

**UNIVERSIDADE FEDERAL DE ALAGOAS-UFAL
CAMPUS DE ARAPIRACA
CIÊNCIA DA COMPUTAÇÃO - BACHARELADO**

SILVIO HENRIQUE DA SILVA PINTO

**ESTUDO DO USO DE ALGORITMOS DE VISÃO COMPUTACIONAL PARA
DETECÇÃO DE FOGO E FUMAÇA**

ARAPIRACA

2023

Silvio Henrique da Silva Pinto

Estudo do uso de algoritmos de visão computacional para detecção de fogo e fumaça

Trabalho de Conclusão de Curso apresentado à Universidade Federal de Alagoas – UFAL, *Campus* de Arapiraca, como pré-requisito para a obtenção do grau de Bacharel em Ciência da Computação.

Orientador: Prof. Dr. Tácito Trindade de Araújo Tiburtino Neves

Arapiraca
2023



Universidade Federal de Alagoas – UFAL
Campus Arapiraca
Biblioteca Setorial *Campus Arapiraca* - BSCA

P659e Pinto, Silvio Henrique da Silva
Estudo do uso de algoritmos de visão computacional para detecção de fogo e fumaça [recurso eletrônico] / Silvio Henrique da Silva Pinto. – Arapiraca, 2023.
23 f.: il.

Orientador: Prof. Dr. Tácito Trindade de Araújo Tiburtino Neves.
Trabalho de Conclusão de Curso (Bacharelado em Ciência da Computação) -
Universidade Federal de Alagoas, *Campus Arapiraca*, Arapiraca, 2023.
Disponível em: Universidade Digital (UD) / RD- BSCA– UFAL (*Campus Arapiraca*).
Referências: f. 23.

1. Inteligência artificial. 2. Prevenção de acidentes. 3. Visão computacional.
4. Redes neurais artificiais. 5. Incêndio. I. Neves, Tácito Trindade de Araújo Tiburtino.
II. Título.

CDU 004

Silvio Henrique da Silva Pinto

Estudo do uso de algoritmos de visão computacional para detecção de fogo e fumaça

Trabalho de Conclusão de Curso apresentado à Universidade Federal de Alagoas – UFAL, *Campus* de Arapiraca, como pré-requisito para a obtenção do grau de Bacharel em Ciência da Computação.

Data de Aprovação: 31/05/2023.

Banca Examinadora



TACITO TRINDADE DE ARAUJO TIBURTINO

Data: 14/06/2023 15:30:36-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. Tácito Trindade de Araújo Tiburtino Neves
Universidade Federal de Alagoas
Campus Arapiraca
(Orientador)



RODOLFO CARNEIRO CAVALCANTE

Data: 14/06/2023 15:42:55-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. Rodolfo Carneiro Cavalcante
Universidade Federal de Alagoas - UFAL
Campus Arapiraca
(Examinador)



ELTHON ALLEX DA SILVA OLIVEIRA

Data: 19/06/2023 16:12:05-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. Elthon Allex da Silva Oliveira
Universidade Federal de Alagoas - UFAL
Campus Arapiraca
(Examinador)

AGRADECIMENTOS

Agradeço, primeiramente, a Deus por ter me proporcionado tantas oportunidades, conquistas e aprendizados. Gostaria também de agradecer à minha mãe, Monica da Silva Pinto, ao meu pai, Severino Ramos Pinto, ao meu irmão, Ericles Vinicius da Silva Pinto, e a todos os outros membros da minha família, que me apoiaram desde o início da minha formação. Sou grato ao meu primo, Gleivson da Silva Pinto, que foi fundamental para a minha entrada na área da programação e Ciência da Computação.

Expresso minha gratidão a todos os docentes do curso, que me prepararam para a vida profissional e a realização deste trabalho. Em especial, gostaria de agradecer ao meu orientador, Prof. Dr. Tácito Trindade de Araújo Tiburtino Neves, que contribuiu significativamente para a minha formação acadêmica e profissional.

