

Universidade de Brasília – UnB
Campus Gama – FGA
Engenharia Aeroespacial

**PROPOSTA E AVALIAÇÃO DE MODELOS PARA
DETECÇÃO E PREDIÇÃO DA PROPAGAÇÃO DE QUEIMADAS
COM BASE EM IMAGENS MULTI-ESPECTRAIS DE SATÉLITES**

DANIEL FARKAT ALVES FONTES

Orientador: DR. CRISTIANO JACQUES MIOSSO
Coorientador: . PROF. DR. GIANCARLO SANTILLI



UNB – UNIVERSIDADE DE BRASÍLIA

FGA – FACULDADE GAMA

ENGENHARIA AEROESPACIAL

**PROPOSTA E AVALIAÇÃO DE MODELOS PARA DETECÇÃO E
PREDIÇÃO DA PROPAGAÇÃO DE QUEIMADAS
COM BASE EM IMAGENS MULTI-ESPECTRAIS DE SATÉLITES**

DANIEL FARKAT ALVES FONTES

ORIENTADOR: DR. CRISTIANO JACQUES MIOSSO

CO-ORIENTADOR: PROF. DR. GIANCARLO SANTILLI

TRABALHO DE CONCLUSÃO DE CURSO

ENGENHARIA AEROESPACIAL

BRASÍLIA/DF, FEVEREIRO DE 2023

UNB – UNIVERSIDADE DE BRASÍLIA
FGA – FACULDADE GAMA
ENGENHARIA AEROESPACIAL

**PROPOSTA E AVALIAÇÃO DE MODELOS PARA DETECÇÃO E
PREDIÇÃO DA PROPAGAÇÃO DE QUEIMADAS
COM BASE EM IMAGENS MULTI-ESPECTRAIS DE SATÉLITES**

DANIEL FARKAT ALVES FONTES

**TRABALHO DE CONCLUSÃO DE CURSO SUBMETIDO À FACULDADE UNB GAMA DA
UNIVERSIDADE DE BRASÍLIA, COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A
OBTENÇÃO DO GRAU DE BACHAREL EM ENGENHARIA AEROESPACIAL**

APROVADA POR:

Dr. Cristiano Jacques Miosso

(Orientador)

Vinícius Pinheiro, MSc

Filipe Emidio Tôrres, MSc

Prof. Ronne Toledo

FICHA CATALOGRÁFICA

FARKAT, DANIEL

Proposta e Avaliação de Modelos para Detecção e Predição da Propagação de Queimadas com Base em Imagens Multi-Espectrais de Satélites

[Distrito Federal], 2022.

56p., 210 × 297 mm (FGA/UnB Gama, Bacharelado em Engenharia Aeroespacial, 2022).

Trabalho de Conclusão de Curso, Faculdade UnB Gama, Engenharia Aeroespacial

- | | |
|------------------------------------|--|
| 1. Sistemas de Observação da Terra | 2. Aprendizado de Máquina Supervisionado |
| 3. <i>Landsat</i> | 4. Processamento de Sinais |
| 5. Identificador de incêndio | |

I. FGA UnB/UnB.

II. Título (série)

REFERÊNCIA

FARKAT, DANIEL (2023). Proposta e Avaliação de Modelos para Detecção e Predição da Propagação de Queimadas com Base em Imagens Multi-Espectrais de Satélites . Trabalho de Conclusão de Curso, Engenharia Aeroespacial, Faculdade UnB Gama, Universidade de Brasília, Brasília, DF, 56p.

CESSÃO DE DIREITOS

AUTOR: Daniel Farkat Alves Fontes

TÍTULO: Proposta e Avaliação de Modelos para Detecção e Predição da Propagação de Queimadas com Base em Imagens Multi-Espectrais de Satélites

GRAU: Bacharel em Engenharia Aeroespacial

ANO: 2023

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

danielfarkataf@gmail.com

Brasília, DF – Brasil

AGRADECIMENTOS

Primeiramente, gostaria de expressar minha gratidão a Deus e à minha mãe Aguida Maria, pois precisei de muita força ao longo desta caminhada. Portanto, esses dois estiveram sempre ao meu lado. Também gostaria de agradecer imensamente à Universidade de Brasília, campus Gama, por me proporcionar a oportunidade de realizar o meu sonho de cursar Engenharia Aeroespacial. Aqui, vivi momentos felizes e fiz grandes amigos que estarão para sempre na minha vida. Além disso, nesta universidade, encontrei um lar para os meus conhecimentos. Percebo que me tornei um homem mais maduro, confiante e com amplo entendimento de engenharia aeroespacial graças a essa grande oportunidade concedida pela Universidade de Brasília.

Agradeço ao Professor Cristiano Miosso por ter me cativado ao longo desses muitos anos no curso de engenharia. Ele não foi apenas um grande orientador, mas também um grande amigo. Com sua orientação, aprendi a escrever melhor, programar melhor e a compreender não apenas o processamento de sinais, a modelagem de sistemas e projetos, mas também como ser um ser humano melhor. Muito obrigado, Professor.

Também agradeço ao Professor Giancarlo Santilli por ter me proporcionado tantas oportunidades de conhecimento na área aeroespacial. Ao longo dessa jornada, creio que não seria metade do que sou hoje em termos de observação da Terra se não fosse pelas suas aulas. Muito obrigado, Professor.

Quero agradecer também ao meu coordenador de curso, Professor Ronne Toledo, por ter dedicado seu tempo para me ajudar. Agradeço também a todos os funcionários da UnB por tornarem possível a organização desta faculdade.

Expresso minha gratidão aos meus amigos Pedro, Raphael, Leonardo, Dimítrius, Daniel, Caetano, Gabriel, Gabriela, Estéfane, Erica, Dani, Fernanda e Táila. Agradeço também ao apoio do meu pai Newton e das minhas irmãs Raíssa e Camila. Sou grato à Áurea Campanharo e Cláudio Carvalho por terem me cedido um espaço em sua casa e por me tratarem como família, permitindo que eu concluísse a produção deste documento. Agradeço também à minha madrinha Vera e aos meus tios Almir, Auria, Arilda, Almantino, Autino, Alda e Amilto por me apoiarem na escolha deste curso.

Por fim, mas não menos importante, agradeço ao Major João Henrique, a todo o Grupamento de Proteção Ambiental e à minha banca examinadora. Sem vocês, este projeto não seria possível.

RESUMO

Esta pesquisa surgiu com o intuito de desenvolver um sistema capaz de identificar marcas de incêndio a partir de imagens de incêndios. Porém, com o desenvolver do projeto a tese foi sendo alterada para auxiliar o GPRAM a desenvolver um algoritmo capaz de demarcar áreas afetadas pelo fogo na região do distrito federal.

Sendo assim, foi implementado e avaliado um modelo capaz de demarcar áreas nas quais foi possível identificar marcas de incêndio ocorridos na região do Distrito Federal. Portanto, são utilizados identificadores supervisionados, baseados em inteligência artificial, aplicados em imagens do satélite *Landsat-8*. Dessa forma, são estabelecidas correlações entre as datas e as localidades espaciais dos incêndios e os dados vetoriais de acesso público produzidos pela autoridade ambiental GPRAM (Grupo de Proteção Ambiental). Em resumo, o processo envolve desenvolver um sistema capaz de demarcar uma classe específica, indicando sua existência, ou a outra classe, indicando sua inexistência, a fim de treinar o classificador de áreas afetadas pelo fogo.

O GPRAM, estabelecido em 2010 e com sede em Brasília, desempenha um papel fundamental como autoridade ambiental no que diz respeito ao combate e prevenção de incêndios no Distrito Federal. Dentro de suas atribuições, o GPRAM possui uma divisão especializada em inteligência tática, responsável por transmitir um relatório anual de áreas afetadas pelo fogo. Esse documento, possui um estudo de sensoriamento remoto com dados espaciais de áreas afetadas pelo fogo.

Através de sistemas de observação da terra em datas específicas, a autoridade ambiental GPRAM elaborou dados vetoriais integrados com o documento anual. Tal estudo, é entregue e esta de livre acesso, neste material os focos de incêndios são demarcados. Esses registros são associados a imagens multiespectrais dos satélites norte-americanos *Landsat*, que revisita a cada 16 dias uma mesma área da terra. A vinculação entre os arquivos vetoriais e as imagens proporciona uma visão ampla e detalhada dos incêndios na região, permitindo uma análise precisa e atualizada dos eventos relacionados ao fogo.

Primeiramente, é implementado um validador para a área 54, que está associada à base de dados *Indian Pines*. Vale ressaltar que esse validador não se trata apenas de um classificador de áreas, mas sim de um classificador de áreas rurais, que englobam diferentes tipos de terreno, como agricultura, florestas e rios. Nesse contexto, foram identificadas 57 classes distintas, com 224 valores espectrais diferentes por pixel.

Para realizar essa classificação, foi utilizado o algoritmo de SVM (Máquina de Vetor de Suporte) por meio do algoritmo SMO (*Sequential Minimal Optimization*), implementado em *Python* e aplicado à base de dados *Indian Pines*. Os resultados obtidos mostraram uma

medida-f e acurácia superiores a 90%. Isso demonstra a eficácia do classificador na tarefa de distinguir e categorizar corretamente as diferentes classes presentes na área estudada.

Após obtermos resultados bem-sucedidos com a aplicação da SVM, reconfiguramos o algoritmo para trabalhar com imagens multiespectrais do satélite *Landsat-8*. Utilizamos classes demarcadas como marcas de incêndio, extraídas do arquivo vetorial fornecido pelo GPRAM. Em seguida, realizamos uma sobreposição desse arquivo da autoridade na imagem de satélite. Essa sobreposição permitiu simular a detecção de marcas de incêndios por meio de classificadores.

Assim como nos testes anteriores, o algoritmo apresentou acurácias superiores a 90%. No entanto, a análise das áreas identificadas como marcas de incêndio pelo classificador treinado evidenciou uma limitação prática dessa abordagem. Embora a taxa de falsos positivos seja relativamente baixa, a presença de vários pixels isolados classificados como marca de incêndio pode resultar em um grande número de falsas classificações.

Uma possível solução para contornar esse problema seria utilizar outras informações para filtrar os falsos positivos. Por exemplo, após sobrepor os resultados com os registros rotulados do GPRAM, ficou claro que a alta reflectância vinculada a áreas com prédios foi considerada como marca de incêndio. Em trabalhos futuros, poderia-se considerar a exclusão das áreas com construções das regiões de potencial incêndio, utilizando o algoritmo em áreas não urbanas. Isso ajudaria a reduzir a ocorrência de falsos alarmes e melhorar a eficácia do sistema de detecção de marcas de incêndios.

Outra abordagem testada foi o uso de redes convolucionais com uso da rede pré treinada *ImageNet V2*. Para tal, são substituídas as últimas camadas de classificação pelas imagens de identificação de incêndio. Desta maneira, o classificador obteve acurácias de até 70% ao determinar as áreas de incêndio. Porém, ao realizar a validação, foram encontradas acurácias inferiores a 60% sendo uma característica de *Over-Fitting* por causa de uma translação entre as imagens de rótulos e as imagens de satélites nos dados usados no treinamento. Esse problema nos dados de treinamento, já corrigido no caso do treinamento da Máquina de Vetor de suporte (SVM), será corrigido também para treinamento das CNN, em um trabalho futuro, para avaliação da nova abordagem.

Este estudo comprovou de forma prática que é possível utilizar imagens multiespectrais do satélite *Landsat-8* para classificar as áreas de incêndio com uso de rótulos vetoriais sobrepostos a imagem. Assim, a abordagem é um primeiro passo para a automatização da geração de alarmes de incêndio em áreas específicas, com base em imagens de satélites. Porém, é necessário combinar a classificação automática gerada com dados já disponíveis sobre as estruturas ou tipos de áreas presentes, como no caso das construções em áreas povoadas. Isso permitirá filtrar falsos positivos em pequenas áreas dispersas, de forma a evitar alarmes desnecessários em áreas em que incêndios são improváveis ou cuja comunicação seria feita

de forma imediata por outros canais.

Como trabalho futuro, sugere-se portanto uma nova simulação dos dados da Rede Neurais Convolucionais (CNN) adicionando mais dados de entrada para a rede. Porém, é necessário ressaltar a necessidade de corrigir a translação, assim como realizado na Máquina de Vetor de suporte (SVM). Sugere-se ainda, filtrar as regiões de construção realizando treinamento somente em áreas de interesse do corpo de bombeiros. Assim, é possível realizar o passo seguinte, que seria um catálogo de áreas de incêndio predizendo suas futuras dimensões. Desta maneira, é possível desenvolver uma técnica ainda mais necessária para auxiliar o combate de incêndios em Brasília.

ABSTRACT

This research arose with the intention of developing a system capable of identifying fires based on fire images. However, as the project progressed, the thesis was modified to assist the GPRAM in developing an algorithm capable of delineating areas affected by fire in the Federal District region.

Thus, a model capable of delineating areas in which fires have occurred in the region of the Federal District was implemented and evaluated. Therefore, supervised identifiers based on artificial intelligence are used, and applied to images from the Landsat-8 satellite. In this way, correlations are established between the dates and spatial locations of the fires and the vector data produced by the GPRAM (Environmental Protection Group), which are publicly available. In summary, the process involves developing a system capable of demarcating a specific class, indicating its existence, or another class, indicating its non-existence, in order to train the classifier for fire-affected areas.

The GPRAM, established in 2010 and headquartered in Brasília, plays a fundamental role as an environmental authority in combating and preventing fires in the Federal District. Among its responsibilities, the GPRAM has a specialized tactical intelligence division responsible for transmitting an annual report on fire-affected areas. This document includes a remote sensing study with spatial data of fire-affected areas.

Through observation systems from the ground on specific dates, the environmental authority GPRAM elevates vector data integrated with the annual document. This study is delivered and made publicly available, and it marks the fire spots. These records are associated with multispectral images from the American Landsat satellites, which revisit the same area of land every 16 days. The linking between vector files and images provides a broad and detailed view of fires in the region, enabling precise and up-to-date analysis of fire-related events.

Firstly, a validator was implemented for area 54, which is associated with the Indian Pines database. It is worth noting that this validator is not only a classifier for areas but specifically a classifier for rural areas, encompassing different types of terrain, such as agriculture, forests, and rivers. In this context, 57 distinct classes were identified, with 224 different spectral values per pixel.

To perform this classification, the SVM (Support Vector Machine) algorithm was used through the SMO (Sequential Minimal Optimization) algorithm, implemented in Python, and applied to the Indian Pines database. The results obtained showed a measure of f-

score and accuracy of over 90%. This demonstrates the effectiveness of the classifier in the task of correctly distinguishing and categorizing different classes present in the study area.

After obtaining successful results with the application of SVM, the algorithm was reconfigured to work with multispectral images from the Landsat-8 satellite. The demarcated classes were used as fire marks, extracted from the vector file provided by the GPRAM. Then, this authority's file was overlaid on the satellite image. This overlay allowed simulation of the detection of fire marks through classifiers. As in previous tests, the algorithm showed accuracies above 90%. However, the analysis of the areas identified as fire marks by the trained classifier highlighted a practical limitation of this approach. Although the false positive rate is relatively low, the presence of several isolated pixels classified as fire marks can result in a large number of false classifications.

One possible solution to address this problem would be to use other information to filter out false positives. For example, after overlaying the results with the labeled records from the GPRAM, it became clear that the high reflectance associated with areas with buildings was considered a fire mark. In future works, the exclusion of areas with constructions from potential fire regions could be considered, using the algorithm in non-urban areas. This would help reduce the occurrence of false alarms and improve the effectiveness of the fire mark detection system.

Another tested approach was the use of convolutional networks using the pre-trained ImageNet V2 network. For this, the last classification layers were replaced by the fire identification images. In this way, the classifier achieved accuracies of up to 70% in determining fire areas. However, during validation, accuracies lower than 60% were found, indicating an Over-Fitting characteristic due to a translation between label images and satellite images in the training data. This problem in the training data, already corrected in the case of the Support Vector Machine (SVM) training, will also be corrected for the training of CNNs in future work to evaluate the new approach.

This study practically proved that it is possible to use multispectral images from the Landsat-8 satellite to classify fire areas using vector labels overlaid on the image. Thus, this approach is a first step towards automating the generation of fire alarms in specific areas based on satellite images. However, it is necessary to combine the automatically generated classification with existing data on the structures or types of areas present, such as in the case of buildings in populated areas. This will allow filtering out false positives in small scattered areas, to avoid unnecessary alarms in areas where fires are unlikely or where communication would be done immediately through other channels.

As a future work, it is suggested to conduct a new simulation of Convolutional Neural Network (CNN) data, adding more input data to the network. However, it is essential to highlight the need to correct the translation issue, as was done in the Support Vector Machine (SVM). Additionally, it is suggested to filter out construction regions by training only in areas of interest to the fire department. This way, it is possible to move to the next step, which would be a catalog of fire areas predicting their future dimensions. In this way, it is possible to develop an even more necessary technique to assist in fighting fires in Brasília.

