



## MONITORAMENTO DE INCÊNDIO COM REDE NEURAL CONVOLUCIONAL

Leandro Bernardo <sup>1</sup> ; Ivanovich Lache <sup>2</sup> ; Clara Gadelha <sup>3</sup>

**Palavras-Chave** – Detecção de Fogo e Fumaça, Edge Computing, Machine Learning, Computer Vision

### INTRODUÇÃO

Detectar fogo em estágio inicial, antes que ele se transforme em um evento catastrófico, é crucial para evitar desastres, salvar vidas e propriedades. Dentro desse aspecto preventivista, a proteção florestal é uma parte fundamental, pois o incêndio mostra-se como o principal agente causador de danos às florestas ao redor do mundo (SOARES, 1972). Contudo, no passado, a atenção era quase que totalmente dirigida para se estimar as atividades de supressão do fogo, procurando estabelecer a extensão dos aperfeiçoamentos aplicados na supressão dos incêndios (VINES, 1969). A tendência moderna, no entanto, é dedicar maior atenção às etapas de prevenção e pré supressão.

Embora os sensores de detecção de incêndio e fumaça sejam amplamente instalados em ambientes internos, eles geralmente exigem que o fogo queime por um tempo para produzir uma grande quantidade de fumaça e, em seguida, acionar o alarme. Além disso, esses dispositivos não podem ser implantados em ambientes externos, de grande escala (por exemplo, uma floresta). Contudo, um sistema de detecção de incêndio baseado na visão, capturando imagens de câmeras e detectando o incêndio imediatamente, mostra-se adequado para detecção precoce de incêndio (ZHANG, 2016).

Recentemente, após grandes avanços nas estruturas de programação e no *Machine Learning*, os sistemas computacionais são capazes de monitorar em tempo real. Os modelos de *Machine Learning* são usados para encontrar uma relação entre os dados não convencionais e seus componentes usando funções não lineares (SCARDAPANE, 2020); são capazes de aprender relações implícitas e, assim, tomar decisões sem exigir instruções explícitas (KHAN et al, 2020).

Sendo o objetivo principal detectar fogo em estágio inicial, então, o modelo principal (modelo 1) de Bernardo et al (2022) foi utilizado. Este projeto propõe um modelo utilizando *Computer Vision* e *Convolutional Neural Network (CNN)*, para detectar fumaça e, conseqüentemente, prevenir incêndios. Sendo uma CNN um tipo especial de Rede Neural que trabalha com imagens e tem apresentado desempenho excepcional em diversas áreas relacionadas à Visão Computacional e processamento de Imagens (KHAN et al, 2020). Portanto, uma vez que a fumaça apareça em qualquer câmera de monitoramento, o sistema pode detectar e emitir um alerta racional e instantâneo.

### MATERIAIS E MÉTODOS

#### Dados

Ao se desenvolver uma rede neural, uma das etapas mais importantes é encontrar uma fonte de dados confiáveis que será utilizada para ensinar ao computador. Deve-se evitar enviesamentos e que tendências pessoais sejam transferidas ao longo do processo de aprendizagem. Na prática a proporção de dados reais é muitas vezes tendenciosa (TANIGUCHI et al, 2018). Portanto, a fim de melhorar a rede neural desenvolvida por Bernardo et al (2022), foi usada uma base de dados ampliada com mais vídeos de incêndios florestais, como demonstra a tabela 1. Os vídeos começaram a ser disponibilizados por Toreyin et al (2006) e são uma referência na literatura para detecção de fogo.

<sup>1</sup>) Estudante de graduação de engenharia de recursos hídricos e do meio ambiente, Universidade federal fluminense, leandropb@id.uff.br

<sup>2</sup>) Professor no departamento de engenharia agrícola e do meio ambiente, Universidade federal fluminense, ilache@id.uff.br

<sup>3</sup>) Estudante de graduação de engenharia de recursos hídricos e do meio ambiente, Universidade federal fluminense, claragadelha@gmail.com

Tabela 1 – Vídeos de Toreyin utilizados

Nome do Vídeo	Imagens
20090409 ManavgatTEs	224
20070817_Aksehir_Duman_Test5_en_Iyisi_near_487_frame	102
Smoke_Manavgat_Raw	172
Pelco Colakli	155

As 664 imagens foram separadas em dois diretórios, sendo eles “Treinamento” e “Validação”, na proporção recomendada pela literatura de 80% / 20%. Ambos diretórios contendo imagens de “Fumaça” e “Não Fumaça” com certa similaridade. Em seguida, foi feita uma validação com imagens inéditas à Rede Neural. Foram escolhidas 50 imagens da internet (25 de fumaça e 25 de não fumaça). A tabela 2 demonstra a divisão:

Tabela 2 – Quantidade de imagens em cada diretório

	Treinamento	Validação	Validação Inédita
Fumaça	269 imagens	54 imagens	25 imagens
Não Fumaça	275 imagens	55 imagens	25 imagens

## Modelo

O modelo deste presente artigo é a continuação da pesquisa de Bernardo et al (2022), e seus hiperparâmetros podem ser vistos na Figura 1




Figura 1 – Hiperparâmetros do Modelo 7. Fonte: autoria própria.