RESUMO

Neste trabalho de conclusão de curso é apresentado um estudo do uso de modelos de Inteligência Artificial (IA) para detecção de fogo e fumaça. O objetivo deste trabalho é o desenvolvimento de um modelo de IA eficiente, que não utiliza muitos recursos computacionais, e que consiga um resultado de, ao menos, 90% das métricas de avaliação. Para alcançar esse objetivo, foi realizada uma pesquisa aplicada e quantitativa, usando dados de imagens coletadas para o treinamento de vários modelos de IA, os fazendo aprender se uma imagem possui fogo, fumaça ou se está sem fogo e nem fumaça, e analisando seus resultados com as métricas avaliativas. Os resultados obtidos mostraram que a detecção de fogo e fumaça em imagem com modelos de IA é possível, com modelos simples e feitos para a classificação de objetos genéricos. Com o uso de modelos de IA para classificação de fogo ou fumaça, é possível usar aparelhos como celulares, vinculando o modelo a sua câmera e detectando se na imagem, foto ou vídeo, tem fogo ou fumaça, democratizando o acesso a uma tecnologia essencial para prevenção de acidentes e desastres.

Palavras-chave: classificação de fogo e fumaça; inteligência artificial; prevenção de acidentes; redes neurais artificiais; visão computacional.

ABSTRACT

This final course project presents a study on the use of Artificial Intelligence (AI) models for fire and smoke detection. The objective of this work is to develop an efficient AI model that utilizes minimal computational resources and achieves a minimum of 90% in evaluation metrics. To achieve this goal, an applied and quantitative research was conducted, using collected image data to train various AI models. These models were trained to learn whether an image contains fire, smoke, or neither, and their results were analyzed using evaluation metrics. The obtained results demonstrated that fire and smoke detection through image analysis using simple AI models, designed for generic object classification, is possible. By employing AI models for fire or smoke classification, it is possible to utilize devices such as smartphones, linking the model to their cameras and detecting the presence of fire or smoke in images, photos, or videos. This democratizes access to an essential technology for accident and disaster prevention.

Keywords: classification of fire and smoke; artificial intelligence; accidents prevention; artificial neural network; computer vision.

LISTA DE FIGURAS

Figura 1 – Classificação de gato e cachorro.....	11
Figura 2 – Ilustração de funcionamento de Nó.....	12
Figura 3 – Ilustração de rede neural artificial.....	12
Figura 4 – Imagens da classe fogo, fumaça e normal.....	15
Figura 5 – Diagrama de processo de desenvolvimento.....	16

LISTA DE QUADROS

Quadro 1 – Arquitetura dos modelos selecionados.	17
Quadro 2 – Resultados das acurácias dos modelos.	19
Quadro 3 – Resultados MobileNetV2.	19
Quadro 4 – Resultados ResNet152V2.	19
Quadro 5 – Resultados DenseNet201.	20
Quadro 6 – Resultados DenseNet121.	20
Quadro 7 – Resultados NASNetMobile.	20
Quadro 8 – Resultados EfficientNetV2B0.	20

LISTA DE ABREVIATURAS E SIGLAS

IA	Inteligência Artificial
VC	Visão Computacional
RNA	Rede Neural Artificial

SUMÁRIO

1	INTRODUÇÃO.....	10
2	REFERENCIAL TEÓRICO.....	11
2.1	TRABALHOS RELACIONADOS.....	14
3	METODOLOGIA.....	15
3.1	ARQUITETURA E MODELOS ESCOLHIDOS.....	17
3.2	COLETA E ORGANIZAÇÃO DOS DADOS.....	17
3.3	TREINAMENTO DOS MODELOS.....	18
3.4	TESTE DOS MODELOS.....	19
4	RESULTADOS.....	20
5	CONCLUSÃO.....	22
	REFERÊNCIAS.....	23

1 INTRODUÇÃO

Acidentes relacionados ao fogo, como incêndios, explosões e queimaduras, são frequentes tanto no Brasil quanto no mundo. Esses acontecimentos têm chamado a atenção da sociedade para a prevenção e combate ao fogo, tanto em áreas urbanas quanto em regiões florestais. Com a evolução tecnológica, a humanidade desenvolveu o aparelho chamado "Detector de Fumaça", que detecta fumaça em um ambiente, entretanto, esses aparelhos só podem ser usados em ambientes fechados e com um hardware específico, aumentando seu preço de compra. Para superar as limitações geográficas e democratizar a prevenção de acidentes relacionados ao fogo (através de um produto barato), torna-se necessário uma alternativa.

