
<b>T21</b>	8,53	8,70	8,71	9,35
<b>T32</b>	11,22	14,29	11,84	8,87

Tabela 5: compilado da área classificada como queimada, em hectares

	Área queimada (hectares)			
	KNN	RF	SVM	CNN
<b>Merge</b>	120,16	125,13	120,74	115,64

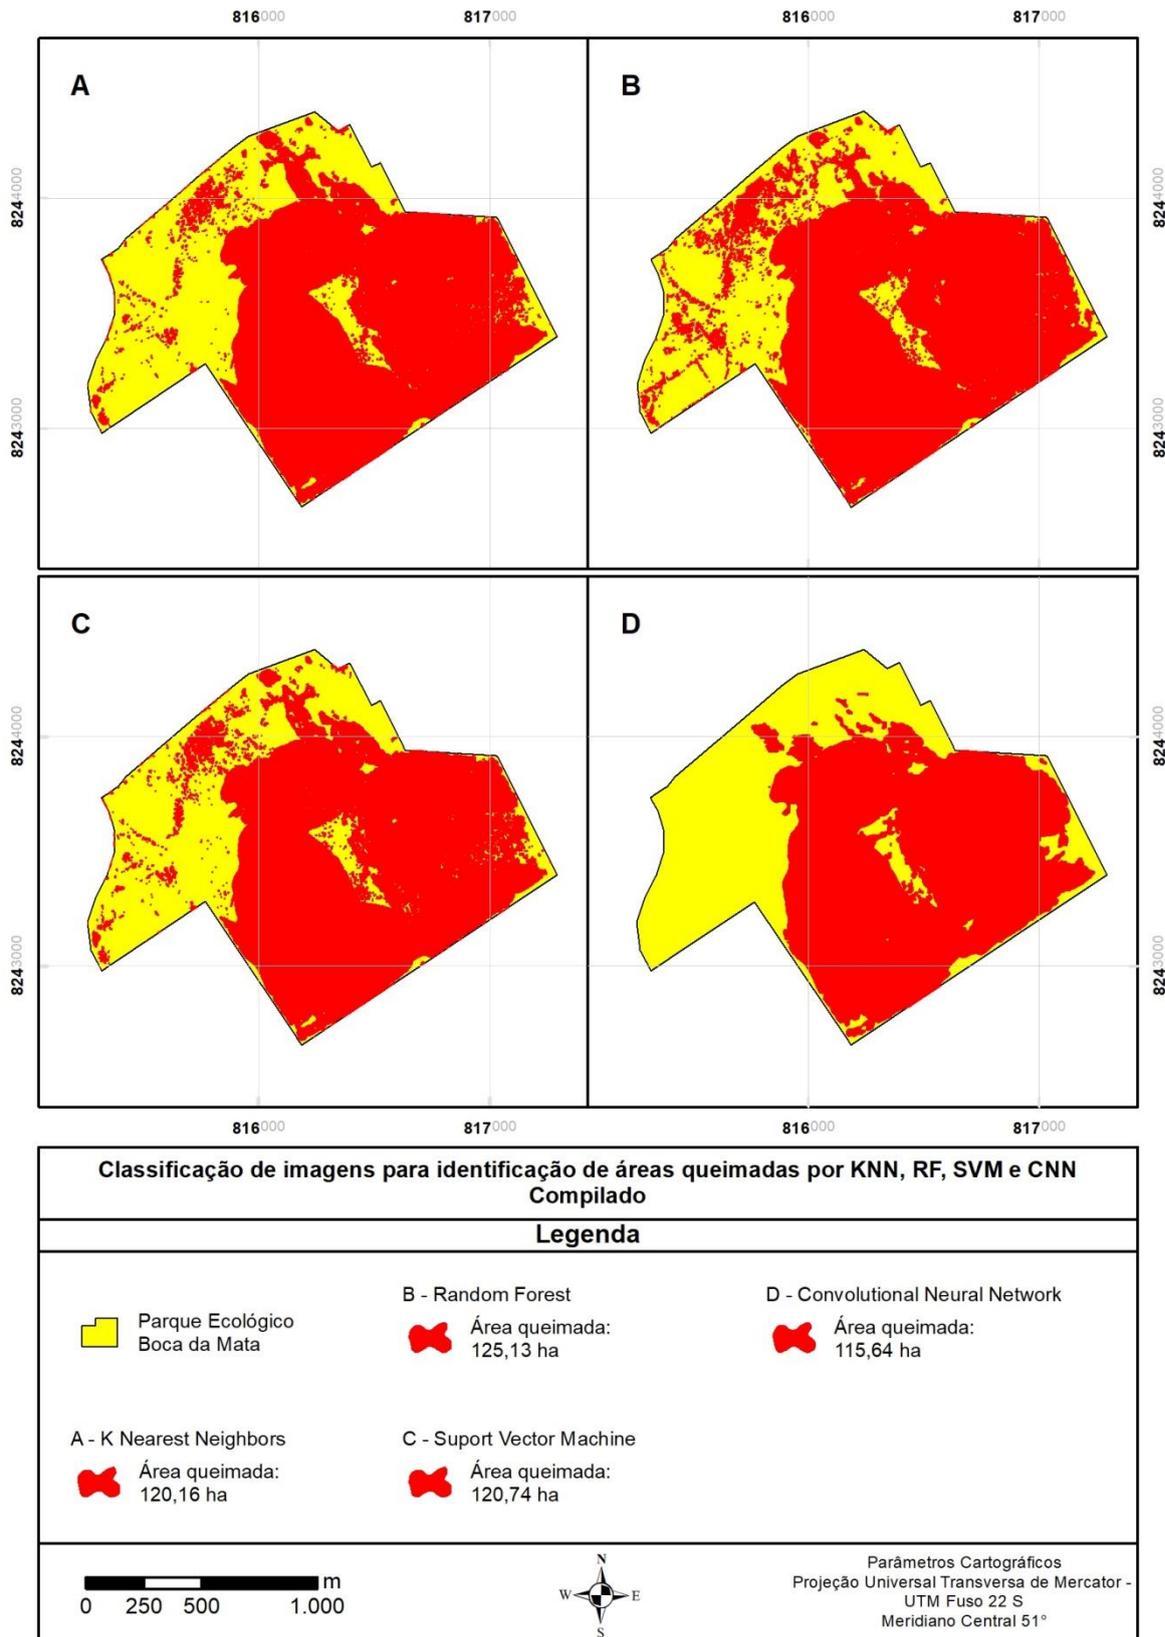


Figura 3: comparação entre áreas queimadas obtidas pelas classificações.

## 5. CONCLUSÃO

A comparação dos métodos de classificação supervisionada de áreas queimadas usando imagens de alta resolução espacial demonstrou que tanto os algoritmos de machine learning quanto de redes neurais convolucionais são adequados, com as redes apresentando resultados mais acurados. No tocante à análise de acurácia, o método de curvas ROC se reafirmou como o mais adequado para classificações binárias.

A área do estudo possuía pequenas dimensões, mas o suficiente para testar a metodologia e obter sucesso na classificação. A metodologia empregada mostrou-se compatível com o uso em imagens de alta resolução espacial, mostrando agilidade e otimização do tempo para a classificação.

O campo de aprendizado de máquina e aprendizado profundo encontra-se em franca expansão, sendo desenvolvido constantemente, por isso outros estudos podem ser desenvolvidos visando a novas metodologias de classificação, com novos e mais complexos algoritmos, que podem, possivelmente, retornar resultados mais acurados.

Destaque deve ser dado ao desenvolvimento no campo das redes neurais, visto que este apresenta grande potencial de trabalhar com grande número de dados, como é o caso da produção de imagens por sensores com alta resolução temporal e espacial, em menor tempo e com resultados bastante confiáveis.