SUMÁRIO

1	Introdução	1
1.1	Contextualização	1
1.2	Definição do Problema Científico e Proposta de Pesquisa	3
1.3	Objetivos	4
1.4	Estrutura da Monografia	5
2	Fundamentos e Estado-da-Arte em Classificação de Imagens de Satélite para Detecção de Incêndios	7
2.1	Observação da Terra e Processamento de Imagens Espaciais Disponíveis .	11
2.2	Aprendizado de máquina, técnicas e aplicações	18
3	Materiais e Métodos	28
3.1	Avaliação preliminar de Imagem de observação da terra Usando a Base <i>Indian Pines</i>	28
3.2	Implementação e Avaliação de Modelos para Detecção e Predição de Propagação de Queimadas com Base em Imagens Multi-Espectrais de Satélites	29
4	Resultados e discussões	35
4.1	Resultados preliminares de classificação de imagem Simulação <i>Indian Pines</i>	35
4.2	Resultados para Imagens Multi-Espectrais de Satélites	40
5	Conclusão e Trabalhos Futuros	51

LISTA DE TABELAS

2.1	Comparação de Bandas do <i>Landsat-8</i> e do <i>Landsat-9</i>	14
2.2	Comparativo Família <i>Landsat</i>	16
3.1	Parâmetros considerados para o treinamento	34
4.1	Comparação com e sem uso de Sub Amostragem	36
4.2	Quantidade de pixels relacionados ou não a incêndio	44
4.3	Teste de eficiência SVM	44
4.4	Teste com o uso da Máquina de Vetor de suporte (SVM)	46

LISTA DE FIGURAS

2.1	Comparativo entre Sistemas Caixa Branca e Caixa Preta	8
2.2	Representação sistema MISO associado a satélites.	10
2.3	Demonstração gráfica do incremento espectral em imagens.	11
2.4	Representação Hiper espectral do projeto AVARIS	12
2.5	Representação AVARIS	12
2.6	Esquemático dos sensores a bordo do <i>Landsat-8</i>	13
2.7	Análise Espectral <i>Landsat-8</i>	14
2.8	Exemplo de <i>ShapeFile</i> do dia 16/09/2019 produzido pelo GPRAM.	15
2.9	Melhoria Espacial Possível nos Satélites da Família <i>Landsat</i>	17
2.10	Comparações entre <i>kernel</i>	21
2.11	Reorganização nuvem de pontos com uso de SVM	22
2.12	Neurônios e organização	24
2.13	Exemplo de CNN aplicada no MNIST	25
2.14	Reconhecimento Facial com Uso de CNN	26
3.1	Acumulado Anual de Área queimada	30
3.2	Datas e Quantidades de Áreas Queimadas por Mês	31
4.1	Comparação de Acurácias.	36
4.2	Comparação de Precisão	37

4.3	Taxa de Falso positivo.	37
4.4	Taxa de verdadeiro Positivo	38
4.5	Comparação Medida F1	38
4.6	Comparação sensibilidade	39
4.7	Demonstração Visual da Área 54 e Demais Áreas	39
4.8	Demonstração da Utilização do Classificador sob Brasília	41
4.9	Reconstrução inicial	42
4.10	Adequação de Áreas e Identificação de Incêndio	43
4.11	Realização da SVM no Identificador de Área queimada	45
4.12	Área Intregue para a rede e Área real	46
4.13	Visualização de um incêndio	47
4.14	Teste com <i>Data Augmentation</i>	49
4.15	Teste com <i>Data Augmentation</i> e 50 Épocas	50

LISTA DE SÍMBOLOS, NOMENCLATURAS E ABREVIACÕES

- INPE* – Instituto Nacional de Pesquisa Espacial
- MISO* – Multi-Input-Single-Output
- CNN* – Convolutional Neural network (Rede neural convolucional)
- SVM* – Support Vector Machine (Máquina de Vetor de Suporte)
- AI* – Artificial Intelligence (Inteligência Artificial)
- GPRAM* – Grupamento de Proteção Ambiental
- SIG* – Sistema de informação geográfica
- GIS* – Nome em Inglês para SIG
- RBF* – Radial basis function (Função de Base Radial)
- UTC* – Tempo Universal Coordenado
- KERNEL* – Núcleo de um sistema computacional
- MSI* – Imagem Multi-espectral
- HSI* – Imagem hiper-espectral
- LANDSAT* – Família de Satélites Norte Americano de Observação da Terra
- NIR* – Infra Vermelho Próximo (Near Infra Red)
- FIR* – Infra Vermelho Distante (Far Infra Red)
- RGB* – Cores Aditivas Formadas por combinações de Vermelho, Verde e Azul
- USGS* – United States Geological Survey (Serviço Geológico dos Estados Unidos)
- NASA* – National Aeronautics and Space Administration (Administração Nacional da Aeronáutica e Espaço)
- AEB* – Agência Espacial Brasileira

1 INTRODUÇÃO

A Autoridade ambiental GPRAM ¹ disponibiliza, de livre acesso, todos os anos, um panorama de dados em formato vetorial de marcas de incêndio com as datas de fácil visualização em mapas [1]. O material demonstra o comportamento de incêndio ao longo das áreas do Distrito Federal. Portanto, o arquivo apresenta o avanço ou não das áreas de incêndio assim, com uma distribuição ao longo do ano, para poder planejar os combates de incêndio [1]. Porém, arquivos do mesmo tipo e com técnicas parecidas foram utilizados em estudos para poder identificar marcas de incêndio [2].

Identificadores de áreas podem fazer uso do estado da arte de processamento de imagem sondando métodos de identificação autônomos de incêndio [3]. Projetos na literatura fazem uso de classificadores que têm por base as imagens de satélite da família *Landsat* para este tipo de classificação.

1.1 Contextualização

Esse estudo foi possível graças ao auxílio do Grupamento de Proteção Ambiental que, para facilitar estudos científicos, cede dados de incêndios vinculados a satélites com um enfoque nos da família *Landsat*.

É importante ressaltar que o cerrado é o segundo maior bioma do Brasil e já chegou a ter 2,5 milhões de km^2 em extensão e hoje não passa de 1 milhão de km^2 [1]. Em adição, durante os períodos de junho a novembro ocorrem muitos incêndios na cidade de Brasília pois é o período de seca [1]. Por consequência, neste período, há uma maior incidência de queimadas [1].

Durante os anos de 2010 a 2020 os casos de incêndios aumentaram em áreas específicas do cerrado brasileiro, dentre elas as áreas de chapadas e planaltos [4]. Em adição, no ano de 2020 se comparado a 2019 houve uma elevação de 121 % dos dados de queimadas na região sudeste do cerrado brasileiro [5].

¹Grupamento de proteção ambiental de Brasília

As bases de dados BDQueimadas e Banco de Dados de Queimadas ² são, respectivamente, estudos de queimadas focado no cerrado e na amazônia[6]. Os sistemas só podem ser utilizados de forma remota, ou seja, com o uso de internet.

O corpo de bombeiros de Brasília estimula o estudo de técnicas para auxiliar o combate de incêndio nos períodos de junho a novembro. Um exemplo de sistema que ajudaria no combate a incêndios é a implementação de um identificador de caminho que será percorrido por uma queimada já iniciada [3]. Para realizar este objetivo o GPRAM ³ se disponibiliza a reunir com faculdades para poder desenvolver projetos de troca de conhecimentos [3]. Visto que existem artigos que exploram caminho a ser percorrido por uma queimada é possível desenvolver um projeto nesta área e comparar os dados com o que já existe [7].

Para auxiliar o GPRAM é possível vincular dados disponibilizados pela Autoridade ambiental com imagens de satélite, no caso, dos satélites da família *Landsat*, como o nome indica, são mais de um satélite e todos com resolução multiespectral, ou seja, uma mesma imagem pode ser vista por diferentes pontos visto que em cada intervalo de frequências certas características do terreno são evidenciadas [8].

Um exemplo de projeto utilizando técnicas de imagem multiespectral para evidenciar características foi desenvolvido pelo museu Louvre de 2008 na observação da mão de La Gioconda no quadro Monalisa de Leonardo da Vinci, em tal parte do quadro no domínio infravermelho próximo é possível evidenciar que o quadro foi repintado pelo pintor [9]. Visto que o domínio do infravermelho não é visível ao olho humano mas pode ser quantificado e transformado em níveis que podem ser representados em formato de imagem. As chamadas reflectâncias, ou seja, a intensidade de luz visível a cada pixel em um intervalo espectral [10].

No estudo feito pela Universidade de Purdue há uma observação de solo que consta com uma Imagem hiper espectral formada por 220 sensores, o conjunto de dados é conhecido como *Indian Pines* (pinheiros indianos) [11]. Este estudo é utilizado para testes de algoritmos de classificações [12].

Satélite de processamento de imagem é formado por sensores que disparam feixes de ondas eletromagnéticas com diferentes amplitudes gerando diferentes bandas de observação, dentre elas, a banda Infra Vermelho Próximo (NIR) e a banda de cores primárias Vermelha Verde e Azul (RGB), que são as bandas mais abundantes em satélites de imageamento, normalmente, sendo essas bandas as 4 primeiras de um satélite [13].

²Ambas realizadas pelo Instituto Nacional de Pesquisa e Estatística (INPE)

³Grupamento de Proteção Ambiental

Modelo científico é qualquer sistema que faz uso das técnicas científicas para reproduzir a realidade, por meio de simplificações [14]. Ao simplificar um sistema, o que é feito não é uma desqualificação dos fatos que circundam um acontecimento, mas sim, uma explicação que facilita a divulgação de acontecimentos [15]. Simplificações existem para diminuir a complexidade até o mínimo necessário mas não menos que isso [15].

Um modelo chamado preditivo é formado por análise prévia do objeto de interesse, com o intuito de prever como será a ocorrência futura de dados, tendo por base o que há de informação passada [16]. Em tal modalidade de sistema, são exploradas métricas para definir a fidedignidade com a qual o sistema será comprovado, dentre eles Acurácia, precisão e f-score [17]. Para tornar possível modelos com tal inteligência, são necessários algoritmos de aprendizado de máquina, adequados para a identificação de padrões, como os que ocorrem quando se há incêndios e é possível perceber a partir de imagens multi-espectrais de satélites .

O aumento da complexidade de aquisição e processamento de imagens, eleva o tempo de processamento para dias, meses ou anos [18]. *Compressive sensing* é um modelo capaz de reduzir tempos de processamento de meses para dias ou até horas, sem perder qualidade de imagem, em certos casos até trazendo mais qualidade [19]. A técnica referida foi testada em ressonância magnética e obteve bons resultados [18] .

1.2 Definição do Problema Científico e Proposta de Pesquisa

Visto que satélites que possuem sensores de geo-observação são importantes aliados no processo de proteção ambiental, havendo estudos com focos em detecção de queimadas, identificação do caminho a ser seguido pelo fogo, identificação de desmatamento ilegal, detecção de focos de pesquisa de drogas. Este trabalho propõe o desenvolvimento de modelos com base em aprendizado de máquina para analisar imagens multi-espectrais e seu uso em detecções de áreas com risco de incêndio, utilizando bases de livre acesso, softwares livres para observação da terra e softwares de programação. Este estudo propõe ainda vincular dados não utilizados para classificação mas que são considerados muito eficientes para desenvolver classificadores.

Já existe na literatura científica algumas abordagens para a validação automática de riscos [20]. No levantamento bibliográfico aqui realizado, não foram encontrados trabalhos aplicando estas técnicas ao cerrado de Brasília. Estes estudos prévios serão levados em consideração.

Este projeto propõe demonstrar, então, que, ao ser disponibilizado informações que

tornem possível a supervisão de um classificador autônomo, é possível separar classes de difícil classificação, tendo por base algoritmos de treinamento e teste.

1.3 Objetivos

- **Objetivo Geral**

Com o intuito de desenvolver um modelo em auxílio as autoridades florestais de Brasília, esta pesquisa sonda técnicas vinculadas a observação da terra que possam tornar possível a identificação de incêndios. Esta dissertação busca intuir, também, dentre os focos, quais possuem maior probabilidade de assumirem grandes proporções.

A proposta aqui presente é explorar a possibilidade de classificar a existência ou não de incêndio com o uso de inteligência artificial aliando o uso de softwares livres, imagens de satélite de livre acesso e arquivos cedidos por autoridades florestais.

O desenvolvimento de um classificador com as características acima tem por objetivo, então, ser uma pesquisa que sirva de base a estudos futuros de preditores de incêndios de grandes proporções.

- **Objetivo Específicos**

1. **Levantamento Teórico de Projetos Encaminhados na Área**

Com o intuito de desenvolver um classificador confiável, primeiramente esta pesquisa efetua um estudo dentre as produções já conhecidas a procura das que sejam correlatas ao tipo de imagem aqui empregado. A finalidade neste primeiro ponto é desenvolver um embasamento teórico para esta pesquisa produzindo, assim, um embasamento teórico extenso.

Nesta etapa foi realizado um levantamento de quais técnicas de aprendizado de máquina são utilizadas nos processamentos de imagens multi-espectrais com o intuito de procurar a existência de tais técnicas vinculadas ao cerrado.

2. **Desenvolver um Classificador de Áreas com uma Base Conhecida**

Após a fase de levantamento das bases teóricas, é realizado o primeiro sistema de classificação que tem, por intuito, o desenvolvimento de um modelo de identificador no qual será necessário utilizar uma base já conhecida. Com esta base de dados será empregado o uso de inteligência artificial para detectar uma dentre todas as classes.

Após realizar o treinamento da base, será realizado o teste com métricas de eficiências. É necessário vincular os resultados obtidos a fim de avaliar os classificadores.

3. Geração do Classificador de Incêndio

A seguir, é feito o treinamento do classificador supervisionado com o modelo selecionado para dados reais. Dados esses advindos de shape files das queimadas, do intervalo de 2011 a 2021, cedidos pelo GPRAM. O treinamento teve por objetivo indicar existência ou não de focos de incêndio.

Testado os tipos de casos, é efetuada uma validação do algoritmo por meio de testes de precisão, acurácia, especificidade e medida-f [17].

Após isso é gerado um relatório de eficiência do classificador.

4. Desenvolvimento de uma Segunda Técnica para Comparação

Um novo treinamento é realizado com uma técnica nova em cima dos dados cedidos pelo GPRAM. Será feito o estudo de eficiência do classificador.

5. Discussão dos Resultados Encontrados

Após desenvolver os classificadores, é elaborada uma breve conclusão que demonstra a eficiência dos classificadores, demonstrando quais são considerados mais e menos eficientes.

6. Busca de Vínculo Entre o Conhecimento Adquirido a Futuras Produções

Em seguida, serão discutidos os resultados obtidos demonstrando falhas e soluções às falhas, assim como possíveis atitudes para mitigar os casos de difícil identificação.

Com os conhecimentos adquiridos do identificador de marcas de incêndio, uma potencial análise subsequente é usar os dados adquiridos no identificador para poder, a partir dos focos atuais, predizer caminhos seguidos por queimada. Isso poderá potencialmente ser usado para indicar irradiar a regiões vizinhas.

1.4 Estrutura da Monografia

Esta dissertação é organizada seguindo as seguintes apresentações. No Capítulo 2 é apresentada uma introdução aos principais temas necessários para o desenvolvimento teórico desta monografia. É apresentado o estado-da-arte dentro de classificadores para aprendizado de máquina, as redes convolucionais (CNN), comparado a Máquina de vetor de suporte (SVM), que exige menor poder computacional e é resistente a desbalanceamento. Ainda no Capítulo 2 São apresentados os termos imagem Multi-Espectral e Hiper-Espectral, relacionando-os com sensoriamento remoto. final do capítulo 2 são apresentadas os Classificadores de imagem, assim como as bases de dados usada para testes de classificadores a *Indian Pines* e a base de dados em formato shape files cedida pelo GPRAM [11].

Em seguida, o Capítulo 3 empregada a teoria apresentada no capítulo 2 para os casos de classificação de Imagens [12].

Após serem apresentados cada um dos capítulos a cima, serão apresentadas as simulações discutindo os resultados encontrados no capítulo 4. As simulação fazem uso da base conhecida *Indian Pines* da base de dados de livre acesso divulgada pelo grupamento de proteção de Brasília e imagens de satélite *Landsat*, simulações de Máquina de Vetor de suporte (SVM) e Rede Neurais Convolucionais (CNN). O capítulo 5 é o último capítulo e informa as conclusões tiradas desta monografia, assim como o impacto dela e os futuros passos que serão tomados a partir da mesma.

2 FUNDAMENTOS E ESTADO-DA-ARTE EM CLASSIFICAÇÃO DE IMAGENS DE SATÉLITE PARA DETECÇÃO DE INCÊNDIOS

O início desta produção é voltado a determinação do modelo empregado. No qual, a discussão gira em torno dos modelos determinístico, que vincula as relações físicas para modelar um classificador e do estocástico que leve em conta variáveis probabilísticas como valor esperado para a classificação [21]. Portanto, são utilizados o material cedido Pelo GPRAM, as linguagens de programação e as imagens de livre acesso para efetuar a escolha. Em resumo, tais objetos de pesquisa conforme vistos em estudos prévios são vinculados a processos estocásticos para variáveis contínuas e vetores aleatórios para variáveis discretas [22].

Ao longo desta pesquisa será empregado um estudo probabilístico, em sistemas digitais. Por tal motivo, será utilizada a técnica chamada de caixa Preta. Tal técnica, pode ser vista no segundo modelo da figura 2.1. Em tal figura, o que seria associado a variáveis da natureza será substituído por variáveis aleatórias ao longo de um vetor aleatório. Em resumo, as variáveis probabilísticas são geradas a partir da correlação entre o arquivo *ShapeFile* e as imagens do satélite *Landsat-8*. podendo assim, gerar como saída do modelo um classificação as áreas de incêndio.