O presente trabalho tem como objetivo a criação de um modelo de Inteligência Artificial que consiga detectar fogo e fumaça através do uso imagens de forma eficiente, sendo possível a utilização desse modelo em qualquer dispositivo capaz de processar as tecnologias necessárias. Se a criação de um modelo de Visão Computacional para detecção de fogo e fumaça for possível e viável, haverá uma inovação no mercado, tendo em vista que será factível utilizar esse modelo em smartphones, tvs, notebooks, etc, através dos portes tecnológicos existentes atualmente, barateando o desenvolvimento do modelo (não sendo necessário um hardware específico) e democratizando o acesso (tendo em vista o número crescente de pessoas com um celular em mãos). Além disso, poderá ser usado em questões ambientais, acidentes domésticos, acidentes industriais, etc, por meio da prevenção de incêndios, explosões, queimaduras, etc.

Este trabalho investiga a possibilidade da criação de um modelo de Visão Computacional para detecção de fogo e fumaça. Para alcançar este objetivo, foi realizada uma pesquisa quantitativa baseada na criação de modelos de Inteligência Artificial em um banco de dados com 9654 imagens. As imagens foram coletadas em diversos bancos de dados públicos disponíveis que continham imagens de fogo, fumaça ou de qualquer outro objeto necessário para o trabalho. A abordagem metodológica usada nesta pesquisa permitiu uma compreensão aprofundada da criação, funcionamento e teste de modelos de inteligência artificial.

2 REFERENCIAL TEÓRICO

Visão Computacional é uma subárea da Inteligência Artificial, que utiliza técnicas de processamento de imagens e aprendizado de máquina para criar modelos e algoritmos capazes de resolver problemas de classificação, detecção, segmentação, entre outros. Uma das questões centrais abordadas neste trabalho é a classificação de imagem, com o objetivo de discriminar a presença ou ausência de determinada classe (objeto, forma, ser, etc) em uma imagem. Um exemplo desse problema está na figura1, onde existe a classificação de uma imagem com um gato, que pertence a classe Gato, e a classificação de uma imagem com um cachorro, que pertence a classe Cachorro.


Figura 1 – Classificação de gato e cachorro



Fonte: O autor (2023).

Uma das técnicas usadas para resolver os problemas de classificação são as Redes Neurais Artificiais. As Redes Neurais Artificiais, como explicado por (GROSSI; BUSCEMA, 2007), são sistemas adaptativos artificiais inspirados no funcionamento do cérebro humano. São sistemas capazes de modificar sua estrutura em relação a um objetivo, como aprender a classificar algum objeto em uma imagem. As RNA são formadas por camadas com um número variado de nós, onde cada nó tem um peso e um limiar associado. Se a saída de qualquer nó estiver acima do valor de limiar especificado, esse nó é ativado, enviando um sinal (dados numéricos) para a próxima camada da rede. Se a saída não atingir o limite especificado, o nó não passará o sinal para o próximo nó, na próxima camada. Um exemplo disso é a Figura2, onde existe uma camada de entrada passando informações para um nó, que fará o cálculo interno e, dependendo do resultado, passará para a camada de saída o valor resultante.

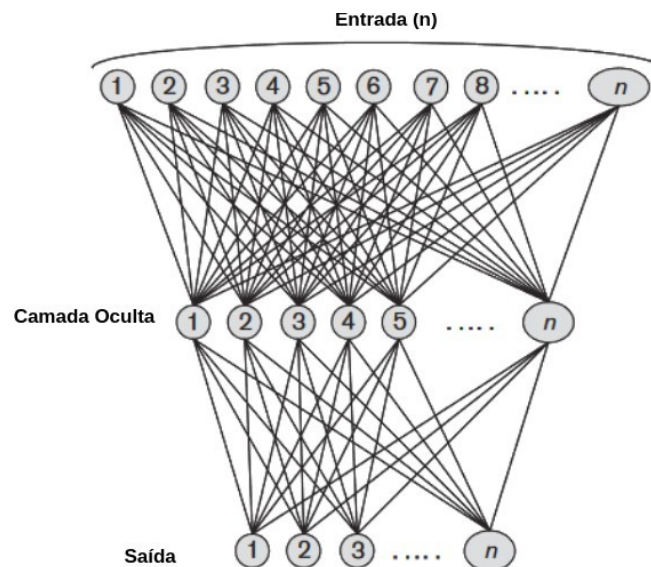
Figura 2 – Ilustração de funcionamento de Nó



Fonte: Grossi; Buscema (2007).