Após serem definidos os hiperparâmetros (valores que caracterizam a estrutura da rede), o modelo foi submetido a 1000 treinamentos com o diretório “Treinamento” (contendo 544 imagens). No final de cada *epoch* foram salvos os valores de *accuracy*, ao longo dos 1000 treinamentos, para verificar se o modelo ainda seria igualmente eficiente nos treinamentos como proposto por Bernardo et al (2022) (com um banco de dados menor, contendo 224 imagens). Foi utilizada uma classificação Binária (“Fumaça” ou Não-Fumaça) com uma *output layer* com função de ativação Sigmoid, sendo essa a Função de Ativação majoritariamente mais utilizada para classificação binária (SHARMA et al, 2017).

Após avaliar os resultados, o modelo teve seu número de *Epochs* aumentados para 35 para verificar a eficiência no aprendizado (ao longo dos 1000 treinamentos).

Por fim, o modelo final foi treinado com 27 *Epochs* e, com isso, foram feitos os testes de validação com as imagens do diretório “Validação” e com imagens inéditas retiradas da internet. Nesses testes, a precisão de acertos do modelo foi avaliada ao longo de 1000 tentativas (cada teste).

## RESULTADOS

### Treinamento

Ao utilizar um bancos de dados com mais imagens, a relação *Accuracy x Epoch* do modelo foi menor quando comparado com os treinamentos de Bernardo et al (2022) (contendo 224 imagens). O Modelo teve uma média de 87% de *Accuracy* e evidenciando uma queda no desempenho (em comparação aos 97%, com o banco de dados anterior), como mostra a figura 2

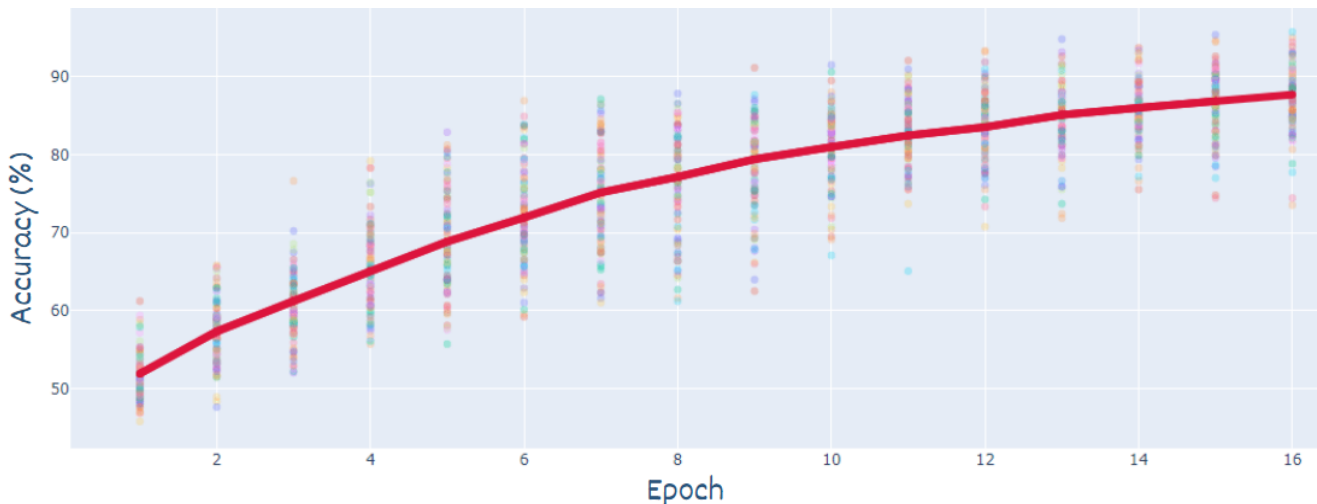


Figura 2 – Treinamento do Modelo com 16 Epochs e 544 imagens. Fonte: autoria própria.

Para resolver isso, o número de Epochs foi aumentado para 35, então o modelo foi submetido a mais 1000 treinamentos. Com isso, o modelo teve um aprendizado melhor, como pode ser visto na figura 3




Figura 3 – Treinamento do Modelo com 35 Epochs e 544 imagens. Fonte: autoria própria.

Como é mostrado na figura 4, o aprendizado do modelo, a partir de certo ponto, não apresenta grandes taxas de crescimento; obtendo 3.5% a mais de *Accuracy* ao longo de mais nove *Epochs*. A fim de evitar gastos desnecessários de recursos computacionais, com excesso de *Epochs*, o número final de *Epochs* ficou definido como 27; apresentando uma média de 94.6% de *Accuracy*.