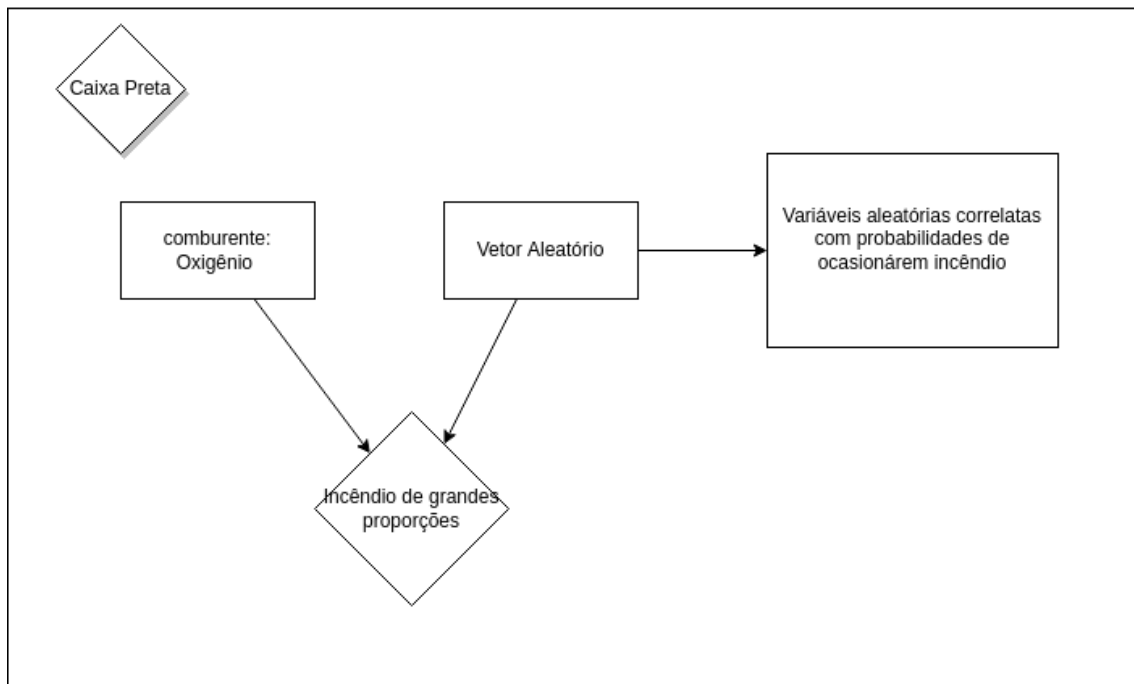
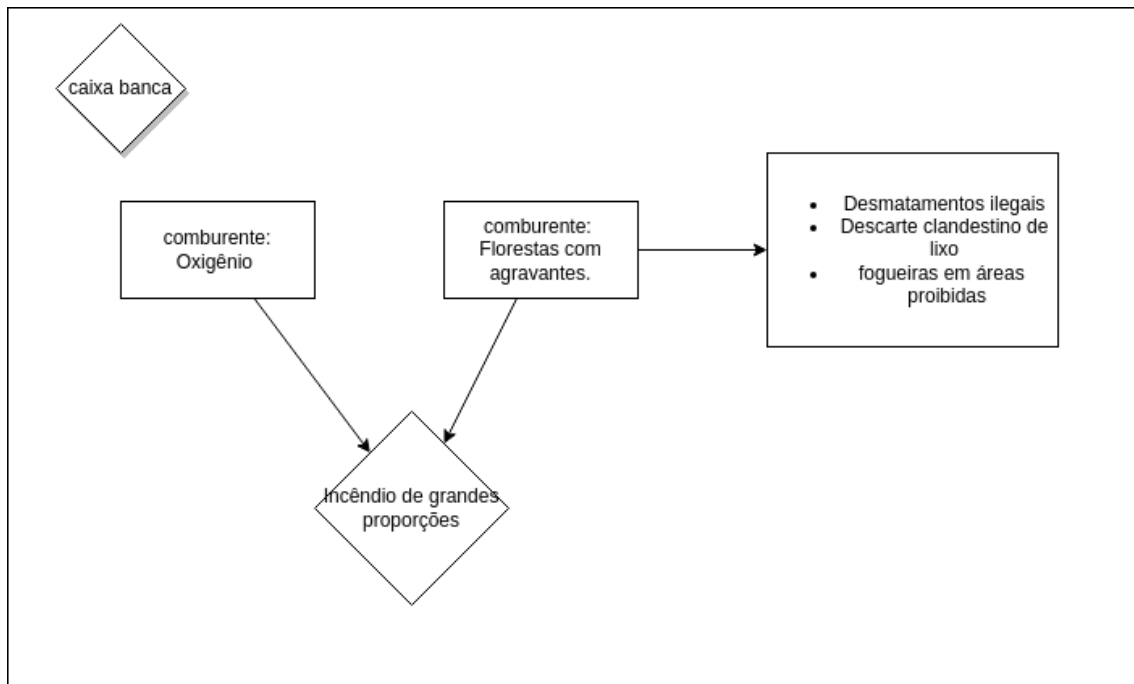


Figura 2.1. Comparativo entre Sistemas considerados Fenomenológicos e sistemas considerados estocásticos para o exemplo de um incêndio.

Utilizando as técnicas acima, é possível modelar o sistema no sentido de chamar o objetivo de caixa. Para isso, conforme as abordagens acima, existem duas caixas: a caixa branca e a caixa preta, que serão explicadas abaixo:

- **Caixa Branca**

O sistema que possui características físicas ou seja um sistema fenomenológico¹.

Portanto, este tipo de sistema busca entender a natureza do fenômeno para que possa modelar da melhor forma possível. Portanto, procurando intuir o mínimo possível [23]. Na figura 2.1 é possível ver no canto superior um exemplo já focado em incêndios em florestas.

- **Caixa Preta**

Este sistema é a ideia de puramente estocástico em que são entregues valores e se solicita ao sistema que intua valores de tal forma a produzir o máximo de eficiência nos valores encontrados [23].

Dessa forma, o modelo não enxerga o que tem ao seu redor como um sistema físico, mas sim como um sistema com erros que precisam ser reduzidos [23]. Na figura 2.1 é possível ver no canto inferior um exemplo já focado em incêndios em florestas.

Na figura 2.2, está claro que para reproduzir uma imagem tridimensional com marcas de incêndio, é necessário ter quatro imagens de entrada: três representando os tensores de luminância do visível e uma quarta imagem representando os recortes de áreas que sofreram queimadas. Isso caracteriza o sistema como capaz de receber diversas entradas para intuir uma única decisão se pertence ou não à classe de incêndio, sendo assim um sistema chamado *Multi-Input-Single-Output* (MISO), que em português seria "Múltiplas Entradas, Única Saída" [24].

Portanto, o intuito de desenvolver um classificador probabilístico de incêndio é vinculado ao *ShapeFile* de livre acesso da Autoridade de proteção ambiental GPRAM do Distrito Federal. Por tanto, tal representação vetorial é apresentada de forma didática na entrada 4 da figura 2.2.

Por fim, o sinal de saída da figura 2.2 representa a correlação entre as imagens de satélite e o *ShapeFile* que será entregue a um classificador de incêndios. O estado da arte de processamento de sinais estocásticos é vinculado diretamente a classificadores com uso de Máquina de Vetor de suporte (SVM) ou Rede Neurais Convolucionais (CNN) [25]. Por tanto, serão apresentados os dois modelos de classificadores autônomos. De tal forma, a

¹Sistema esse que leva em questão os acontecimentos físicos dentro de um sistema.

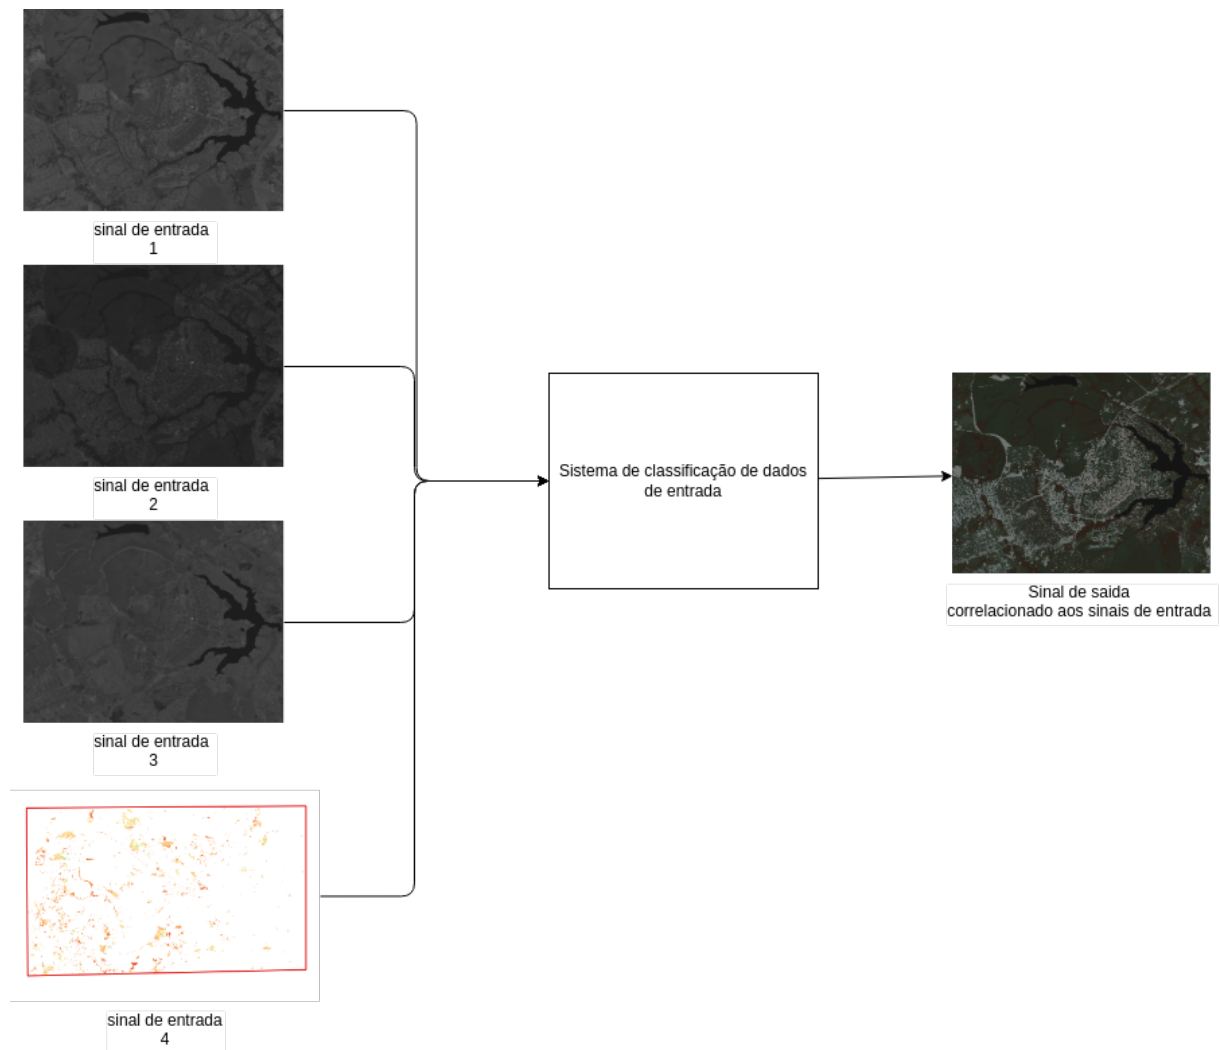


Figura 2.2. Este exemplo mostra como o modelo possui diversas entradas e somente uma saída que seria considerado um modelo do tipo MISO [24].

estudar métodos supervisionados que atuem na melhor identificação das características probabilísticas de um incêndio.

2.1 Observação da Terra e Processamento de Imagens Espaciais Disponíveis

- Imagem Multi-Espectral (MSI) e Imagem Hiper-Espectral (HSI)

Em se tratando de sistemas de observação da terra imagens podem ser classificadas quanto as suas resoluções espectrais. As imagens chamadas de multiespectral e as hiperespectrais, o que define elas é a quantidade de imagens amostradas por espectro conforme pode ser visto nas figuras 2.3a, 2.3c e 2.3b. Porém, para aumentar a quantidade de espectros, é necessário aumentar a resolução do sensor ou utilizar mais de um sensor ou um sensor com diversas bandas [10].

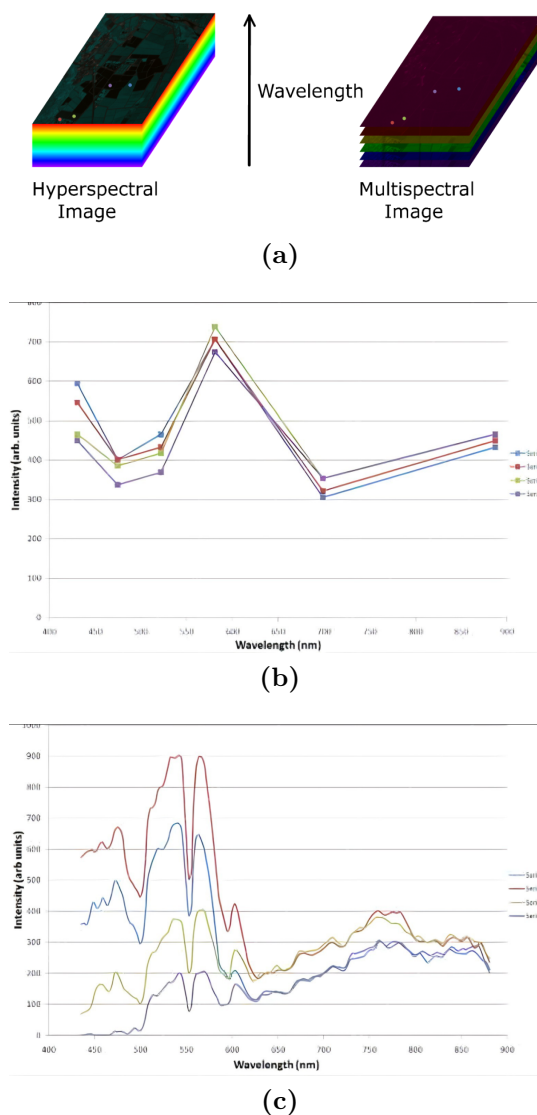


Figura 2.3. Comparativo entre imagens multiespectrais e hiperespectrais. Fonte *Spectral Imaging as a Potential Tool for Optical Sentinel Lymph Node Biopsies* [26]

O exemplo do sensor contendo diversas bandas pode ser visto na vista na figura 2.4. Em resumo, este sensor possui 224 bandas, sendo assim considerado um sensor hiperespectral (HSI). Em adição, o sistema foi desenvolvido pela Administração Nacional da Aeronáutica e Espaço (NASA).




Figura 2.4. Cubo representando a imagem hiperespectral da base de dados *Indian Pines* realizadas pelo sensor AVIRIS. Fonte: *A short survey of hyperspectral remote sensing applications in agriculture* [11] [27]

O mecanismo é acoplado a uma aeronave como pode ser visto na figura 2.5. Infelizmente, tais sensores são muito caros, sensíveis e pesados para serem levados como carga útil em foguetes. De tal forma, há uma maior complexidade ao entrar em órbita a bordo de satélites. Por tal motivo, é de mais fácil acesso Imagens Multiespectrais em satélite [10].




Figura 2.5. Representação do projeto de observação AVIRIS *Airborne Visible InfraRed Imaging Spectrometer*, tal como o sensor acoplado. Fonte: *A short survey of hyperspectral remote sensing applications in agriculture* [11] [27]

O satélite *Landsat-8* é o exemplo de satélite com dois sensores multiespectrais. Tais sensores, podem ser vistos na figura 2.6. Em resumo, o primeiro sensor chamado *Operational Land Imager (OLI)* possui resolução espacial que varia de 15 a 30 metros como pode ser visto na tabela 2.1. Em adição, o segundo sensor chamado *Thermal Infrared Sensor (TIRS)* tem resolução espacial de 100 metros e representa as bandas 10 e 11 do satélite *Landsat-8*.




Figura 2.6. Sensores *Landsat-8*. Fonte: *Landsat 8 (18) data users handbook [28]*

A resolução espectral dos sensores OLI e TIRS a bordo do satélite *Landsat-8* podem ser vista na figura 2.7. Tal figura, representa o intervalo de ondas aos quais é possível visualizar informação a partir de cada um dos sensores[28].

Tabela 2.1. Tabela de precisão espectral e espacial por bandas dos satélites *Landsat-8* e *Landsat-9* Fonte: *Landsat 9 (19) data users handbook [29]*

Número da Banda	Nome da banda	Precisão espectral média(nm)	Máxima resolução espacial em nadir (m)
1	Coastal / Aerosol	443	30
2	Azul	482	30
3	Verde	562	30
4	Vermelho	655	30
5	Infra vermelho Próximo(NIR)	865	30
6	Infra vermelho de onda curta 01 (SWIR1)	1610	30
7	Infra vermelho de onda curta 02 (SWIR2)	2200	30
8	Pan cromática	590	15
9	Cirrus	1375	30
10	Thermal 01	10900(Landsat8) 10800(Landsat9)	100
11	Thermal 02	12000	100




Figura 2.7. Comparativo entre frequências do satélite *Landsat-8*. Fonte: *Landsat 8 (18) data users handbook [28]*

- **Base de Dados Vetorial Utilizada**

O chamado *ShapeFile* é um arquivo vetorial responsável por demarcações em terrenos [3].

O objetivo deste arquivo é descrever em polígonos áreas de ocorrência de incêndio, demarcados por autoridades ambientais. O *ShapeFile* é referente a datas específicas e pode ser visto na figura 2.8. Na figura as áreas de branco são consideradas ocorrência de incêndio e as preto não.




Figura 2.8. Exemplo de *ShapeFile* do dia 16/09/2019 produzido pelo GPRAM.