A arquitetura de uma Rede Neural Artificial é composta por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. Cada camada pode ter n número de nós. A camada de entrada é relativa a entrada da rede, onde cada nó representará uma parte de algo maior, recebendo, por exemplo, um pixel de uma imagem. Na camada oculta, acontece o cálculo de características, onde cada nó aprenderá alguma característica para que então, com a junção de todos os nós, ajude a discriminar a classe de uma imagem, se a imagem é um gato ou um cachorro, por exemplo. Essa discriminação acontecerá na última camada, camada de saída, após receber algum valor da camada oculta. Temos como exemplo a figura 2, que descreve a estrutura de uma Rede Neural Artificial.

Figura 3 – Ilustração de Rede Neural Artificial



Fonte: Grossi; Buscema (2007).

A fim de medir se um modelo consegue classificar um objeto ou, por exemplo, prever um evento, são usadas métricas de avaliação de modelos. No presente trabalho, serão usados a acurácia, precisão, recall e f1-score, que foram descritas e recomendadas por (GÉRON, 2019).

A Acurácia indica a porcentagem de amostras classificadas corretamente pelo modelo. É calculada pela divisão do número de previsões corretas pelo número total de previsões. É uma medida simples e amplamente usada, mas pode não ser adequada quando as classes estão desequilibradas.

A Precisão (*precision*) indica a proporção de amostras classificadas como positivas pelo modelo que realmente são positivas. É calculada, como mostrado na equação 1, pela divisão do número de verdadeiros positivos (TP) pelo número de verdadeiros positivos mais falsos positivos (FP). É uma medida importante em casos em que a classe positiva é rara ou quando se quer evitar falsos positivos.

$$precision = \frac{TP}{TP + FP} \quad (1)$$

O Recall indica a proporção de amostras positivas que são corretamente identificadas pelo modelo. É calculado, como mostrado na equação 2, pela divisão do número de verdadeiros positivos (TP) pelo número de verdadeiros positivos mais falsos negativos (FN). É uma medida importante em casos em que se quer evitar falsos negativos, como na detecção de doenças.

$$recall = \frac{TP}{TP + FN} \quad (2)$$

O F1-score é uma medida que combina a precisão e o recall em uma única pontuação. É calculado, como mostrado na equação 3, pela média harmônica da precisão e do recall. É uma medida útil quando se quer equilibrar a importância da precisão e do recall. Ou seja, quanto melhores a precisão e recall, melhor será o f1-score.

$$f1 = \frac{2}{\frac{1}{precision} + \frac{1}{recall}} = 2 \times \frac{precision * recall}{precision + recall} = \frac{2 * TP}{2 * TP + FN + FP} \quad (3)$$

2.1 TRABALHOS RELACIONADOS

A classificação de fogo ou fumaça por VC é uma tarefa bastante explorada no âmbito científico, portanto existem diversas publicações referentes ao tema. Um dos exemplos é o trabalho (TRUE, 2009), onde foi construído um detector de fogo, utilizando técnicas de Processamento de Imagem e Inteligência Artificial. O classificador construído consegue detectar fogo em vídeos, basicamente, através de 3 técnicas, detecção de movimento, análise dos valores dos pixels das imagens e análise de textura da imagem. É um classificador que funciona em vídeos (necessário para a etapa de detecção de movimento) e teve bons resultados para a detecção de fogo, contudo, não foi satisfatório na discriminação de vídeos sem fogo.

O trabalho (WU; WU; ZHAO, 2019) fornece uma abordagem inteligente para detecção de fogo usando câmeras e métodos de visão computacional. O estudo tem como objetivo desenvolver um sistema eficiente e preciso para detecção de fogo em tempo real. O trabalho enfatiza o uso de técnicas de processamento de imagens, detecção de movimento e inteligência artificial para identificar a presença de incêndios em imagens de câmeras de vigilância. Os resultados experimentais demonstram uma alta taxa de detecção com baixas taxas de alarmes falsos, demonstrando a eficácia da abordagem baseada em visão computacional para a detecção de incêndios.