## 6. REFERÊNCIAS BIBLIOGRÁFICAS

- ALMEIDA-FILHO, R.; SHIMABUKURO, Y. E. Monitoring biomass burning in the Brazilian Amazônia. **International Journal of Remote Sensing**, v. 25, n. 24, p. 5537–5542, 2004.
- ALVES, D. B.; PÉREZ-CABELLO, F. Multiple remote sensing data sources to assess spatio-temporal patterns of fire incidence over Campos Amazônicos Savanna Vegetation Enclave (Brazilian Amazon). **Science of the Total Environment**, v. 601–602, p. 142–158, 2017.
- BATISTA, A. C. Detecção de incêndios florestais por satélites. **Floresta**, v. 34, n. 2, p. 237–241, 2004.
- BELENQUER-PLOMER, M. A.; TANASE, M. A.; FERNANDEZ-CARRILLO, A.; CHUVIECO, E. Burned area detection and mapping using Sentinel-1 backscatter coefficient and thermal anomalies. **Remote Sensing of Environment**, v. 233, n. July 2018, p. 111345, 2019.
- BRAGA, J. V. Detecção de Áreas Queimadas Através de Séries Temporais MODIS no Intermédio da RPPN Serra do Tombador e o Parque Nacional Chapada dos Veadeiros – GO. **Dissertação de Mestrado**, p. 34, 2013.
- BREIMAN, L. Random forests. **Machine learning**, p. 5–32, 2001.
- CARDOSO, M. R. D.; MARCUZZO, F. F. N.; BARROS, J. R. CLASSIFICAÇÃO CLIMÁTICA DE KÖPPEN-GEIGER PARA O ESTADO DE GOIÁS E O DISTRITO FEDERAL. **Acta Geográfica**, v. 8, n. 16, p. 40–55, 2014.
- CHUVIECO, E. Measuring changes in landscape pattern from satellite images: Short-term effects of fire on spatial diversity. **International Journal of Remote Sensing**, v. 20, n. 12, p. 2331–2346, 1999.
- COCHRANE, M. A.; ALENCAR, A.; SCHULZE, M. D.; SOUZA JR, C. M.; NEPSTAD, D. C.; LEFEBVRE, P.; DAVIDSON, E. A. Positive feedbacks in the fire dynamic of closed canopy tropical forests. **Science**, v. 284, n. 5421, p. 1832–1835, 1999.
- COLLINS, L.; GRIFFIOEN, P.; NEWELL, G.; MELLOR, A. The utility of Random Forests for wildfire severity mapping. **Remote Sensing of Environment**, v. 216, n. December 2017, p. 374–384, 2018.
- DALDEGAN, G. A.; CARVALHO JÚNIOR, O. A.; GUIMARÃES, R. F.; GOMES, R. A.

T.; RIBEIRO, F. F.; MCMANUS, C. Spatial Patterns of Fire Recurrence Using Remote Sensing and GIS in the Brazilian Savanna: Serra do Tombador Nature Reserve, Brazil. **Remote Sensing**, v. 6, n. 10, p. 9873–9894, 2014.

DE BEM, P. P.; CARVALHO JÚNIOR, O. A.; GOMES, R. A. T.; GUIMARÃES, F. G. Burned Area Classification in Multispectral Satellite Imagery Using Deep Convolutional Neural Networks. 2018.

DE BEM, P. P.; CARVALHO JÚNIOR, O. A.; MATRICARDI, E. A. T.; GUIMARÃES, R. F.; GOMES, R. A. T. Predicting wildfire vulnerability using logistic regression and artificial neural networks: A case study in Brazil's Federal District. **International Journal of Wildland Fire**, v. 28, n. 1, p. 35–45, 2019.

DÍAZ-DELGADO, R.; LLORET, F.; PONS, X. Influence of fire severity on plant regeneration by means of remote sensing imagery. **International Journal of Remote Sensing**, v. 24, n. 8, p. 1751–1763, 2003.

DRAGOZI, E.; GITAS, I. Z.; STAVRAKOUDIS, D. G.; THEOCHARIS, J. B. Burned area mapping using support vector machines and the FuzCoC feature selection method on VHR IKONOS imagery. **Remote Sensing**, v. 6, n. 12, p. 12005–12036, 2014.

FANG, L.; YANG, J. Atmospheric effects on the performance and threshold extrapolation of multi-temporal Landsat derived dNBR for burn severity assessment. **International Journal of Applied Earth Observation and Geoinformation**, v. 33, n. 1, p. 10–20, 2014.

FRANÇA, H.; RAMOS NETO, M. B.; SETZER, A. **O fogo no Parque Nacional das Emas**. [s.l: s.n.].

GIGLIO, L.; RANDERSON, J. T.; WERF, G. R. **Analysis of daily, monthly, and annual burned area using the fourth-generation global fire emissions database (GFED4)** **Journal of Geophysical Research: Biogeosciences**, 2013. Disponível em: <<https://doi.org/10.1002/jgrg.20042>>

GIGLIO, L.; WERF, G. R.; RANDERSON, J. T.; COLLATZ, G. J.; KASIBHATLA, P. Global estimation of burned area using MODIS active fire observations. **Atmospheric Chemistry and Physics**, v. 6, n. 4, p. 957–974, 2006.