- **Breve Introdução à Família de Satélites *Landsat***

Landsat é uma família de satélites Norte Americana de observação da terra propostos pela USGS ² em 1962 e lançado pela NASA ³ em 1972. Desde então, o sucesso do projeto foi tão grande que foram lançados mais 8 satélites [29]. Atualmente, a partir do projeto *Landsat*, é possível rever uma mesma área da terra em aproximadamente 8 dias isto pois, em 2021, o satélite *Landsat-9* entrou em órbita antes o período era de 16 dias, ou seja, o sucesso das missões *Landsat* vem aumentando a precisão temporal da constelação [29].

Um satélite pode ser considerado pertencente a uma família sem necessariamente ser considerado parte de uma constelação de satélite. Para que seja pertencente a uma constelação, é necessário que mais de um satélite da família esteja ativo e com a mesma funcionalidade. Portanto, conforme pode ser visto na tabela 2.2, 3 satélites estão ativos ou seja um caráter de constelação [29].

O uso da família *Landsat* como constelação, entre diversos motivos, é de suma importância para o *Change Detection* [28]. Em adição, esta técnica de observação da terra possibilita a percepção de alteração na regularidade de padrões. Ou seja, os

²USGS é o órgão norte americano responsável por Serviço Geológicos

³NASA é o órgão norte americano responsável pelo controle e lançamento de foguetes[30]


Tabela 2.2. histórico de uso da família *Landsat* com seus respectivos sensores e anos de funcionamento. Fonte: *Landsat 8 (18) data users handbook* [28].

Satélites	Sensores	Anos em funcionamento
Landsat 1	MSS, RBV	1972-1978
Landsat 2	MSS, RBV	1975-1983
Landsat 3	MSS, RBV	1978-1983
Landsat 4/D	MSS, TM	1982-1993
Landsat 5	MSS, TM	1984-2013
Landsat 6	ETM	1993* Failed
Landsat 7	ETM+	1999-Present
Landsat 8	OLI, TIRS	2013-Present
Landsat 9	OLI, TIRS	2021-Present

satélites são multiespectrais e têm resoluções temporal, espacial e espectral constante, como podem ser vistas na figura 2.7 [31]. Por tanto, ao observar imagens distintas é possível efetuar comparações. Tal comparação, é chamada de *Change Detection*.

O satélite *Landsat-8* eexplorado aqui neste documento. Tal satélite, gera principalmente dois tipos de produtos nas chamadas *Collection category* e são divididos em tempo real, nível 1 e nível 2. Por tanto, conforme o nível vai aumentando, correções são realizadas e as imagens se tornam mais nítida [28]. Em se tratando, de estudos científicos são mais utilizados os níveis um e dois.

Na figura 2.9 são vistas dois recortes do mesmo feixe. Porém, são vistas com níveis diferentes. Primeiramente, na figura 2.9a o nível é um. Já na figura 2.9b o nível considerado é o dois.



(a)



(b)

Figura 2.9. Na figura 2.9a temos um recorte de uma imagem do *Landsat-8* com Índice NDVI aplicado retirada no dia 31/08/2019 em nível 1 enquanto na figura 2.9b o recorte é do mesmo satélite, Índice e período só que em nível 2.

A figura 2.9b é mais recomendada a este estudo científicos [3]. Em tal recorte, é visível um melhor contraste e uma maior redução de ruídos. Assim, a comparação na figura 2.9 Demonstra de forma prática que conforme a teoria o nível 2 possui uma melhor visualização de contrastes [3].

2.2 Aprendizado de máquina, técnicas e aplicações

Aprendizado de máquina surgiu da teoria de aprendizado computacional, possui dentre seus fundamentos os classificadores que são modelo que treinam tomadas de decisões a partir de correlações entre bases de dados. Após, são testadas as eficiência das ações tomadas. Ou seja, os valores recebidos são classificados conforme uma relação probabilística com uma certa eficiência. Por fim será tomada uma atitude de classificar se uma amostra é pertencente ou não a uma classe [32].

Existem classificadores que treinam desde imagens ditas brutas ou seja sem processamento prévio, até imagens com características extraídas previamente, ambos têm seus prós e contras e serão explorados [33], [34].

O aprendizado de máquinas pode ser realizado por Supervisão. Para este método, se trabalha com informações previamente rotuladas. De tal forma, a testar eficiência de estimar a classificação das amostras [12]. A supervisão propriamente dita, ocorre quando um agente externo é usado para qualifica o classificador [35].

Dentre os classificadoras de imagem, dois se destacam para imagem de satélite. Primeiramente, os que fazem uso de redes convolucionais. Mas também, os que fazem uso Máquina de vetor de suporte [25]. Por tanto, Ambas são exploradas de forma a comparar o que é visto na teoria com os dados reais do GPRAM.

Primeiramente, é utilizado um classificador resistente a desbalanceamento visto que as queimadas ocorrem em parcelas pequenas e localizadas dos terrenos. ou seja, será entregue aos classificadores mais áreas de não ocorrência de incêndio. Por tal motivo, A Máquina de Vetor de suporte (SVM) será a primeira a ser testada [36]. Por fim, é implementada a Rede neural (CNN) nas imagens de incêndio. A fim de, comparar as eficiências de classificadores.

1. Métricas de Desempenho

As métricas de eficiência tornam capaz a medição de qualidade de um classificador[17]. O estudo probabilístico trás como objetivo identificar corretamente uma certa classe conforme pre requisitos de projeto. A simplificação necessária é em casos considerados pertencentes a uma classe chamados de verdadeiros e não pertencentes chamados de falsos [17].

Existem ainda os casos que são corretamente classificados, chamados de verdadeiros positivos e negativos [17]. Por consequência, existem os casos erroneamente classificados como pertencentes a uma classe, chamados Falsos positivos e negativos [17].

algumas simplificações serão tomadas a fim de facilitar na visualização de cada uma das métricas:

- Acurácia = A
- Precisão = P
- Positivo = Pos
- Negativo = Neg
- Sensibilidade = S
- Medida F = F_1
- Especificidade = E
- Taxa de Verdadeiro Positivo = v_{Pos}
- Verdadeiro Positivo = V_{Pos}
- Verdadeiro Negativo = V_{Neg}
- Falso Positivo = F_{Pos}
- Falso Negativo = F_{Neg}
- Taxa de Falso Positivo = f_{Pos}

A seguir serão apresentadas as métricas utilizadas neste trabalho para validação da eficiência dos classificadores:

- **Acurácia (A)**

A primeira métrica aqui referida é a acurácia. Esta métrica, indica dentre todos os casos quantos realmente foram classificados corretamente [17]. Ou seja, esta métrica indica a quantidade de predições precisas que ocorrem [17].

$$A = \frac{V_{Pos} + V_{Neg}}{Pos + Neg} \quad (2.1)$$

- **Precisão (P)**

É necessário reparar que a eficiência do sistema será proporcional as corretamente identificações da classe chamada positiva [17].

Portanto, a precisão existe para preencher esta lacuna [17]. Representando dentre as previsões positivas feitas pelo modelo quais são realmente consideradas corretas [17].

$$P = \frac{V_{Pos}}{V_{Pos} + F_{Pos}}, \quad (2.2)$$

- **Sensibilidade (S)**

Para esta dissertação foi analisado um sistema desbalanceado [17]. Ou seja, existe um caso majoritário e um minoritário [17]. No qual, os positivos e negativos são os casos minoritário e majoritário respectivamente [17].

As métricas de precisão e acurácia não consideram levam em consideração portanto foram necessárias serem adicionadas mais métricas que levem em consideração o desbalanceamento [17]. então é possível levar em consideração assim de todos os verdadeiros quantos realmente são considerados verdadeiros [17].

$$S = v_{\dot{P}os} = \frac{V_{Pos}}{P_{Os}} \quad (2.3)$$

- **Medida F (F_1)**

Ao combinar a sensibilidade com a precisão a medida F adicina leva em consideração o desbalanceamento [17]. Sendo uma métrica de extrema importância para o processo de cálculo de eficiência [17].

$$F_1 = \frac{2}{\frac{1}{S} \times \frac{1}{P}}, \quad (2.4)$$

- **Taxa de Falso Positivo ($f_{\dot{P}os}$)**

É também chamada de taxa de falso alarme [17]. Pois, está vinculada diretamente ao que foi classificado como Positivo e que na verdade é negativo [17]. Portanto, demonstra o erro com relação ao caso negativo [17].

$$f_{\dot{P}os} = \frac{F_{Pos}}{Neg} \quad (2.5)$$

- **Especificidade (E)**

Para medir o desbalanceamento real e o tanto que ele afeta o sistema existe a especificidade [17].

$$E = \frac{V_{Pos}}{F_{Pos} + T_{Neg}} = 1 - f_{\dot{P}os}, \quad (2.6)$$

2. Máquina de Vetor de Suporte

A teoria necessária para o desenvolvimento de máquina de vetores de suporte surgiu em 1963 para resolver o problema matemático de pontos de difícil determinação de valores nos quais atuam os vetores de suporte que podem ser visto na figura 2.10 [36]. Porém, o primeiro algoritmo foi proposto em meados de 1992, e propõe um algoritmo capaz de diferenciar pontos de transição que têm caráter dúbio, como pode ser visto na figura 2.10 [37]

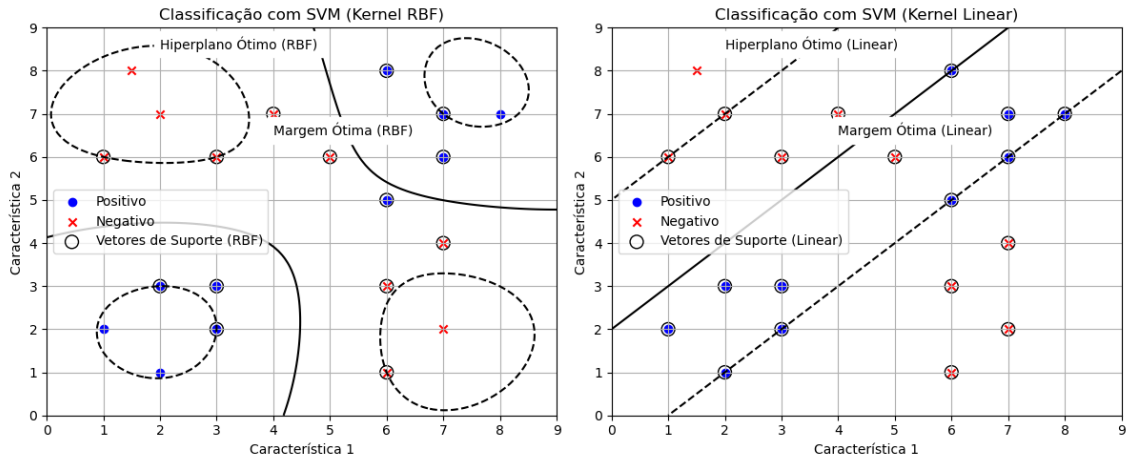



Figura 2.10. Exemplo de um classificadores sob o mesmo ponto porem com aproximação por *kernel* diferente [37].


Por tratar dos pontos de difícil classificação, como pode ser visto na representação da figura 2.10, a Máquina de Vetor de suporte (SVM) atua em pontos de caráter dúbio como os vistos na figura 2.11a. Portanto, ao levar a um plano de ordem diferente do atual é mais fácil separar classes como pode ser visto na figura 2.11.

Para Funções de complexidade alta. Os pontos que antes eram considerados de difícil classificação são modelados em uma ordem superior a atual em um novo plano [34].

Os pontos de difícil classificação seriam onde o vetores de suporte irá atuar [34]. Para isso, são implementadas técnicas de álgebra linear. Dentre as técnicas, o produto interno também chamado de *Kernel*.



(a)



(b)

Figura 2.11. Nuvens de pontos desordenadas 2.11a, nuvem de pontos reordenadas a partir de uma SVM 4.11b

O *kernel* é o produto interno entre o resultado da função de transformação aplicada em um vetor de características de entrada. Conforme pode ser visto na representação algébrica,

$$\begin{bmatrix} x_0 & x_1 & x_0 & \dots \end{bmatrix} \times \begin{bmatrix} a_0 & a_1 & a_2 & a_3 & a_4 & a_5 & a_6 \\ b_0 & b_1 & b_2 & b_3 & b_4 & b_5 & b_6 \\ c_0 & c_1 & c_2 & c_3 & c_4 & c_5 & c_6 \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & & & & \cdot & \cdot \\ \cdot & & & & & & \cdot \end{bmatrix} = \begin{bmatrix} K_{rbf0} \\ K_{rbf1} \\ K_{rbf2} \\ K_{rbf3} \\ K_{rbf4} \\ K_{rbf5} \\ K_{rbf6} \end{bmatrix}^T, \quad (2.7)$$

$$\text{vetor de carcter.} \times \text{character. de entrada} = \text{kernel}. \quad (2.8)$$

Na literatura, o desenvolvimento de identificadores em imagens desbalanceadas de satélite vinculadas a Máquina de Vetor de suporte (SVM) Apresentaram resultados promissores ao serem vinculados ao *kernel*[7] do tipo *radial basis function*(*RBF*). Dado pela função:

$$f(x, y) = \alpha \exp \left[-\frac{(x - y)^2}{2\gamma^2} \right], \quad (2.9)$$

onde α e γ podem ser arbitrados previamente ao treinamento. Esta *kernel*, surge de uma função de gauss. Amplamente utilizado pois é sabido que, ao entrar dados manipulados sobre uma função exponencial, a saída do sistema também será pautado pela mesma exponencial somente com alteração de amplitude [38].

3. Redes Neurais Convolucionais

Dentro do estudo de processamento de sinais por classificador em imagens de satélite existem as Redes Neuro Convolucionais(CNN). As redes, são Consideradas o Estado da Arte em classificadores do tipo [33].

Este classificador funciona através de camadas [33]. Cada camada possui diversos sistemas ativos chamados Neurônios que podem ser vistos na figura 2.12.

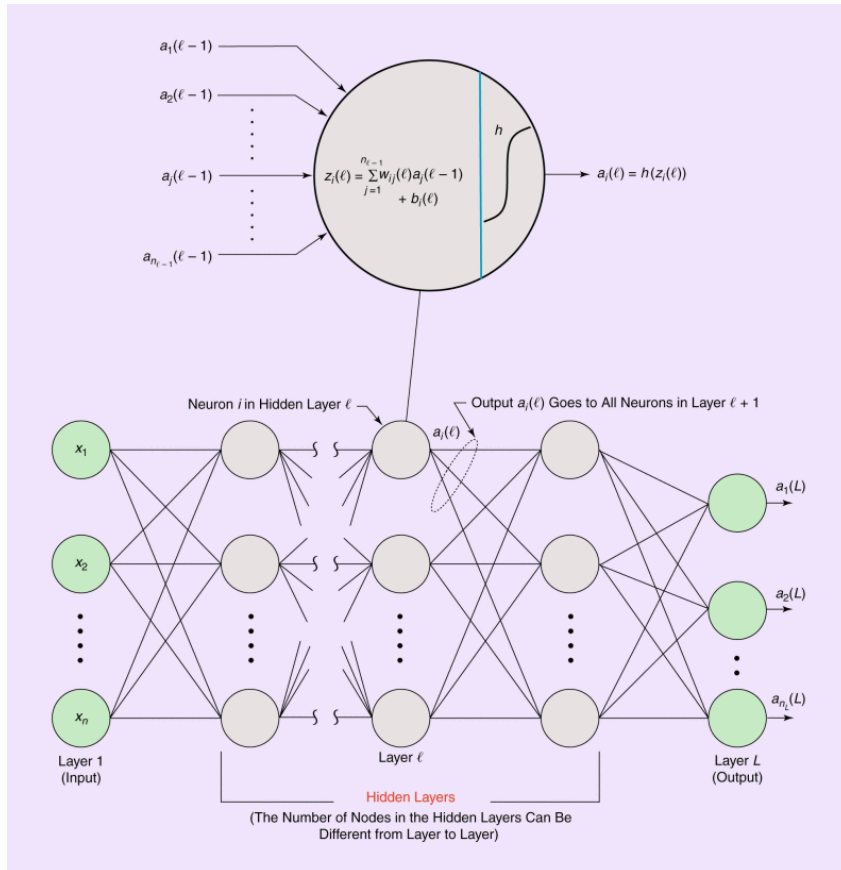


Figura 2.12. Organização dos neurônios de uma rede convolucional. Fonte *Deep Convolutional Neural Networks Lecture Notes* [33].

Cada um dos sistemas ativos representa a convolução de um filtro com um objeto a ser classificado. São geradas múltipla convoluções por camada. Após tais convoluções o sistema reduz o tamanho das imagens através de uma técnica chamada *pooling*. Apos reduzir as imagens, o resultado recebe uma convolução por um novo filtros em uma nova camada. Enquanto houverem camadas será realizado o processo de convolução seguido por *pooling*.

Ao fim, será atribuída a probabilidade de que uma imagem pertença a uma classe. Este esquemático pode ser visualizado na figura 2.13.