Os dois trabalhos apresentam métodos únicos para a detecção de fogo, tendo bons resultados e servindo como uma referência valiosa para o desenvolvimento e aprimoramento dos sistemas de detecção de fogo em imagens. Contudo, o desenvolvimento dos classificadores dos dois projetos são complexos, sendo difícil a democratização de acesso as pessoas que não são da área da tecnologia. Além disso, a detecção de fumaça por Visão Computacional não foi abordada nesses trabalhos.

3 METODOLOGIA

A natureza do presente trabalho se enquadra no campo das pesquisas aplicadas, tendo em vista a resolução, de forma prática, da problemática da detecção de fogo e fumaça através de um modelo de IA. A resolução da problemática é a criação de um modelo eficiente para detecção de fogo e fumaça, que apresente resultados satisfatórios, visando atingir cerca de 90% em métricas como precisão, recall, entre outras. Para alcançar esse objetivo, a pesquisa adotará uma abordagem quantitativa, cujo objetivo é realizar uma análise numérica dos fenômenos em questão, comparando o resultado dos diferentes modelos.

Os dados foram coletados pela internet a partir de diversos bancos de dados, como o COCO Dataset, para imagens aleatórias sem fogo nem fumaça, FireNet Dataset, imagens de fogo coletadas e classificadas por (JADON *et al.*, 2019), Smoke100k Dataset, imagens de fumaça produzidas por (CHENG *et al.*, 2019) e o Fire and Smoke Dataset, disponibilizado no Kaggle pela DataCluster Labs. Foi selecionado as melhores imagens para o propósito da pesquisa. Os dados foram armazenados no ambiente do Google Drive, que é o serviço de armazenamento e sincronização de arquivos. Os dados tem cerca de 1,8 GB. No total, existem 9654 imagens, distribuídas entre classes de fogo, fumaça e imagens que não continham fogo e nem fumaça. Um exemplo dessa separação é na figura4, onde na primeira linha existem 3 imagens de Fogo, na segunda linha existem 3 imagens de fumaça e, na última linha, existem 3 imagens da classe normal (com imagens aleatórias, mas sem fogo ou fumaça).

Figura 4 – Imagens da classe fogo, fumaça e normal



Fonte: O autor (2023).

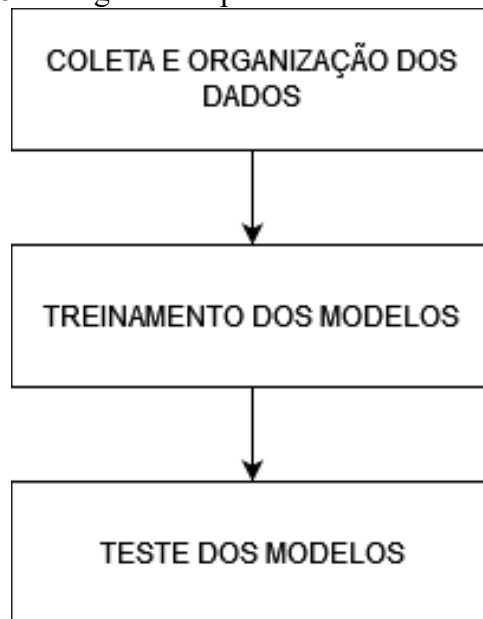
O ambiente de desenvolvimento utilizado neste trabalho foi o Colab Pro, que oferece acesso a recursos avançados, incluindo um acelerador gráfico de GPU com 32 GB de VRAM e 25 GB de RAM. O Colab Pro é uma plataforma baseada em navegador, especialmente adequada para desenvolvimento de código Python, aprendizado de máquina e análise de dados.

A escolha do Colab Pro foi motivada pela sua capacidade de fornecer uma infraestrutura computacional adequada para treinamento de modelos de Inteligência Artificial. No entanto, devido ao custo associado ao acesso a esses recursos o trabalho foi limitado a treinar apenas 6 modelos de Inteligência Artificial.

A seleção dos recursos computacionais foi realizada levando em consideração o tempo de treinamento dos modelos, a viabilidade financeira e a disponibilidade dos recursos necessários para a conclusão do trabalho. Embora as limitações de recursos possam restringir o escopo do estudo, após os modelos serem treinados o uso dos recursos computacionais é reduzido, restando um ambiente robusto para a implementação e avaliação dos modelos propostos.