HEYDARI, S. S.; MOUNTRAKIS, G. Meta-analysis of deep neural networks in remote sensing: A comparative study of mono-temporal classification to support vector machines. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 152, n.

February 2018, p. 192–210, 2019.

HU, F.; XIA, G.; HU, J.; ZHANG, L. Transferring deep convolutional neural networks for the scene classification of high-resolution remote sensing imagery. **Remote Sensing**, v. 7, n. 11, p. 14680–14707, 2015a.

HU, W.; HUANG, Y.; WEI, L.; ZHANG, F.; LI, H. Deep Convolutional Neural Networks for Hyperspectral Image Classification. **Journal of Sensors**, v. 740, p. 397–410, 2015b.

IBGE. **Distrito Federal | Cidades e Estados | IBGE**. Disponível em: <<https://www.ibge.gov.br/cidades-e-estados/df/.html?>>. Acesso em: 24 maio. 2019.

IBRAM. Relatório de área queimada nos parques e unidades de conservação do Distrito Federal no ano de 2018. **Diretoria de Avaliação da Qualidade Ambiental - IBRAM**, p. 146, 2019.

JI, S.; ZHANG, C.; XU, A.; SHI, Y.; DUAN, Y. 3D convolutional neural networks for crop classification with multi-temporal remote sensing images. **Remote Sensing**, v. 10, n. 1, 2018.

KÄÄB, A.; ALTENA, B.; MASCARO, J. Coseismic displacements of the 14 November 2016 Mw7.8 Kaikoura, New Zealand, earthquake using the Planet optical cubesat constellation. **Natural Hazards and Earth System Sciences**, v. 17, n. 5, p. 627–639, 2017.

KEMKER, R.; SALVAGGIO, C.; KANAN, C. Algorithms for semantic segmentation of multispectral remote sensing imagery using deep learning. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 145, n. March, p. 60–77, 2018.

KEY, C.; BENSON, N. The normalized burn ratio, a Landsat TM radiometric index of burn severity incorporating multi-temporal differencing. **U.S. Geological Survey**, p. 2000, 1999.

KOLTUNOV, A.; USTIN, S. L.; QUAYLE, B.; SCHWIND, B.; AMBROSIA, V. G.; LI, W. The development and first validation of the GOES Early Fire Detection (GOES-EFD) algorithm. **Remote Sensing of Environment**, v. 184, p. 436–453, 2016.

LANDIS, J. R.; KOCH, G. G. The Measurement of Observer Agreement for Categorical Data. **Biometrics**, v. 33, n. 1, p. 159, 1977.

LIBONATI, R.; DACAMARA, C. C.; PEREIRA, J. M. C.; PERES, L. F. Retrieving middle-infrared reflectance for burned area mapping in tropical environments using MODIS. **Remote Sensing of Environment**, v. 114, n. 4, p. 831–843, 2010.

MA, L.; LIU, Y.; ZHANG, X.; YE, Y.; YIN, G. JOHNSON, B. A. Deep learning in remote sensing applications: A meta-analysis and review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 152, n. April, p. 166–177, 2019.

MIRANDA, H. S. **Efeitos do regime do fogo sobre a estrutura de comunidades de cerrado: Resultados do Projeto Fogo**. [s.l: s.n.].

MORENO RUIZ, J. A.; RIAÑO, D.; ARBELO, M.; FRENCH, N. H. F.; USTIN, S. L. Burned area mapping time series in Canada (1984-1999) from NOAA-AVHRR LTDR: A comparison with other remote sensing products and fire perimeters. **Remote Sensing of Environment**, v. 117, p. 407–414, 2012.

MYERS, N.; MITTERMEIER, R. A.; MITTERMEIER, C. G.; FONSECA, G. A. B.; KENT, J. Biodiversity hotspots for conservation priorities. **Nature**, v. 403, n. February, p. 853–858, 2000.

NEPSTAD, D. C.; VERÍSSIMO, A.; ALENCAR, A.; NOBRE, C.; LIMA, E.; LEFEBVRE, P.; SCHLESINGER, P.; POTTER, C.; MOUTINHO, P.; MENDOZA, E.; COCHRANE, M.; BROOKS, V. Large-scale impoverishment of Amazonian forests by logging and fire. **Nature**, v. 398, n. 9727, p. 505–508, 1999.