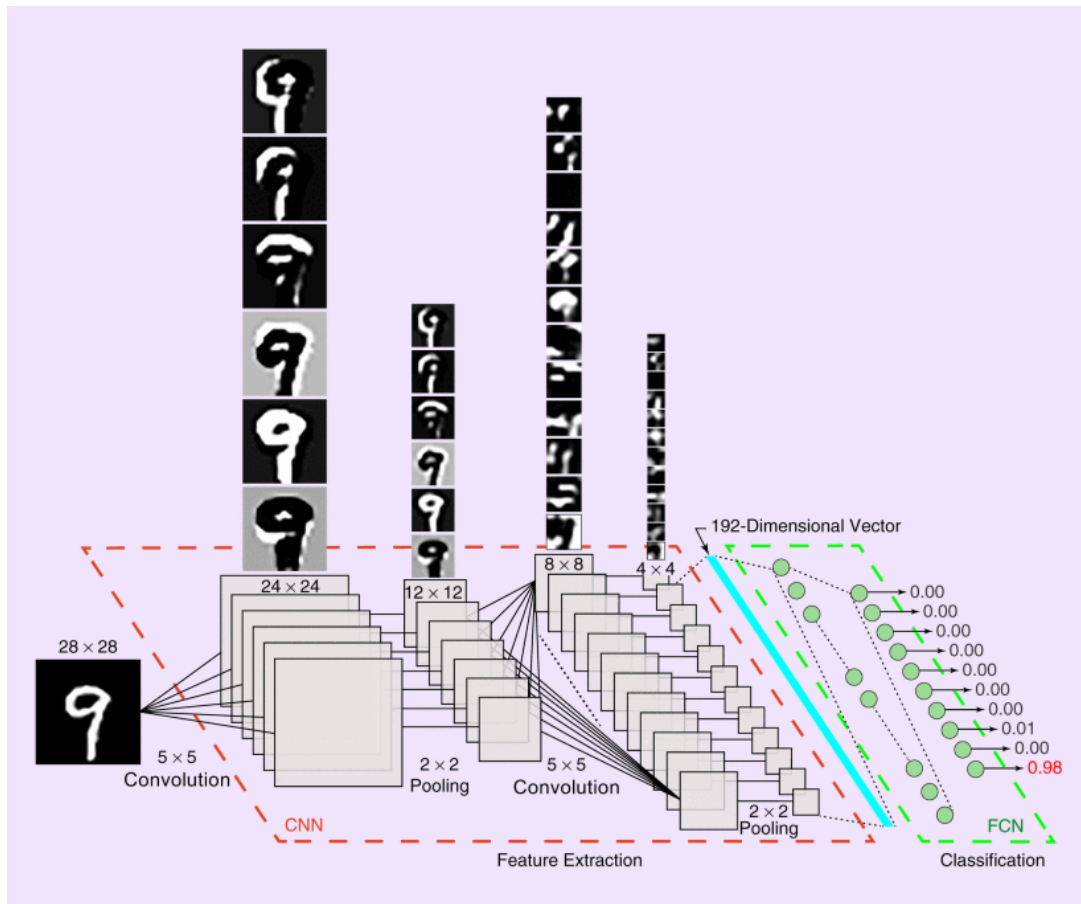


Figura 2.13. Representação de um identificador de texto conforme Redes Neurais. Fonte *Deep Convolutional Neural Networks Lecture Notes* [33].

Uma realização ocorre quando temos um esquemático completo da figura 2.13. O diferencial da Rede Neural Convolutiva (CNN) ocorre através de minimização de uma função intitulada função erro [12]. Tal função, consiste em realizar um esquemático completo da 2.13, comparar com os resultados e testar novamente. O reteste será feito alterando os valores dos filtros procurando aumentar a acurácia do sistema.

A figura 2.14 representa uma Rede Neural Convolutacional (CNN) com o intuito de observar um dos olhos da menina em uma foto. Para isso, são manipulados diferentes filtros. O intuito é selecionar um quesito que realce o olho. para tal será realizado um mapa de características. Por tanto, através de uma técnica chamada de *Back Propagation* é possível interagir as primeiras com as últimas camadas [39]. Com o intuito de selecionar os neurônios que melhor classificão a imagem.

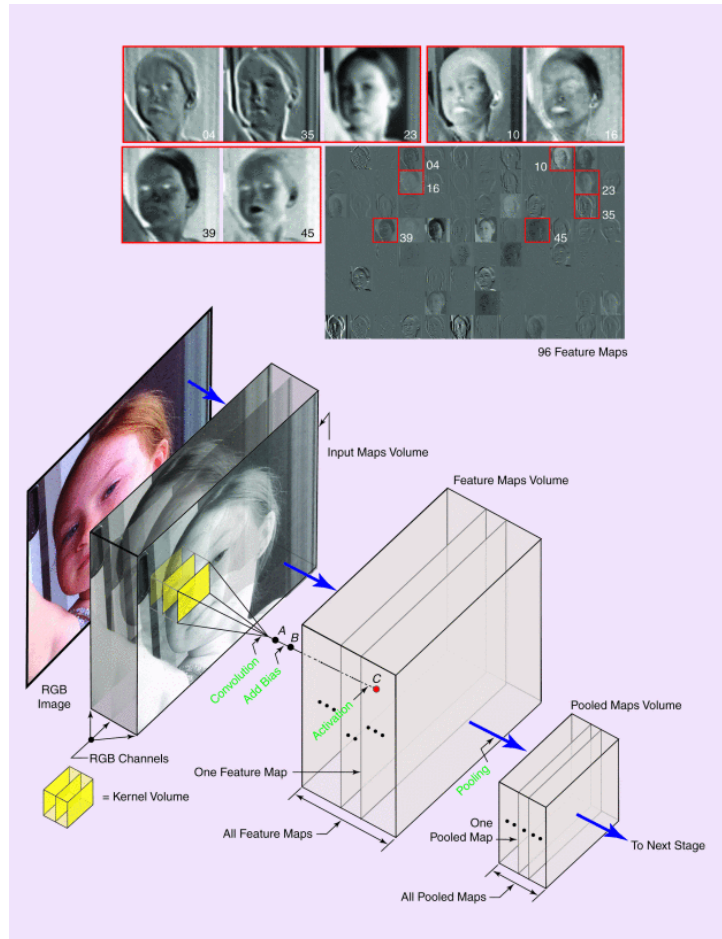


Figura 2.14. Esquemático de uma rede neural convolutacional. Fonte: *Deep Convolutional Neural Networks Lecture Notes* [33].

Por fim, o Mapa de características terá o intuito de realçar somente a área de interesse. Terá de ser testado em outras imagens para poder garantir a capacidade de identificação de uma área de interesse.

No projeto de uma Rede Neural Convolutacional (CNN) existem três passos necessários para validação de eficiência de um projeto. Primeiramente, é necessário treinar uma Rede para que ela seja capaz de identificar os requisitos de projeto. Em seguida, os valores têm que ser válidos de tal forma a evitar o chamado sobre-treino ⁴, também chamado de descolamento. Portanto uma porcentagem dos dados

⁴o termo em inglês é *Overfit*

é separa para treinamento e realiza nelas testes buscando uma validação dos dados encontrados [33].

3 MATERIAIS E MÉTODOS

3.1 Avaliação preliminar de Imagem de observação da terra Usando a Base *Indian Pines*

A base *Indian Pines* Foi escolhida para o desenvolvimento do primeiro algoritmo. Tem de ser avaliada quais as dimensões da imagem gerada, assim como avaliar se a imagem possui um arquivo externo de alvos. A escolha de uma região que tenha pouca incidência é crucial visto que, em casos de imagens de satélites, a área de queimada é menor que uma área inteira de observação.

- **Experimentos Computacionais com uso da Base *Indian Pines***

A base de dados *Indian Pines* possui resolução espectral de 224 bandas. Ou seja, 224 subdivisões conforme visto na figura 2.4. Portanto, Tendo por base a ampla resolução espectral será realizada, como primeira abordagem, uma análise do tipo pixel a pixel.

Como existem 57 classes, dentro do arquivo, é necessário escolhida uma área que possua certo desbalanceamento. No caso, a área 54 representa rio e será a escolhida por ter grande desbalanceamento. Por esse motivo, é necessário sub amostrar os casos majoritários a fim de primar pelo equilíbrio do treinamento.

Para testar o desbalanceamento e como ele interage com o sistema, foram elaborados quatro cenários no treinamento com vetores de suporte.

1. Primeiro Cenário

Treinamento e teste com a quantidade de amostras totais disponibilizadas. Os resultados devem ser testados por métricas [17]. Neste caso será avaliada a eficiência do classificador perante a alto nível de desbalanceamento.

2. Segundo Cenário

Sub amostrar os casos majoritários em 90 % e realizar treinamento e teste. os resultados têm de ser analisados e testados a fim de comprovar ou não a

eficiência em identificar áreas de uma imagens de satélite. Em adição, como ocorreu subamostragem dos casos majoritários em ambos os casos é realizado o segundo cenário a fim de evitar o chamado *overfit* [12].

3. Terceiro Cenário

Sub amostrar os casos majoritários em 90 % e realizar treinamento. Porem, realizar o teste com a porcentagem original de negativos. Uma observação interessante é que esse cenário ocorrerá para Máquina de Vetor de suporte (SVM) [16].

Portanto, visto que é realizada a chamada validação no caso das Rede Neurais Convolucionais (CNN). Desta forma, para as redes, é concluível a não necessidade deste cenário.

4. Quarto Cenário

Treinamento com o total de casos negativos e testado com 90 % do valor original de negativos, esse caso se prova ineficiente para representações de imagens de satélite, visto que o comportamento será viciado da máquina treinada [12].

3.2 Implementação e Avaliação de Modelos para Detecção e Predição de Propagação de Queimadas com Base em Imagens Multi-Espectrais de Satélites

Para este estudo foi necessário obter as datas exatas da geração de polígonos.

Dentre os satélites da família *Landsat*, foi escolhido o satélite *Landsat-8* para este projeto pois, como pode ser visto no gráfico: 3.1, em 2019, segundo o arquivo cedido pelo GPRAM, 400000 pixels contém dados referentes a incêndio. Dessa forma utilizando o material enviado pelo GPRAM e alterando de pixels para área em hectares foi possível perceber que os anos de 2011, 2014, 2019 e 2021 foram os com maiores incêndios conforme pode ser visto no gráfico: 3.1.

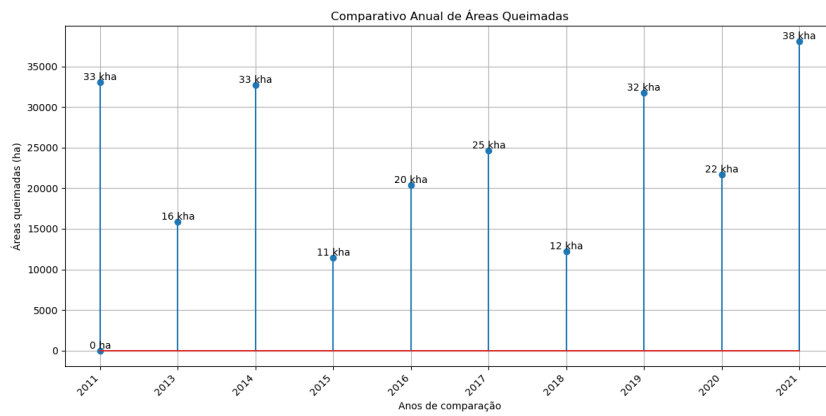


Figura 3.1. Acumulado anual de Área queimada. fonte: *Camadas Vetoriais (GPRAM)* [40].

Segundo o gráfico 3.1, a quantidade de ocorrências de incêndio foi superior no ano de 2021 se comparada a 2019. Porém em 2019 há um padrão que se repete tanto nos anos de 2014 quanto no ano de 2011. Além disso, o ano de 2019 é o último ano que possui dados de datas e meses no arquivo de base de dados.

Embora segundo o gráfico: 3.2 o ano de 2011 tenha tido muito incêndio na mesma data foi escolhido o ano de 2019 pois em 2011 não existia o *Landsat-8*. Portanto, Para este projeto foi escolhido o ano de 2019 para efetuar os treinamentos das Rede Neurais Convolucionais (CNN) e da Máquina de Vetor de suporte (SVM).

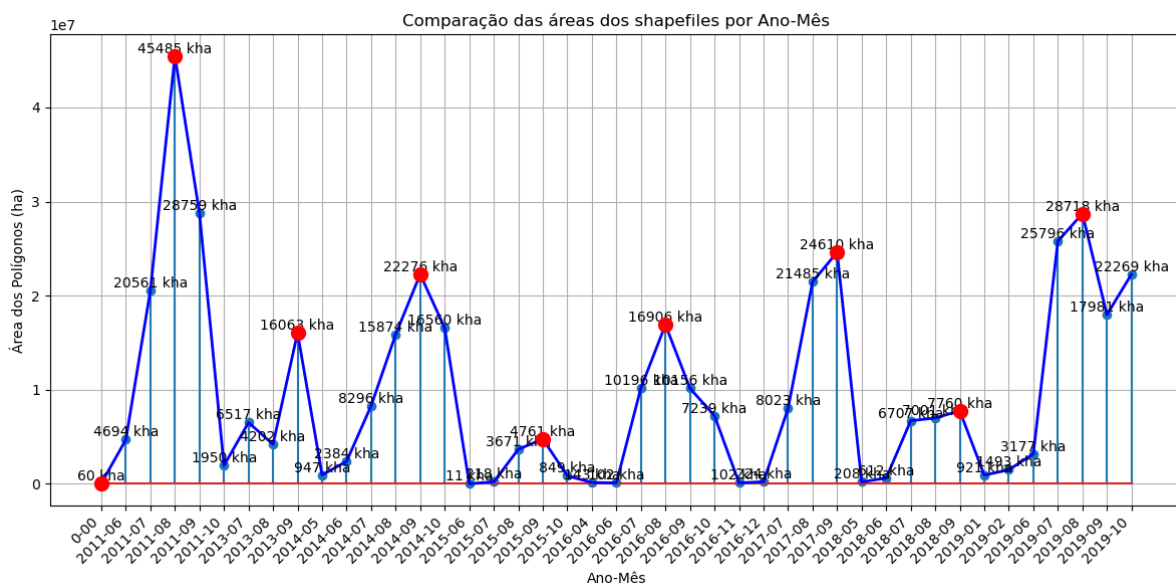


Figura 3.2. Comparação mensal entre áreas queimadas de 2011 a 2019 [40].

- **Avaliação de Desempenho de um Classificador de Incêndio com base em Máquina de Vetor de Suporte Aplicada à Imagens Multiespectrais de Satélite**

Utilizando as imagens multi-espectrais recortadas com o uso do QGIS e a máscara de identificação de incêndio, processada no *Python* e iniciada a classificação com uso de uma Máquina de Vetor de suporte (SVM).

Assim como no projeto *Indian Pines*, o teste da Máquina de Vetor de suporte (SVM) será realizado em *Python* e também faz uso de um classificador pixel a pixel.

O caminho seguido na modelagem de treinamento e teste da Máquina de Vetor de suporte (SVM) começa ao separarmos pixels considerados como contendo incêndio em um vetor e pixels considerados como não contendo incêndio em outro vetor. Conforme demonstrado na literatura, uma proporção que tem boa eficiência em identificadores é de 70% para treinamento e 30% para teste e, portanto, é assumida tal proporção no classificador aqui desenvolvido [41].

A Máquina de Vetor de suporte (SVM), assim como no classificador do *Indian Pines*, efetua classificação pixel a pixel, portanto, visto que neste tipo de classificação é possível considerar ou não efeitos da vizinhança em um pixel e visto que foram consideradas 7 bandas espectrais do satélite *Landsat-8*, é desconsiderada, a priori, o efeito de vizinhança. São coletados os pixels sem levar em conta as posições espaciais, apenas os valores em cada uma das bandas e um arquivo indicando se o mesmo retrata ocorrência ou não de incêndio. Esse material é enviado na entrada de um classificador Máquina de Vetor de suporte (SVM) com kernel RBF para que seja realizado um treinamento. Após a realização do treinamento, o arquivo que corresponde a rede treinamento é salvo para que os testes sejam realizados.

O teste é realizado com pixels diferentes dos de treinamento para evitar a possibilidade de dados enviesados, ou seja, dados tendenciosos [17]. Com o uso da rede treinada, os dados de teste são anexados para aferir a eficiência do modelo. Para aferir a eficiência são utilizadas as métricas de acurácia, precisão, medida-f e *recall* [17].

Para a utilização da máquina de vetor de suporte em ambiente *python* foi empregado o uso do algoritmo de treinamento *Sequention minimum Optmization*. O *kernel* utilizado é o RBF, foram normalizadas as entradas para que fosse possível utilizar a função γ padrão.

Em caso de resultados previamente satisfatórios, é realizado um teste do classificador em cima da imagem considerando as coordenadas do sistema para plotar o que o sistema considerou como incêndio ou não para ser comparado de forma visual com o que de fato foi identificado como incêndio ou não.

- **Avaliação de Desempenho de um Classificador de Incêndio com Base em Redes Neurais Convolucionais Aplicada a Imagens Multiespectrais de Satélite**

Após familiarização com classificadores realizada com o uso da base de dados *Indian Pines*, é realizado um teste com uso das redes convolucionais neurais.

O teste começa separando a área de interesse em áreas menores de 65 por 65 pixels. Essas áreas são comparadas com o shape file dos mesmos pontos, também recortada em um retângulo de 65 por 65 pixels. Estas novas imagens então são comparadas com o *ShapeFile* que indica incêndio com o valor 1.

As imagens que contêm incêndio, então, são enviadas a uma pasta e as que não contêm são enviadas a outra pasta.

Com as imagens separadas em pastas, é separada uma certa porcentagem das imagens para treinamento e outra porcentagem para teste, armazenando em quatro pastas: duas referentes ao treinamento e as outras referentes ao teste. É necessário separar a mesma quantidade de imagens com incêndio e não contendo, tanto para o caso de treinamento quanto para o caso de testes, para que o desbalanceamento não cause interferência nos resultados.

Com as imagens separadas em pastas, é selecionada a pasta de treinamento e os arquivos contidos nelas serão usados para treinar uma Rede Neurais Convolucionais (CNN). É importante ressaltar que este método possui uma validação então é possível utilizar uma Rede Neurais Convolucionais (CNN) inicialmente só com validação [33].