Conforme mostrado na Figura 5, o processo de desenvolvimento do projeto é sequencial, passando de uma etapa para a outra, e pode ser descrito como: coleta e organização dos dados, treinamento dos modelos e teste dos modelos.

Figura 5 – Diagrama de processo de desenvolvimento



Fonte: O autor (2023).

3.1 ARQUITETURA E MODELOS ESCOLHIDOS

Foram selecionados 6 modelos de Inteligência Artificial para o presente experimento. O único critério de escolha foi o consumo de poder computacional para o treinamento, que precisava ser baixo devido ao ambiente de desenvolvimento disponível. Os modelos selecionados são menores em tamanho e, portanto, exigem menos poder computacional para serem treinados e usados. No entanto, é importante mencionar que modelos maiores normalmente possuem uma maior capacidade de aprendizado e, logo, melhores resultados.

No quadro 1, está a arquitetura de cada modelo de RNA selecionado. O quadro apresenta o nome do modelo sendo a primeira coluna, o tamanho (ocupado em disco) do modelo a segunda coluna, o número de parâmetros (nós) de cada camada na terceira coluna e o número de camadas que o modelo possui. Os parâmetros possuem um "M" no final para indicar a casa dos milhões.

Quadro 1 – Arquitetura dos modelos testados

Modelo	Tamanho (MB)	Parâmetros	Camadas
MobileNetV2	14	3.5M	105
ResNet152V2	232	60.4M	307
DenseNet201	80	20.2M	402
DenseNet121	33	8.1M	242
NASNetMobile	23	5.3M	389
EfficientNetV2B0	29	7.2M	-

Fonte: Disponível em: <https://keras.io/api/applications/>. Acesso em: 25 maio 2023.

3.2 COLETA E ORGANIZAÇÃO DOS DADOS

O primeiro passo no processo de desenvolvimento é a coleta e organização dos dados. Como os modelos escolhidos tem uma entrada de tamanho fixo em pixels, as imagens devem ter o mesmo tamanho. Caso uma imagem possua um tamanho diferente do esperado (em pixels), o modelo lançará um erro indicando essa discrepância.

O dataset possui imagens de tamanhos variados, e para contornar a problemática dos tamanhos das imagens de entrada dos modelos, faz-se necessário o uso de técnicas de redimensionamento de imagens. No presente trabalho, foi utilizado uma biblioteca de leitura

e manipulação de imagens chamado OpenCv. Com essa ferramenta, foi possível ler a imagem, manipular, e, resolvendo a problemática dos tamanhos, redimensionar.

Conforme abordado por (GÉRON, 2019), uma das transformações mais importantes que é preciso aplicar aos dados é o redimensionamento. Com poucas exceções, os algoritmos de aprendizado de máquina não funcionam bem quando os atributos numéricos de entrada têm escalas muito diferentes. No presente projeto, a técnica de redimensionamento utilizada é a *min-max scaling*, ou apenas normalização, que consiste em subtrair de todos os pixels da imagem o valor mínimo e dividir pelo valor máximo menos o valor mínimo. O valor máximo em imagens é 255 e o valor mínimo é 0, quando se usa a técnica de normalização, os pixels saem da frequência de 0 a 255, para 0 a 1.

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} = \frac{x}{255} \quad (4)$$

Dentro do fluxo de coleta e organização dos dados, realiza-se a leitura das imagens, seu redimensionamento, normalização e arquivamento em memória (variável que terá os dados tratados). Para suas respectivas classes (labels), existe o fluxo de leitura das classes e arquivamento em memória. Ao final desse processo, obtemos dois arrays: X, que contém as imagens representadas como matrizes de pixels, e y, que contém as classes a que cada imagem pertence.

3.3 TREINAMENTO DOS MODELOS

Na fase de treino dos modelos, após os dados serem lidos e as variáveis de X e y forem geradas, os modelos tem a saída de sua rede neural alterada. A saída dos modelos deve ser alterada para terem as classes fogo, fumaça e normal, pois os modelos são desenvolvidos com classes já estabelecidas, um exemplo é o MobileNetV2 que é um modelo de classificação para classes genéricas, como pessoa, armário, sapato, etc.