OLIVEIRA, S.; OEHLER, F.; SAN-MIGUEL-AYANZ, J.; CAMIA, A.; PEREIRA, J. M. C. Modeling spatial patterns of fire occurrence in Mediterranean Europe using Multiple Regression and Random Forest. **Forest Ecology and Management**, v. 275, p. 117–129, 2012.

PAL, M. Random forest classifier for remote sensing classification. **International Journal of Remote Sensing**, v. 26, n. 1, p. 217–222, 2005.

PARK, S. H.; GOO, J. M.; JO, C.-H. Receiver Operating Characteristic (ROC) Curve: Practical Review for Radiologists. **Korean Journal of Radiology**, v. 5, n. 11–18, 2004.

PENG, J.; ZHOU, Y.; CHEN, C. L. P. Region-Kernel-Based Support Vector Machines for Hyperspectral Image Classification. **IEEE Transactions on Geoscience and Remote Sensing**, v. 53, n. 9, p. 4810–4824, 2015.

PETROPOULOS, G. P.; KONTOES, C.; KERAMITSOGLOU, I. Burnt area delineation from a uni-temporal perspective based on landsat TM imagery classification using Support Vector Machines. **International Journal of Applied Earth Observation and Geoinformation**, v. 13, n. 1, p. 70–80, 2011.

PLANET LABS. Planet Imagery Product Specification. n. October, p. 56, 2019.

RAMO, R.; CHUVIECO, E. Developing a Random Forest algorithm for MODIS global burned area classification. **Remote Sensing**, v. 9, n. 11, 2017.

REQUIA, W. J.; COULL, B. A.; KOUTRAKIS, P. The impact of wildfires on particulate carbon in the western U.S.A. **Atmospheric Environment**, v. 213, n. May, p. 1–10, 2019.

RIBEIRO, J. F.; WALTER, B. M. T. Fitofisionomias do Bioma Cerrado. **Embrapa Cerrados - Capítulo em livro científico (ALICE)**, 1998.

RODRÍGUEZ, M. P. R.; SOARES, R. V. Análisis Comparativo Entre Los Incendios Forestales En Monte Alegre, Brasil Y Pinar Del Río, Cuba. **Floresta**, v. 34, n. 2, p. 101–107, 2004.

ROUSE, J. W.; HASS, R. H.; SCHELL, J. A. DEERING, D, W. Monitoring Vegetation Systems in the Great Plains with ERTS. **Third Earth Resources Technology Satellite-1 Symposium**, v. 1, p. 309–317, 1974.

ROY, D. P.; BOSCHETTI, L.; JUSTICE, C. O.; JU, J. The collection 5 MODIS burned area product - Global evaluation by comparison with the MODIS active fire product. **Remote Sensing of Environment**, v. 112, n. 9, p. 3690–3707, 2008.

SALGADO-LABOURIAU, M. L.; FERRAZ-VICENTINI, K. R. Fire in the Cerrado 32,000 years ago. **Current Research in the Pleistocene**, v. 11, n. 1, p. 85–87, 1994.

SAMANIEGO, L.; BÁRDOSSY, A.; SCHULZ, K. Supervised classification of remotely sensed imagery using a modified k-NN technique. **IEEE Transactions on Geoscience and Remote Sensing**, v. 46, n. 7, p. 2112–2125, 2008.

SANDAU, R.; BRIESS, K.; D'ERRICO, M. Small satellites for global coverage: Potential and limits. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65, n. 6, p. 492–504, 2010.

SANTOS, A. S. DOS.; ALVES, J. S.; OLIVEIRA, S. D. F. Plano de Manejo do Parque Nacional das Emas. **Rev da FECHAFFA**, v. 1, p. 215–221, 2004.

SAYAD, Y. O.; MOUSANNIF, H.; AL MOATASSIME, H. Predictive modeling of wildfires: A new dataset and machine learning approach. **Fire Safety Journal**, v. 104, n. September 2018, p. 130–146, 2019.

SCHROEDER, W.; PRINS, E.; GIGLIO, L.; CSISZAR, I.; SCHMIDT, C.; MORISETTE, J.; MORTON, D. Validation of GOES and MODIS active fire detection products using ASTER and ETM+ data. **Remote Sensing of Environment**, v. 112, n. 5, p. 2711–2726,

2008.