A rede utilizada é pré-treinada com o uso do modelo *MobileNet V2*, que é uma arquitetura relativamente pequena comparada a muitos modelos pré-treinados existentes, o que viabiliza o posterior ajuste fino com relativamente poucos dados de treinamento, o que é uma das limitações que existem neste projeto. A *MobileNet V2* foi desenvolvida pelo google com treinamento a partir da base de dados *ImageNet* formado por 2,4M de imagens com 1000 classes [42]. Para este teste serão retirados 115232 parâmetros para desenvolver um identificador com 4 variáveis treináveis. Para tornar possível a substituição dos últimos parâmetros e para que eles sejam considerados treináveis, será utilizado o ativador *ReLU* por ser mais eficiente computacionalmente por zerar os valores negativos das saídas das camadas anteriores 3.1.

Em seguida, para simplificar uma camada atual com uso da camada anterior, é utilizada a técnica de *Max Pooling* que escolhe a cada 4 pixels o maior e substitui

Tabela 3.1. Parâmetros considerados para o treinamento

Total de camadas: 2,373,216
Parâmetros treináveis: 115,232
Parâmetros não treináveis: 2,257,984

Numero de variáveis treináveis = 4

os 4 píxeis por somente um, como pode ser visto na seguinte demonstração:

$$\begin{bmatrix} 1 & 2 & 1 & 4 \\ 3 & 4 & 2 & 3 \\ 4 & 2 & 1 & 2 \\ 3 & 1 & 4 & 3 \end{bmatrix} \rightarrow \left[\begin{bmatrix} 1 & 2 \\ 3 & 4 \\ 4 & 2 \\ 3 & 1 \end{bmatrix} \quad \begin{bmatrix} 1 & 4 \\ 2 & 3 \\ 1 & 2 \\ 4 & 3 \end{bmatrix} \right] \xrightarrow{MaxPooling} \begin{bmatrix} 4 & 4 \\ 4 & 4 \end{bmatrix} \quad (3.1)$$

. Visto que este sistema atua em camadas pré-treinadas, nosso sistema já irá começar em um max-pooling e, por isso, temos que definir inicialmente as entradas da rede com no mínimo a dimensão de 65×65 como pode ser visto na figura 4.12.

4 RESULTADOS E DISCUSSÕES

4.1 Resultados preliminares de classificação de imagem Simulação *Indian Pines*

Neste caso, visto que há um amplo desbalanceamento no qual há 1641182 amostras das quais 3110 são consideradas positivas, ou seja, dentre todas as amostras aqui consideradas, 0.189 % são positivas. O modelo utilizou vetores de suportes pois, em testes prévios, se mostrou um bom modelo frente a desbalanceamento [7].

O treinamento da rede utilizada nos cenários 1 e 4 é a rede que demorou um maior tempo para seu desenvolvimento, cerca de 15 horas em um notebook convencional. Enquanto o resultado dos cenários 2 e 3 demorou menos de 1 hora. Porém, as métricas são afetadas pela subamostragem. Os resultados são comparados nas figuras 4.1 e 4.2.

Os resultados das eficiências dos gráficos estão representados nos gráficos 4.3,4.4 e 4.5 testes estes simulados com uma permutação aleatória dos pontos repetidos 3 vezes.

Com base na tabela: 4.1 que representa as métricas de acurácia precisão e Medida F 2.4, Acurácia 2.1, Precisão 2.2 e sensibilidade 2.3, apresentadas de forma gráfica, podemos perceber que o valor de precisão informam que, dentre os valores considerados positivos, a maior parte é considerada corretamente como positiva. Neste caso, devido ao fato de não existirem falsos positivos, é convencionada uma precisão de 100 % mas, visto que temos uma acurácia de 99.9 %, é dando um peso a beta de 0,5 e podemos perceber que a medida f tem um valor de cerca de 97 %.

Para este teste foram realizadas simulações com desbalanceamento com cerca de 1 % dos valores dados a casos positivos e 99 % dados aos casos negativos. Mesmo com tamanhas discrepâncias, as métricas de acurácia, precisão e medida f ficaram todas a cima de 90 % como pode ser visto no gráfico 4.1.

	Sub amostrado	Original
Taxa de Verdadeiro Positivo (%)	94.3	94.3
Taxa de Falso Positivo (%)	0.00	30.9
Precisão (%)	100	50.4
Acurácia (%)	99.9	99.7
Sensibilidade (%)	94.3	94.3
Medida F1 (%)	97.1	83.8

Tabela 4.1. Média das métricas para a subamostragem do caso majoritário e o desbalanceado.

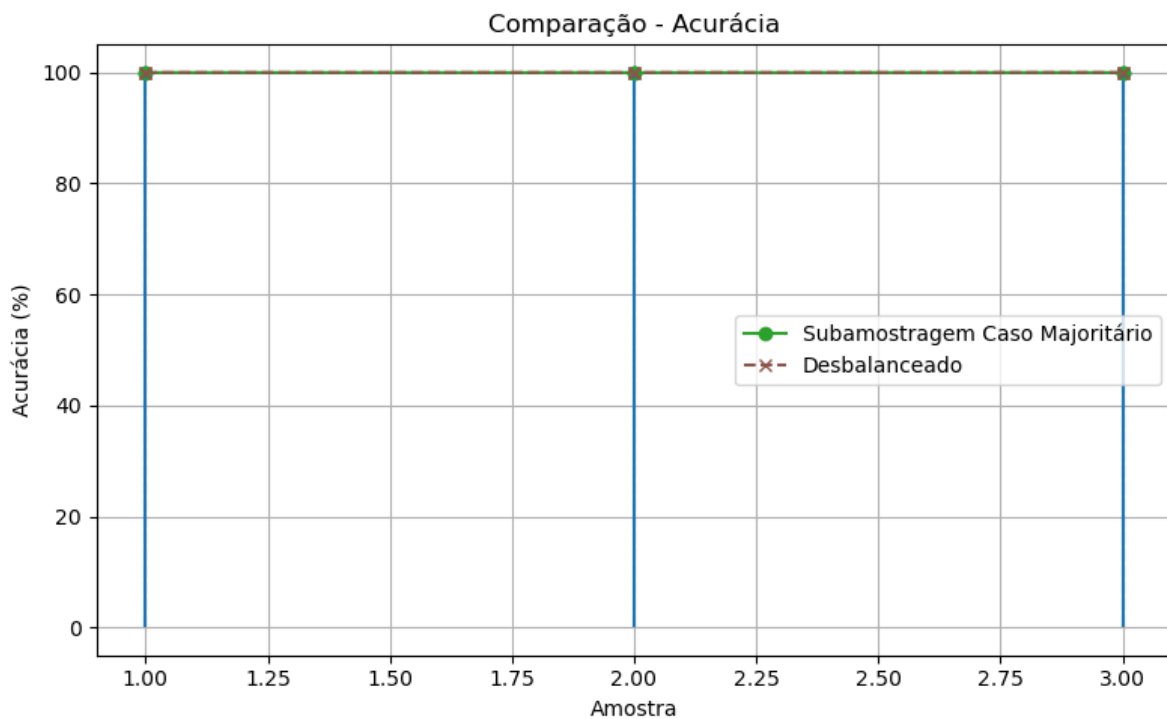


Figura 4.1. Comparação de Acurácias.

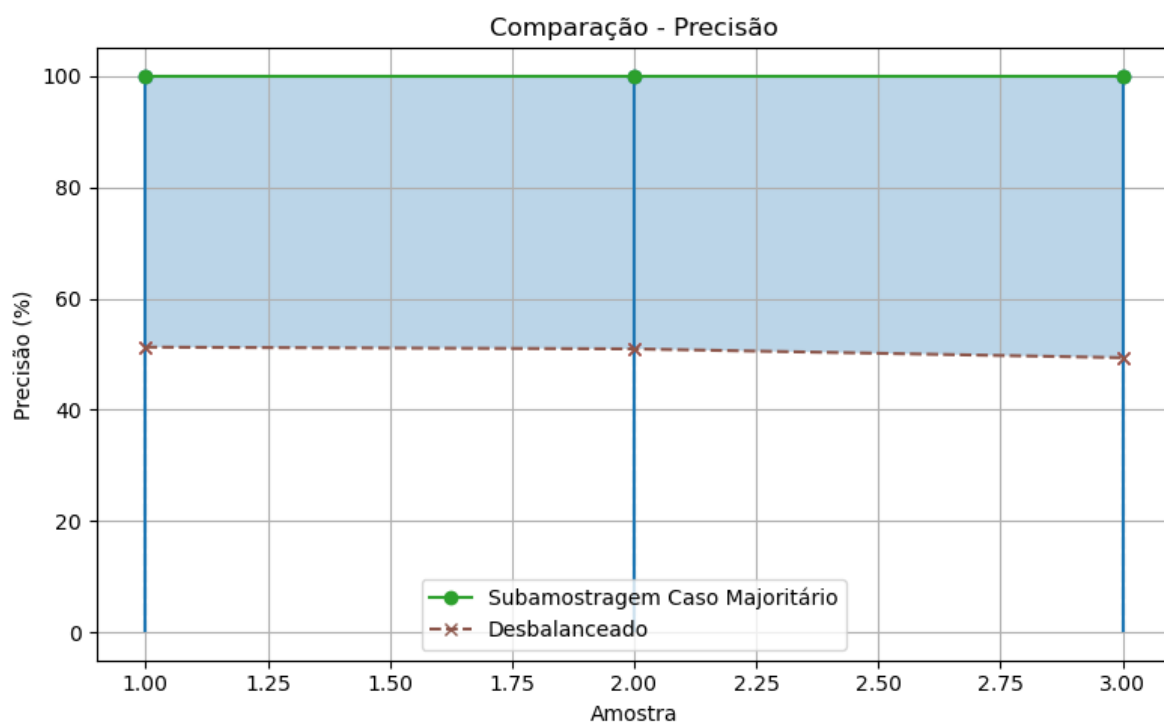


Figura 4.2. Comparação de Precisão

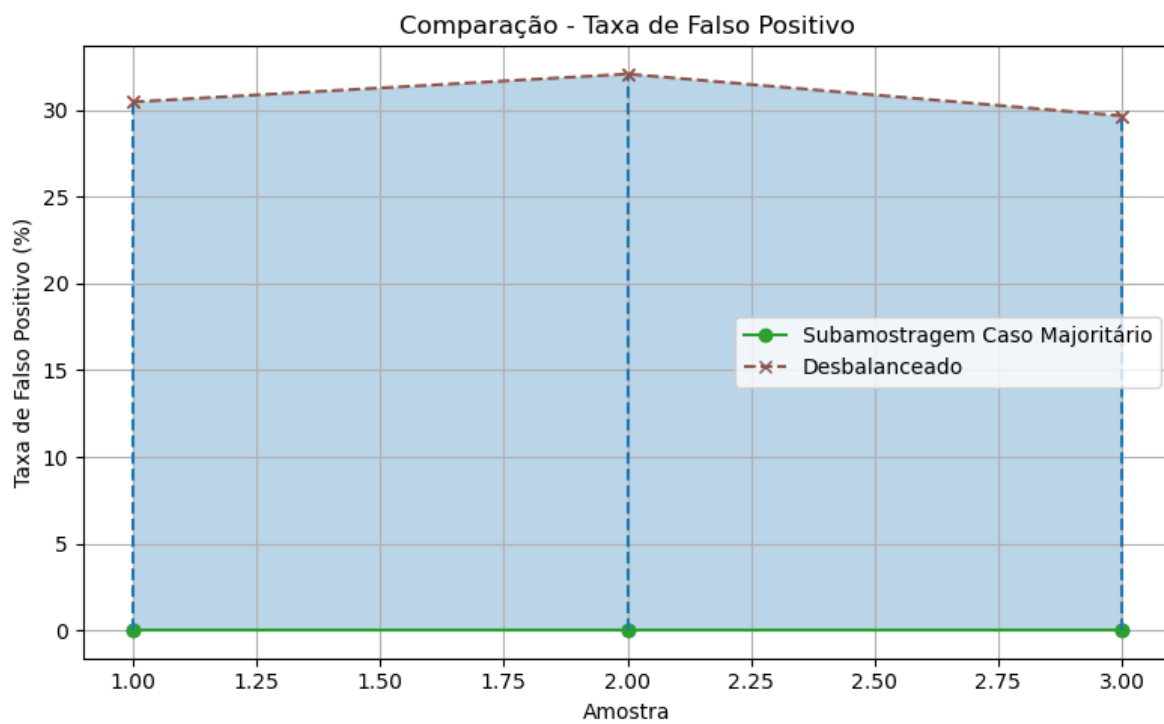


Figura 4.3. Taxa de Falso positivo.