Os modelos de IA usados nesse trabalho são do framework Keras, sendo que esses modelos foram treinados, previamente, com o dataset ImageNet. Como os modelos são previamente treinados, eles são capazes de reconhecer certas classes e, portanto, certas características de objetos como forma e cor. Portanto, é feito um retreino, chamado geralmente de *fine-tuning*, para aproveitar o que o modelo já "sabe", aprendendo algo novo, como detectar fogo e fumaça.

Para o treinamento, foram utilizadas 6654 imagens, sendo 2218 com fogo, 2218 com

fumaça e 2218 sem fogo nem fumaça. Cada modelo foi treinado usando 50 epochs. Após esse treino, é esperado que o modelo consiga reconhecer as classes treinadas, fogo, fumaça e normal, de forma satisfatória, visando atingir cerca de 90% nas métricas de avaliação, como descrito anteriormente.

3.4 TESTE DOS MODELOS

Para testar os modelos, foi usado o conjunto de imagens de teste, composto por 3000 imagens, sendo 1000 com fogo, 1000 com fumaça e 1000 sem fogo nem fumaça. O modelo testado usa essas imagens e tenta prever sua classe. Quanto mais acertos em todas as classes, melhor o modelo treinado. Para avaliação dos modelos, as métricas de avaliação acurácia, precisão, recall e f1-score foram usadas.

4 RESULTADOS

Após a etapa de teste dos modelos, o resultado numérico da acurácia, precisão, recall e f1-score foram coletados para cada modelo. O resultado será apresentado em formato de quadro para cada modelo, apresentando os valores das métricas para cada classe avaliada. As classes fogo, fumaça e normal, serão avaliadas com as métricas precisão, recall e f1-score, por modelo. E a acurácia avaliará cada modelo individualmente.

Quadro 2 – Resultados das acurácias dos modelos

Modelo	Acurácia
MobileNetV2	0.92
ResNet152V2	0.94
DenseNet201	0.94
DenseNet121	0.95
NASNetMobile	0.81
EfficientNetV2B0	0.33

Fonte: O autor (2023).

Quadro 3 – Resultados do modelo MobileNetV2

Classe	Precisão	Recall	F1-score
Fogo	0.98	0.83	0.90
Fumaça	0.85	0.99	0.92
Normal	0.94	0.92	0.92

Fonte: O autor (2023).

Quadro 4 – Resultados do modelo ResNet152V2

Classe	Precisão	Recall	F1-score
Fogo	0.92	0.97	0.94
Fumaça	0.97	0.95	0.96
Normal	0.95	0.92	0.93

Fonte: O autor (2023).

Os modelos que alcançaram uma pontuação de 90% em todas as métricas de avaliação para todas as classes foram o ResNet152V2 e o DenseNet121, conforme apresentado no quadro 1. Entre os modelos que atingiram a meta, o DenseNet121 se destaca

por ser o menor em termos de tamanho, número de parâmetros e camadas. Embora o ResNet152V2 tenha obtido melhores resultados em algumas métricas, para algumas classes, ele é aproximadamente 7 vezes maior em tamanho, possui cerca de 7 vezes mais parâmetros e quase o dobro de camadas.

Quadro 5 – Resultados do modelo DenseNet201

Classe	Precisão	Recall	F1-score
Fogo	0.97	0.91	0.94
Fumaça	0.89	0.99	0.94
Normal	0.95	0.92	0.94

Fonte: O autor (2023).

Quadro 6 – Resultados do modelo DenseNet121

Classe	Precisão	Recall	F1-score
Fogo	0.92	0.96	0.94
Fumaça	0.96	0.99	0.98
Normal	0.98	0.91	0.94

Fonte: O autor (2023).

Quadro 7 – Resultados do modelo NASNetMobile

Classe	Precisão	Recall	F1-score
Fogo	0.66	0.99	0.79
Fumaça	0.94	0.77	0.84
Normal	0.83	0.74	0.78

Fonte: O autor (2023).

Quadro 8 – Resultados do modelo EfficientNetV2B0

Classe	Precisão	Recall	F1-score
Fogo	0.00	0.00	0.00
Fumaça	0.00	0.00	0.00
Normal	1.00	0.33	0.50

Fonte: O autor (2023).