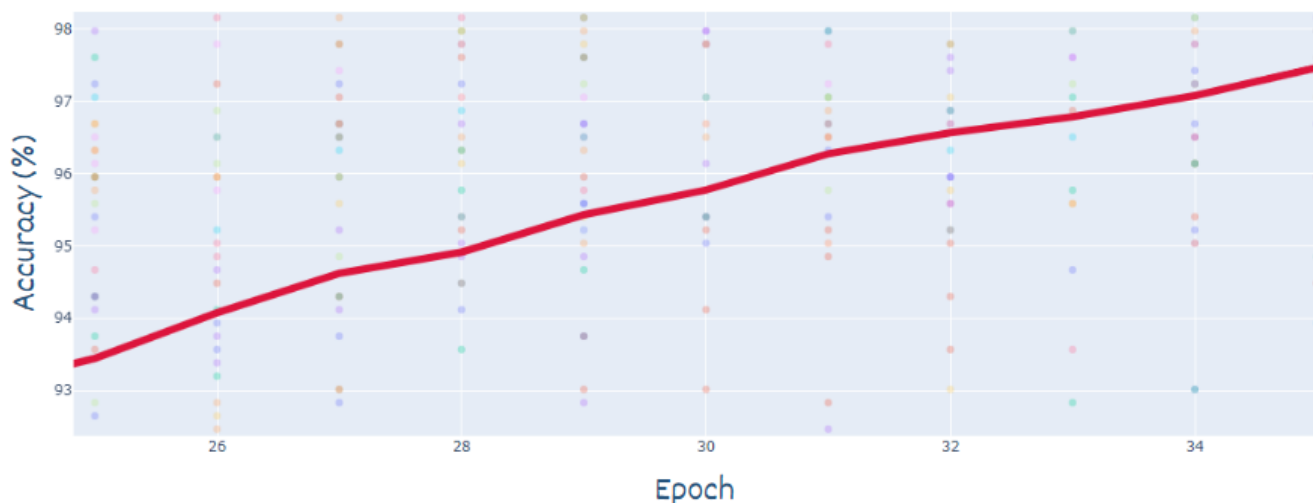


Figura 4 – Últimas Epochs do treinamento do Modelo com 35 Epochs. Fonte: autoria própria.

### Validação

A validação foi realizada com o diretório “Validação” contendo 109 imagens retiradas do banco de dados original (contendo 664 imagens). O modelo apresentou 97.1% de acerto e o resultado é mostrado na tabela 3.

Tabela 3 - Validação com imagens do banco de dados

Validação		
Acertos	Falsos Positivos	Falsos Negativos
971	21	8

Na validação com imagens inéditas à Rede Neural, com 50 imagens da internet (25 de fumaça e 25 de não fumaça), o modelo apresentou 54.4% de acerto e o resultado é mostrado na tabela 4.

Tabela 4 - Validação com imagens da internet

Validação		
Acertos	Falsos Positivos	Falsos Negativos
544	393	63

### CONCLUSÕES

Os dois testes de validação (com imagens similares às do banco de dados e com imagens inéditas) ratificam a principal limitação relacionada ao Machine Learning: *acesso a um banco de dados suficientemente grande* e não enviesado com tendências pessoais.

Contudo, o modelo apresentado mostrou-se suficiente em dois cenários. O primeiro cenário é o uso em ambientes onde a Rede teve previamente acesso a imagens do local para o seu treinamento; *podendo assim, ser aplicada para monitorar incêndio*, desde que o local não seja alterado. O segundo cenário é tal que, uma vez que o banco de dados seja ampliado (através de uma fonte de dados consideravelmente maior), a Rede poderá treinar com imagens diversas. Com isso, *evita-se que o banco de dados seja decorado* e, portanto, o modelo *podará ser aplicado para monitorar incêndio em lugares diversos*, sem precisar ter visto o local previamente. Portanto, ambas soluções são adequadas para usos específicos.

## REFERÊNCIAS

BERNARDO, Leandro et al. **Redes Neurais para monitoramento de incêndio.** 2022

KHAN, Asifullah et al. **A survey of the recent architectures of deep convolutional neural networks.** Artificial intelligence review, v. 53, n. 8, p. 5455-5516, 2020.

SCARDAPANE, Simone; TROVINI, Giovanni; SABBELLA, Sandeep Reddy. Fire and Smoke Detection for Smart Cities Using Deep Neural Networks and Edge Computing on Embedded Sensors.

SHARMA, Sagar; SHARMA, Simone; ATHAIYA, Anidhya. **Activation functions in neural networks.** towards data science, v. 6, n. 12, p. 310-316, 2017.

TÖREYİN, B. Uğur et al. **Computer vision based method for real-time fire and flame detection.** Pattern recognition letters, v. 27, n. 1, p. 49-58, 2006. Disponível em: <<http://signal.ee.bilkent.edu.tr/VisiFire/>>. Acesso em 10 de Set. de 2022.

ZHANG, Qingjie et al. Deep convolutional neural networks for forest fire detection. In: **2016 International Forum on Management, Education and Information Technology Application.** Atlantis Press, 2016. p. 568-575.