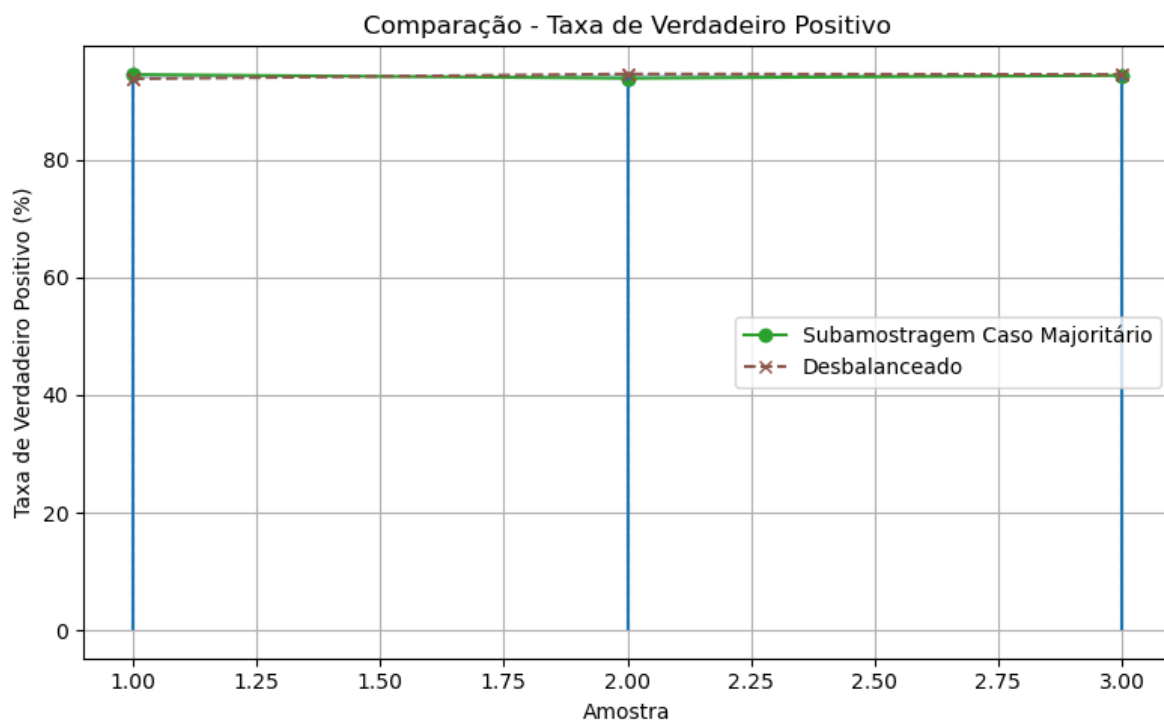


Figura 4.4. Taxa de verdadeiro Positivo

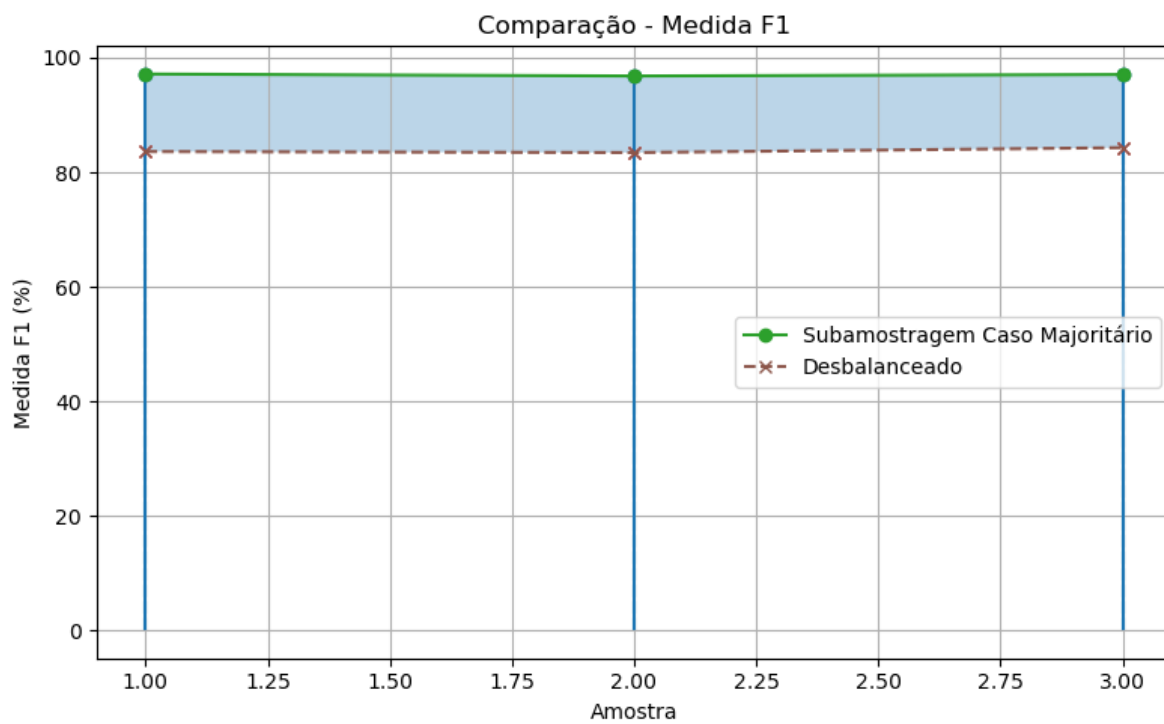


Figura 4.5. Comparação Medida F1

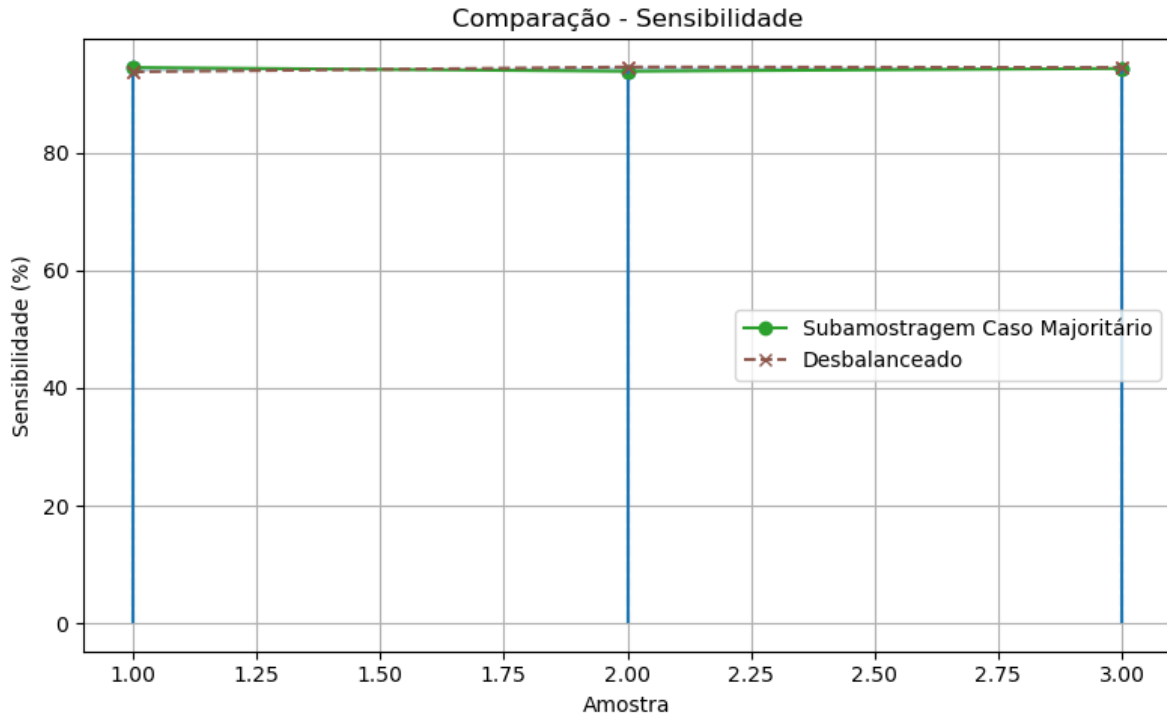


Figura 4.6. Comparação sensibilidade

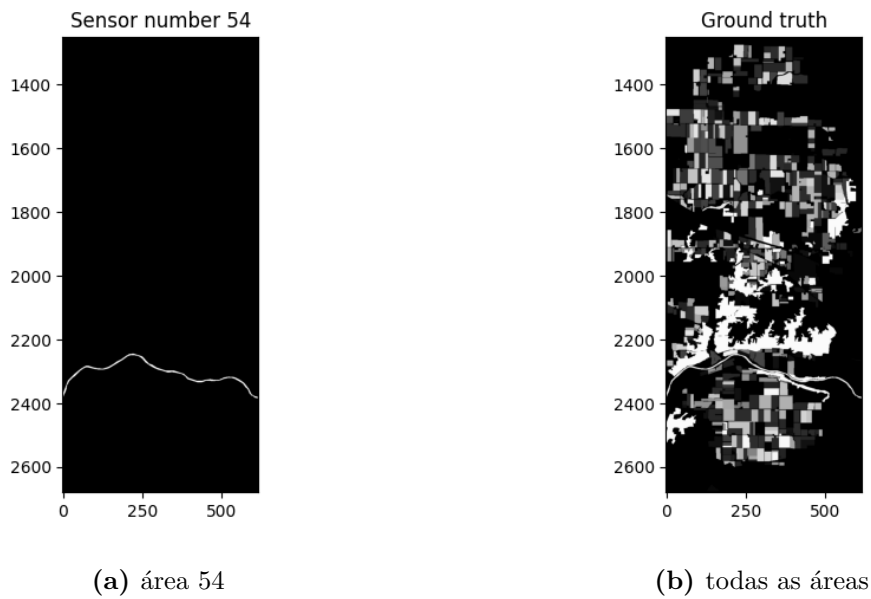


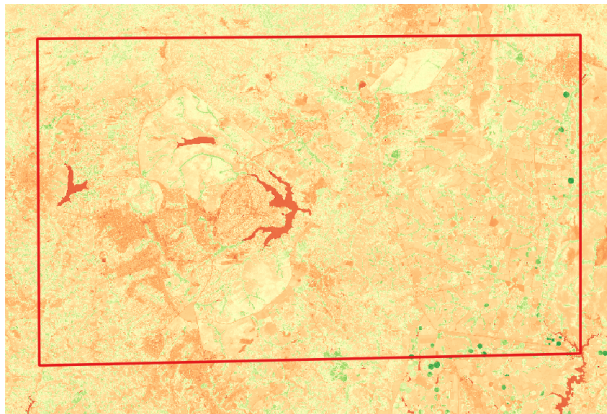
Figura 4.7. Análise feita sobre a Imagem (b), extraída da base *Indian Pines* [11]

4.2 Resultado da Implementação e Avaliação de Modelos para Detecção e Predição de Propagação de Queimadas Com Base em Imagens Multi-Espectrais de Satélites


Inicialmente, com o uso do software QGIS, são adicionadas as camadas vetoriais e multi-espectrais do satélite de forma a recortar as figuras em um quadrado que corresponde a região de Brasília, como pode ser visto na figura 4.8c. Após isso, a camada vetorial ¹ é transformada em formato portátil de gráfico (PNG) para ser interpretada pelo identificador com o intuito de ser a máscara de ausência ou existência de incêndio nas imagens ² da figura 4.8 resultando na imagem que pode ser vista na figura 4.8e.

¹consiste nos valores de **um** às áreas de queimada e **zero** a áreas de ausência do fenômeno.


²As cores representam o NDVI gerada com um indicie de falsas cores para realçar as áreas que possuem baixo indicie.



(a)




(b)



(c)



(d)



(e)

Figura 4.8. Na figura 4.8a é representada uma imagem do feixe no qual é possível visualizar Brasília, na figura 4.8b em nível de cinza está a imagem recortada na região de Brasília, na figura 4.8c é representada a mesma área com as áreas referentes a incêndio sobrepostas na cor roxa e na figura 4.8d está representada a imagem original recortada nas áreas de incêndio com o recorte referente a Brasília em vermelho e na figura 4.8e está representado o pós processamento da figura 4.8d.

1. Métricas Obtidas Durante a Avaliação de Desempenho de um Classificador de Incêndio com Base em Máquina de Vetor de Suporte Aplicada a Imagens Multiespectral de Satélite

A técnica adotada para o treinamento tem por base a classificação pixel a pixel das imagem com o uso da Máquina de Vetor de suporte (SVM) destinado a identificar os pontos que representam incêndio. Os pontos que representam o efeito podem ser visto na figura 4.9a, o que está em branco representa incêndio. O arquivo originalmente é divulgado em formato vetorial e precisa ser transformado em formato gráfico para que possa ser processado no *python*. Inicialmente, foi desenvolvido um código para transformar o arquivo vetorial, porém certos polígonos foram classificados de forma equivocada como pode ser visto ao comparar a figura gerada: 4.9b com a figura esperada: 4.9a.






Figura 4.9. Primeira tentativa de reconstruir o dado vetorial da figura 4.9a em formato gráfico pode ser visto na figura 4.9b.

A fim de evitar dados enviesados, foi realizada a transformação do dado vetorial em imagem geográfica que assume um para qualquer área que representa incêndio e zero as demais conforme pode ser visto na figura 4.10a. O teste visual sobrepondo a máscara de incêndio na figura 4.10b³ pode ser visto na figura 4.10c.



(a)



(b)



(c)

Figura 4.10. Em 4.10a, é representado o *ShapeFile*. Em 4.10b, é representada uma imagem da área do *ShapeFile*. Em 4.10c, é representado o *ShapeFile* sobreposto a imagem de satélites.

³representa uma imagem combinada dos sensores Infravermelho próximo e infravermelhos distantes, com o Infra Vermelho Próximo (FIR) no vermelho, Infra Vermelho Distante (FIR-1) no Verde e Infra Vermelho Distante (FIR-2) no azul

Satisfeitos os requisitos de relação entre a imagem de satélite e a base de dados vetorial, foi elaborado o Classificador com máquina de vetor de suporte e *Kernel* RBF. Para o treinamento foram sub-amostrados os casos não contendo ocorrências de incêndio conforme a tabela 4.2, garantindo assim uma estabilidade entre quantidade de casos contendo e não contendo incêndio.

Tabela 4.2. Quantidade de pixels relacionados ou não a incêndio

Não ocorrências de incêndio	Quantidade de ocorrências de incêndio
7054727	78207


O treinamento terminou em menos de 10 minutos, visto que a complexidade foi reduzida por não levar em consideração as posições espaciais. A fase de teste demorou na média, após 2 treinamentos, 10 minutos pois foi gerado no final do teste uma imagem o que aumenta o processamento digital de imagem, gerando reflexo no tempo computacional necessário para computar o modelo. O resultado do treinamento foi convertido nas métricas de performance da tabela 4.3, o resultado demonstrou em sua acurácia superior a 90 %, o que relata que o teste classificou corretamente quase todos os valores que seriam considerados negativos e positivos.

Tabela 4.3. Métricas de eficiência após realização de teste com uso de Máquina de Vetor de suporte (SVM).


Evaluated Metric	Value
Positives	23462
Negatives	23462
True positives	21849
True negatives	22168
False positives	1294
False negatives	1613
Precision	94,41
Accuracy	93,8
Recall	93,13
F1 score	93,8

Nas figuras 4.11a e 4.11b são representadas respectivamente os pontos de incêndio em Brasília segundo banco de dados do GPRAM e segundo o classificador da Máquina de Vetor de suporte (SVM). A priori, tendo por base as informações da tabela 4.3, o sistema aparenta estar equilibrado, pois as métricas de eficiência das simulações demonstram que a classificação dos pixels está determinando o valor esperado para incêndio com uma baixa variância. Visualmente o sistema aparente está desbalanceado, aparentemente o caráter é visto por dois motivos, primeiramente por ter considerado a reflectância espectral do centro da cidade como prédios e demais

estruturas de terreno similares as vistas em áreas contendo incêndio e também pelo fato de ter classificado inicialmente cada um dos pixels, sem levar em consideração as correlações entre um pixel e sua vizinhança.



(a)



(b)

Figura 4.11. Em 4.11b, está representado o *ShapeFile* reconstruído com o uso de uma Máquina de Vetor de suporte (SVM). Em 4.11a.

Ao observarmos a tabela 4.4 podemos ver que, embora visualmente a quantidade de falsos positivos pareça alta, o que acontece é que proporcionalmente a quantidade de casos negativos é superior quase que em 30%, resultando em uma classificação que gerou 5% a mais de áreas contendo incêndio. Proporcionalmente é baixo o valor e visualmente estes valores a mais estão dentro de grandes centros, isso se dá pois a reflectância espectral de tais pixels se assemelha ao que é recebido em incêndios.

2. Métricas Obtidas Durante a Avaliação de Desempenho de um Classificador de Incêndio com Base em Redes Neurais Convolucionais Aplicada a Imagem Multiespectral de Satélite

Após a supervisão realizada na figura 4.11b, observou-se que, mesmo com a ta-

Tabela 4.4. Teste comparativo entre o shape file de dados original e o reconstruído com uso da Máquina de Vetor de suporte (SVM).


Casos contendo Incêndio	931441
Casos não Contendo Incêndio	1215926
Falsos incêndios	66478
Incêndios não Classificados	1088
Classificação Correta de Incêndio	930353
Correta classificação	1149374
Não Incêndio	
Acurácia	96,85%
Precisão	93,33%
Especificidade	94,53%

bela 4.3 comprovando a eficiência do classificador, deveriam ser testadas outras técnicas supervisionadas. Por esse motivo, foi desenvolvido o classificador que utiliza redes neuro convolucionais para classificar às áreas de incêndio.

O classificador sub-amostrou a imagem em pequenos recortes de 65 por 65 pixels, como pode ser visto na figura 4.12. Sub-amostrando nos mesmos intervalos a máscara vetorial de áreas de incêndio como pode ser visto na figura 4.13. Foi arbitrado que área sub-amostradas contendo mais de 10% de superfície contendo incêndio seriam entregues ao classificador como áreas de incêndio e as áreas com menos seriam condicionadas a não ocorrência do evento meteorológico.



(a)



(b)

Figura 4.12. Em 4.12a temos um recorte da imagem com resolução de 65×65 já em 4.12b temos a figura completa.

A classificação conforme o uso da Rede Neurais Convolucionais (CNN) nos primeiros resultados gerou acurácias conforme os vistos na figura 4.14a. Para explorar se a quantidade de amostras é considerada baixa para o processo, foram implementadas técnicas de aumento de data na fase de treinamento através da implementação de *data augmentation*. Antes do uso de *data augmentation* e utilizando somente os

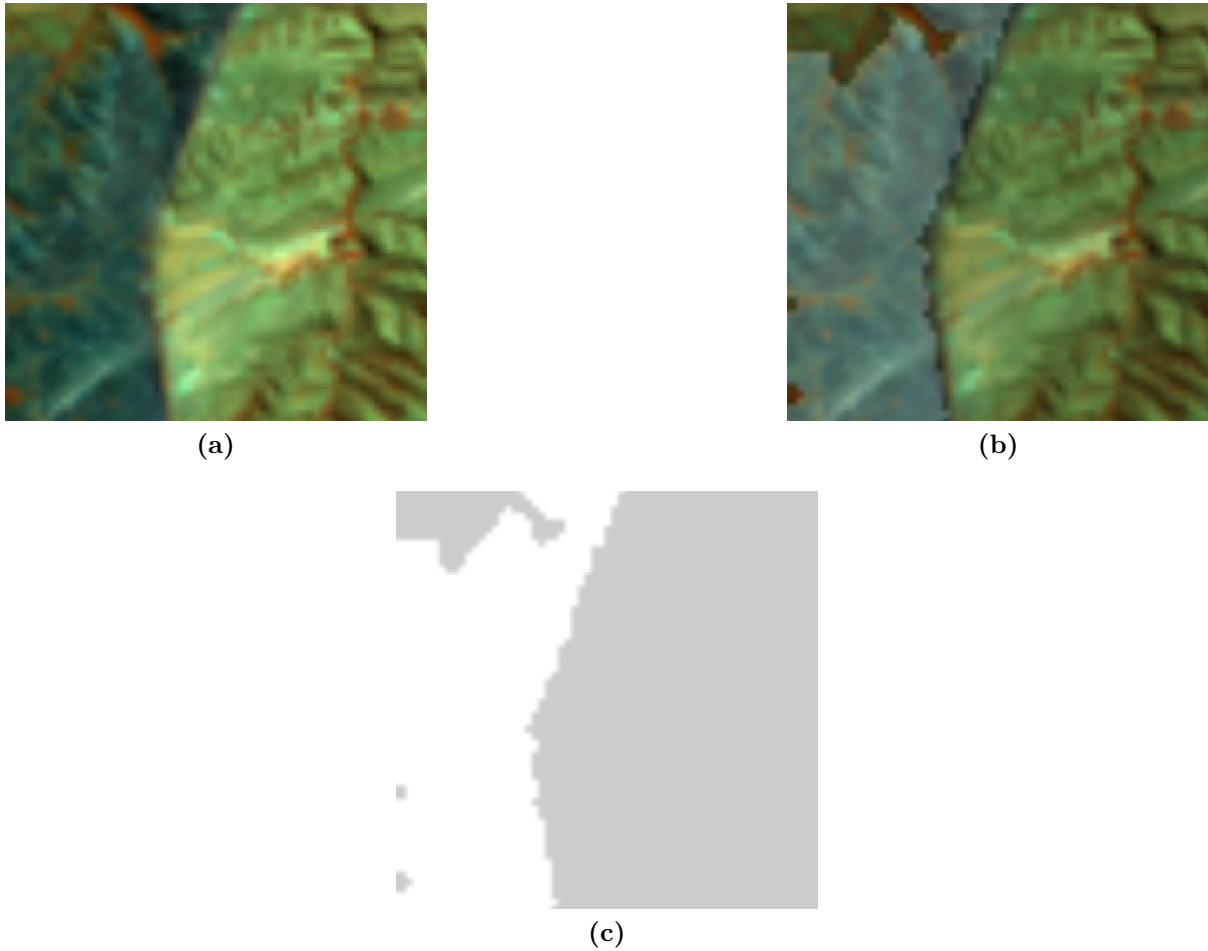


Figura 4.13. Exemplo de recorte com resolução de 65×65 de imagem contendo incêndio, em 4.13c temos o *ShapeFile* do arquivo, em 4.13a temos o arquivo e em 4.13b temos o *ShapeFile* sobreposto no arquivo.