Portanto, considerando os resultados das métricas de avaliação e a eficiência em termos de arquitetura, o modelo DenseNet121 é considerado a melhor escolha para a solução do problema neste trabalho.

5 CONCLUSÃO

Ao longo deste trabalho, foi investigado o impacto da aplicação de RNAs no reconhecimento de fogo e fumaça em imagens. Os objetivos estabelecidos foram alcançados por meio da seleção, treinamento e avaliação de diversos modelos de redes neurais com dados coletados.

Os resultados obtidos demonstraram a eficácia das RNAs na tarefa de reconhecimento de fogo e fumaça em imagens, com taxas superiores a 90% para todas as classes avaliadas. Os modelos ResNet152V2 e DenseNet121 se destacaram como os mais eficientes, cumprindo os critérios de desempenho estabelecidos.

Além disso, foi possível observar que, embora o modelo ResNet152V2 tenha apresentado um desempenho ligeiramente superior em algumas de métricas de avaliação, para algumas classes, o modelo DenseNet121 se destacou pelo seu desempenho e arquitetura reduzida. O modelo DenseNet121 se mostrou a escolha mais adequada para a resolução do problema abordado neste trabalho.

As conclusões obtidas com este estudo contribuem para o avanço do campo de reconhecimento de fogo e fumaça por meio de redes neurais artificiais. Os resultados evidenciam a importância de considerar não apenas o desempenho dos modelos, mas também suas características de tamanho e complexidade computacional. Essa análise pode auxiliar na seleção adequada de modelos para aplicações práticas, considerando as restrições de recursos computacionais disponíveis.

Por fim, ressaltamos a relevância de futuras pesquisas que explorem ainda mais os diferentes modelos de Inteligência Artificial existentes, bem como sua aplicação em outros domínios e conjuntos de dados. Essas investigações podem contribuir para aprimorar ainda mais o desempenho e a eficiência dessas redes, impulsionando avanços em reconhecimento de objetos e áreas relacionadas. Além disso, futuras pesquisas podem explorar o problema de detecção de objetos, usando modelos de detecção para a localização de fogo e fumaça em imagens.

Em suma, este trabalho apresentou resultados promissores, proporcionando uma base sólida para futuros estudos e aplicações práticas nesse campo em constante evolução.

REFERÊNCIAS

CHENG, H. *et al.* Smoke 100k: a database for smoke detection. *In: GLOBAL CONFERENCE ON CONSUMER ELECTRONICS*, 8., Osaka, Japan, 2019. **Proceedings** [...]. Osaka, Japan: IEEE, 2019. p. 596–597. Fonte: Disponível em: https://bigmms.github.io/cheng_gcce19_smoke100k/. Acesso em: 25 maio 2023.

GROSSI, E; BUSCEMA, M. Introduction to artificial neural networks. **European Journal of Gastroenterology Hepatology**, v, 19, n. 12, p. 1046-1054, dec. 2007. Disponível em: https://journals.lww.com/eurojgh/abstract/2007/12000/introduction_to_artificial_neural_networks.5.aspx. Acesso em: 25 maio 2023.

GÉRON, A. **Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: concepts, tools, and techniques to build intelligent systems**. 2nd ed. Sebastopol, CA, EUA: O'Reilly Media, 2019.

JADON, A. *et al.* FireNet: a specialized lightweight fire & smoke detection model for real-time IoT applications. **ArXiv**, Ithaca, NY, EUA: Cornell University, 04 sept. 2019. Disponível em: <https://arxiv.org/abs/1905.11922>. Acesso em: 25 maio 2019.

TRUE, N. **Computer vision based fire detection**. San Diego, CA, EUA: University of California, 2009. Disponível em: <https://cseweb.ucsd.edu/classes/wi09/cse190-a/reports/ntrue.pdf>. Acesso em: 25 maio 2023.

WU, H.; WU, D.; ZHAO, J. An intelligent fire detection approach through cameras based on computer vision methods. **Process Safety and Environmental Protection**, v. 127, p. 245-256, july 2019. Disponível em: https://www.researchgate.net/publication/333195147_An_intelligent_fire_detection_approach_through_cameras_based_on_computer_vision_methods. Acesso em: 25 maio 2023.