SILVA, J. M. N.; SÁ, A. C. L.; PEREIRA, J. M. C. Comparison of burned area estimates derived from SPOT-VEGETATION and Landsat ETM+ data in Africa: Influence of spatial pattern and vegetation type. **Remote Sensing of Environment**, v. 96, n. 2, p. 188–201, 2005.

SOTHE, C. et al. Abordagens para classificação do estágio sucessional da vegetação do parque nacional de São Joaquim empregando imagens landsat-8 e rapideye. **Boletim de Ciências Geodesicas**, v. 23, n. 3, p. 389–404, 2017.

SOUSA, R. T. Avaliação de classificadores na classificação de radiografias de tórax para o diagnóstico de pneumonia infantil. **Dissertação (Mestrado) - Programa de Pós-Graduação do Instituto de Informática da Universidade Federal de Goiás**, p. 61, 2013.

TAN, K.; JIN, X.; PLAZA, A.; WANG, X.; XIAO, L.; DU, P. Automatic Change Detection in High-Resolution Remote Sensing Images by Using a Multiple Classifier System and Spectral-Spatial Features. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 9, n. 8, p. 3439–3451, 2016.

TEHRANY, M. S.; JONES, S.; SHABANI, F.; MARTÍNEZ-ÁLVARES, F.; BUI, D. T. et al. A novel ensemble modeling approach for the spatial prediction of tropical forest fire susceptibility using LogitBoost machine learning classifier and multi-source geospatial data. **Theoretical and Applied Climatology**, v. 137, n. 1–2, p. 637–653, 2019.

VALERO, M. M.; RIOS, O.; MATA, C.; PASTOR, E.; PLANAS, E. An integrated approach for tactical monitoring and data-driven spread forecasting of wildfires. **Fire Safety Journal**, v. 91, n. May, p. 835–844, 2017.

VERBESSELT, J.; SOMERS, B.; AARDT, J.; JONCKHEERE, I.; COPPIN, P. Monitoring herbaceous biomass and water content with SPOT VEGETATION time-series to improve fire risk assessment in savanna ecosystems. **Remote Sensing of Environment**, v. 101, n. 3, p. 399–414, 2006.

WARDLOW, B. D.; EGBERT, S. L. Large-area crop mapping using time-series MODIS 250 m NDVI data: An assessment for the U.S. Central Great Plains. **Remote Sensing of Environment**, v. 112, n. 3, p. 1096–1116, 2008.

XING, H.; MENG, Y.; WANG, Z.; FAN, K.; HOU, D. Exploring geo-tagged photos for land cover validation with deep learning. **ISPRS Journal of Photogrammetry and**

**Remote Sensing**, v. 141, n. December 2017, p. 237–251, 2018.

ZHANG, L.; ZHANG, L.; DU, B. Deep learning for remote sensing data: A technical tutorial on the state of the art. **IEEE Geoscience and Remote Sensing Magazine**, v. 4, n. 2, p. 22–40, 2016.

ZHANG, R.; QU, J. J.; LIU, Y.; HAO, X.; HUANG, C.; ZHAN, X. Detection of burned areas from mega-fires using daily and historical MODIS surface reflectance. **International Journal of Remote Sensing**, v. 36, n. 4, p. 1167–1187, 2015.

ZHANG, X.; CUI, J.; WANG, W.; LIN, C. A study for texture feature extraction of high-resolution satellite images based on a direction measure and gray level co-occurrence matrix fusion algorithm. **Sensors (Switzerland)**, v. 17, n. 7, 2017.

ZHANG, Z.; LIU, Q.; WANG, Y. Road Extraction by Deep Residual U-Net. **IEEE Geoscience and Remote Sensing Letters**, v. 15, n. 5, p. 749–753, 2018.

ZHAO, F.; HUANG, C.; ZHU, Z. Use of vegetation change tracker and support vector machine to map disturbance types in greater yellowstone ecosystems in a 1984-2010 landsat time series. **IEEE Geoscience and Remote Sensing Letters**, v. 12, n. 8, p. 1650–1654, 2015.

ZHU, X. X.; TUIA, D.; MOU, L.; XIA, G.; ZHANG, L.; XU, F.; FRAUNDORFER. Deep learning in remote sensing: a review. **IEEE Geoscience and Remote Sensing Magazine**, n. december, 2017.