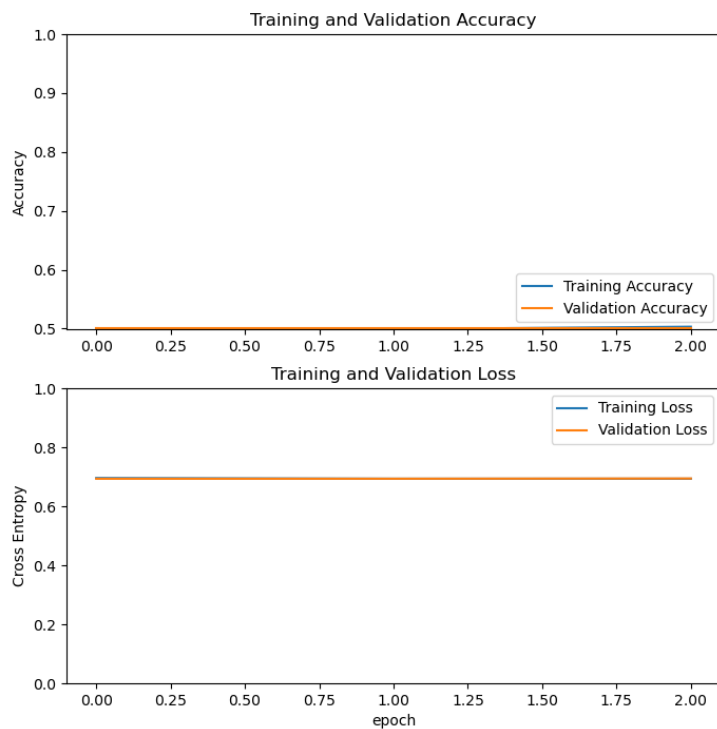
sensores vermelho, infravermelho próximo e infravermelho distante com 86 amostras separadas para os caso contendo incêndio e 86 não contendo, foi possível obter uma identificação com 50% de acurácia das áreas contendo incêndio com coeficiente de erro acima de 70%, sem grande descolamento como pode ser visto na figura 4.14a.

Após o uso da técnica de data augmentation foram gerados 41184 amostras contando queimadas e 41184 não contendo queimada. Gerando acurácias superiores a 80%, com valores inferiores de 60% para a perda, com gráficos se mantendo constantes, como pode ser visto na figura 4.14b.

Em seguida foi realizado o treinamento e validação da figura 4.15 que representa um treinamento sem *Data Augmentation* Porém considerando duas datas distintas para efetuar o treinamento.

Fica claro ao comparar a figura 4.14b com a figura 4.15a que o uso de *Data Augmentation* e de consideração de mais datas separou as classes a procura de padrões com maior confiabilidade se comparado ao caso original da figura 4.14a. Porém, o clas-

sificador ainda não foi capaz de reproduzir métricas confiáveis como as realizadas no classificador da Máquina de Vetor de suporte (SVM).



(a)




(b)

Figura 4.14. Em 4.14a temos os testes iniciais com poucas amostras já em 4.14b temos o caso com *data augmentation*.



(a)



(b)

Figura 4.15. Em 4.15a é realizado um treinamento com 50 épocas em 4.15b ocorre um refinamento de 4.15a com 3 épocas.

5 CONCLUSÃO E TRABALHOS FUTUROS

Nesta pesquisa, foram desenvolvidos e avaliados modelos computacionais vinculados à inteligência artificial capazes de identificar e classificar incêndio a partir de imagem multiespectral de satélite. Nesta pesquisa, é primeiramente desenvolvido um sistema de classificação com uso de uma Máquina de Vetores de Suporte (SVM) para identificar terrenos a partir da base de dados *Indian Pines*, que utiliza um sensor hiperespectral com 224 bandas. Em seguida, é realizado o mesmo tipo de processamento, porém nas 7 primeiras bandas do satélite *Landsat-8*, vinculando datas e localidades espaciais dos incêndios a partir de dados vetoriais de livre acesso produzidos pela autoridade ambiental GPRAM. Em seguida, é aplicado um classificador de área com uso de uma Rede Neural Convolutiva (CNN); o identificador multiespectral conta com as 7 primeiras bandas do satélite *Landsat-8*, vinculadas às posições espaciais dos dados vetoriais de livre acesso do GPRAM.

Como era previsto, o Algoritmo de Máquina de Vetor de Suporte (SVM) teve como melhor métrica a acurácia, quesito esse que é o destaque deste tipo de classificador [16]. Os resultados apresentados na implementação do aprendizado de máquina, formado por uma Máquina de Vetores de Suporte com núcleo do tipo RBF, demonstram que a implementação de um *kernel* gaussiano, seguindo a equação 2.9, é eficiente em imagens geradas a partir de sensor hiperespectral ou multiespectral em satélites ou aeronaves com o objetivo de observação da terra [16].

No caso da base de dados *Indian Pines*, existem 224 faixas diferentes no sensor hiperespectral AVARIS e, por esse motivo, os resultados da classificando pixel a pixel da área 54, mesmo representando menos de 1 % da superfície observada, foram promissores. A predição com uso de Máquina de Vetor de suporte (SVM) observa todas as métricas acima de 75 % em testes de acurácia, precisão e especificidade. Não sendo necessário efetuar a Pré-classificação de áreas.

Embora a resolução espectral do satélite *Landsat-8* seja de pouco superior a 3 % da hiperespectral do projeto vinculado a base *Indian Pines*, o desbalanceamento relacionado entre os casos minoritários e majoritários é inferior a 50 %, por esse motivo os resultados

da tabela 4.4 para a Máquina de Vetor de suporte (SVM) e do gráfico 4.15b são tão promissores.

Os resultados obtidos com a máquina de vetor de suporte mostraram-se satisfatórios no quesito de métricas de eficiência tanto no primeiro momento ao realizar o classificador vinculado a base de dados *Indian Pines* quanto referente as áreas de incêndio vinculadas ao arquivo vetorial produzido pelo GPRAM. Observou-se, que embora proporcionalmente a quantidade de falsos classificados seja de no máximo 5 % que visualmente aparenta ser um erro maior, cabe ressaltar que este erro é puramente experimental. Esta confusão pode ser resolvida em passos futuros empregando uma máscara recortando as áreas que devem ser monitoradas.

Até o momento, o Algoritmo que faz uso da máquina de vetor de suportes possui melhor classificação se comparada a rede neural. Isso se deve ao fato de que a base de dados proporcional a quantidade de pixels necessários para utilizar a rede pré-treinada está bem baixa, o que ocasiona o caso de *Over-fitting*. Esta conclusão se deu pois, ao aumentar a quantidade de dados pela técnica de *Data Augmentation* visto no gráfico 4.15b, os resultados do classificador foram superiores aos vistos anteriormente sem a técnica 4.15a.

Uma desvantagem desta abordagem, no entanto, é que, embora as métricas representem uma boa porcentagem de acerto na classificação, visualmente será necessário pré-processar o arquivo indicador de incêndio focando em áreas de interesse. Assim, embora tenha se mostrada viável para as métricas o sistema ainda não pode ser empregado por Autoridades Ambientais.

Como sugestão para trabalhos futuros, há a possibilidade de adquirir mais imagens do satélite *Landsat-8* e agora também do satélite *Landsat-9*, visto que a base de dados do GPRAM é atualizada anualmente, poderiam ser adquiridas mais informações de incêndio referentes as bases de dados para treinar a Rede Neurais Convolucionais (CNN) evitando o efeito de *Over Fitting*, gerando um classificador que, segundo a bibliografia, se implementado corretamente, tem uma melhor classificação [25]. Conforme visto ao longo desta pesquisa a precisão do sistema aumenta conforme são adquiridos mais dados.

Uma segunda sugestão a trabalhos futuros, é utilizar o classificador aqui sugerido, com as considerações a cima, para auxiliar a divisão de inteligência do GPRAM a escolher incêndios a serem combatidos. Para tornar o estudo mais rico seriam necessário vincular bases que estudam terrenos diferentes e informações de solo. Bases essas que são consideradas de livre acesso. Ainda é interessante confirmada a seguridade dos resultados anteriores com o intuito de desenvolver uma possível testagem de focos verídicos com o GPRAM. Sondando formas de afirmar a eficiência quanto ao combate.

Referências Bibliográficas

- [1] Wanderson Rodrigues da Silva. Operação Verde Vivo (OPVV): conteúdo informativo de prevenção a incêndios florestais no Distrito Federal (DF). November 2021. Accepted: 2022-01-19T18:13:47Z.
- [2] Ubirajara Oliveira, Britaldo Soares-Filho, William Leles de Souza Costa, Letícia Gomes, Mercedes Bustamante, e Heloisa Miranda. Modeling fuel loads dynamics and fire spread probability in the Brazilian Cerrado. *Forest Ecology and Management*, 482:118889, February 2021.
- [3] Matheus Castro de Carvalho. Mapeamento de vulnerabilidade de incêndios florestais no Parque Nacional de Brasília. August 2021. Accepted: 2021-10-28T21:07:11Z.
- [4] Gabrielly Cristiny Andrade e Stffane Beatriz Figueredo Lemes. DINÂMICA DE USO E COBERTURA VEGETAL NAS ZONAS DE AMORTECIMENTO DO PARQUE NACIONAL DAS EMAS E DO PARQUE NACIONAL CHAPADA DOS VEADEIROS ENTRE 1985 E 2019. *REDE - Revista Eletrônica do PRODEMA*, 1(15):83–93, August 2021.
- [5] Marcelo de Oliveira Latuf, Guilherme da Silva Rios, e Raiane Cristina Pereira. Análise multitemporal de incêndios florestais ocorridos no Estado de Minas Gerais entre 2001 e 2020. *Revista Cerrados*, 20(01):120–148, February 2022. Number: 01.
- [6] Alberto Setzer, Fabiano Morelli, e Jean Carlos Souza. O banco de dados de queimadas do inpe. *Biodiversidade Brasileira-BioBrasil*, (1):239–239, 2019.
- [7] Deepak Kumar Jain, Surendra Bilouhan Dubey, Rishin Kumar Choubey, Amit Sinhal, Siddharth Kumar Arjaria, Amar Jain, e Haoxiang Wang. An approach for hyperspectral image classification by optimizing SVM using self organizing map. *Journal of Computational Science*, 25:252–259, March 2018.
- [8] Te-Ming Tu, P.S. Huang, Chung-Ling Hung, e Chien-Ping Chang. A fast intensity-hue-saturation fusion technique with spectral adjustment for IKONOS imagery. *IEEE Geoscience and Remote Sensing Letters*, 1(4):309–312, October 2004. Conference Name: IEEE Geoscience and Remote Sensing Letters.

- [9] Alejandro Ribes, Ruven Pillay, Francis Schmitt, e Christian Lahanier. Studying That Smile: A tutorial on multispectral imaging of paintings using the Mona Lisa as a case study. *IEEE Signal Processing Magazine*, August 2008.
- [10] Christian Fischer e Ioanna Kakoulli. Multispectral and hyperspectral imaging technologies in conservation: current research and potential applications. *Studies in Conservation*, 51(sup1):3–16, 2006.
- [11] M. F. Baumgardner, L. L. Biehl, e D. A. Landgrebe. 220 Band AVIRIS Hyperspectral Image Data Set: June 12, 1992 Indian Pine Test Site 3. 1992.
- [12] Pedram Ghamisi, Yushi Chen, e Xiao Xiang Zhu. A Self-Improving Convolution Neural Network for the Classification of Hyperspectral Data. *IEEE Geoscience and Remote Sensing Letters*, 13(10):1537–1541, October 2016. Conference Name: IEEE Geoscience and Remote Sensing Letters.
- [13] Morteza Ghahremani, Yonghuai Liu, Peter Yuen, e Ardhendu Behera. Remote sensing image fusion via compressive sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 152:34–48, June 2019.
- [14] Morris F Cohen. *An introduction to logic and scientific method*. Read Books Ltd, 2011.
- [15] Nigel Cross, John Naughton, e David Walker. Design method and scientific method. *Design studies*, 2(4):195–201, 1981.
- [16] Amanpreet Singh, Narina Thakur, e Aakanksha Sharma. A review of supervised machine learning algorithms. In *2016 3rd International Conference on Computing for Sustainable Global Development (INDIACom)*, pages 1310–1315, March 2016.
- [17] Tom Fawcett. An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8):861–874, June 2006.
- [18] Cristiano Jacques Miosso, Ricardo von Borries, M. Argaez, L. Velazquez, C. Quintero, e C. M. Potes. Compressive Sensing Reconstruction With Prior Information by Iteratively Reweighted Least-Squares. *IEEE Transactions on Signal Processing*, 57(6):2424–2431, June 2009. Conference Name: IEEE Transactions on Signal Processing.
- [19] C. J. Miosso, R. von Borries, e J. H. Pierluissi. Compressive Sensing With Prior Information: Requirements and Probabilities of Reconstruction in ℓ_1 -Minimization. *IEEE Transactions on Signal Processing*, 61(9):2150–2164, May 2013. Conference Name: IEEE Transactions on Signal Processing.

- [20] M Arif, KK Alghamdi, SA Sahel, SO Alosaimi, ME Alsahaft, MA Alharthi, e M Arif. Role of machine learning algorithms in forest fire management: a literature review. *J Robotics Autom*, 5(1):212–226, 2021.
- [21] C. J. Miosso, R. von Borries, e J. H. Pierluissi. Compressive sensing method for improved reconstruction of gradient-sparse magnetic resonance images. In *2009 Conference Record of the Forty-Third Asilomar Conference on Signals, Systems and Computers*, pages 799–806, November 2009. ISSN: 1058-6393.
- [22] Daniel Lucas Ferreira e Almeida. Reconstrução de imagens de ressonância magnética com base em compressive sensing usando informação a priori estrutural em abordagem estocástica. February 2017. Accepted: 2017-09-11T16:40:09Z.
- [23] Melville S Green. Markoff random processes and the statistical mechanics of time-dependent phenomena. *The Journal of Chemical Physics*, 20(8):1281–1295, 1952.
- [24] Gopal Jee, V Brinda, DS Sheela, e VR Lalithambika. Control law design for miso system in the presence of actuator position limit constraint. *IFAC-PapersOnLine*, 53(1):164–169, 2020.
- [25] Sai Yeshwanth Chaganti, Ipseeta Nanda, Koteswara Rao Pandi, Tavva GNRSN Prudhvith, e Niraj Kumar. Image classification using svm and cnn. In *2020 International conference on computer science, engineering and applications (ICCSEA)*, pages 1–5. IEEE, 2020.
- [26] Jack D O’Sullivan, Paul R Hoy, e Harvey N Rutt. Spectral imaging as a potential tool for optical sentinel lymph node biopsies. In *European Conference on Biomedical Optics*, page 80872J. Optica Publishing Group, 2011.
- [27] Mustafa Teke, Hüsne Seda Deveci, Onur Haliloğlu, Sevgi Zübeyde Gürbüz, e Ufuk Sakarya. A short survey of hyperspectral remote sensing applications in agriculture. In *2013 6th international conference on recent advances in space technologies (RAST)*, pages 171–176. IEEE, 2013.
- [28] Karen Zanter. Landsat 8 (18) data users handbook. *Landsat Science Official Website*, 33, 2016.
- [29] Linda (Contractor) Owen. Landsat 9 Data Users Handbook. February 2022.
- [30] Brian Jirout. *One satellite for the world: The American Landsat earth observation satellite in use, 1953-2008*. PhD thesis, Georgia Institute of Technology, 2017.

- [31] Mahlatse Kganyago e Lerato Shikwambana. Assessment of the Characteristics of Recent Major Wildfires in the USA, Australia and Brazil in 2018–2019 Using Multi-Source Satellite Products. *Remote Sensing*, 12(11):1803, January 2020. Number: 11 Publisher: Multidisciplinary Digital Publishing Institute.
- [32] Mohsen Pourahmadi. *Foundations of time series analysis and prediction theory*, volume 379. John Wiley & Sons, 2001.
- [33] Rafael C. Gonzalez. Deep Convolutional Neural Networks [Lecture Notes]. *IEEE Signal Processing Magazine*, 35(6):79–87, November 2018. Conference Name: IEEE Signal Processing Magazine.
- [34] Christopher J.C. Burges. A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery*, 2(2):121–167, June 1998.
- [35] Cai Ruikai. Research Progress in Image Denoising Algorithms Based on Deep Learning. *Journal of Physics: Conference Series*, 1345(4):042055, November 2019. Publisher: IOP Publishing.
- [36] Vapnik V. Pattern recognition using generalized portrait method. *Automation and Remote Control*, 24:774–780, 1963.
- [37] Bernhard E. Boser, Isabelle M. Guyon, e Vladimir N. Vapnik. A training algorithm for optimal margin classifiers. In *Proceedings of the fifth annual workshop on Computational learning theory, COLT '92*, pages 144–152, New York, NY, USA, July 1992. Association for Computing Machinery.
- [38] Hui Cao, Takashi Naito, e Yoshiki Ninomiya. Approximate RBF Kernel SVM and Its Applications in Pedestrian Classification. October 2008.
- [39] Stephen P. Boyd e Lieven Vandenberghe. *Convex optimization*. Cambridge University Press, Cambridge, UK ; New York, 2004.
- [40] https://ambiental.cbm.df.gov.br/?page_id=629 - Camadas Vetoriais – GPRAM.
- [41] Borislava Vrigazova. The proportion for splitting data into training and test set for the bootstrap in classification problems. *Business Systems Research: International Journal of the Society for Advancing Innovation and Research in Economy*, 12(1):228–242, 2021.
- [42] TensorFlow. Manual mobilenet v2, February 2023.