

INPE

Fotografia de satélite, 2020

# MONITORAMENTO DE INCÊNDIOS POR MEIO DE REDES E LINHAS AÉREAS DE ENERGIA ELÉTRICA

ADRIANO CHAVES LISBOA\*

PEDRO VINÍCIUS ALMEIDA BORGES DE VENÂNCIO\*\*

ARLINDO FOLLADOR NETO\*\*\*

HERMES AGUIAR MAGALHÃES\*\*\*\*

CARLOS ALEXANDRE MEIRELES NASCIMENTO\*\*\*\*\*

HANI CAMILLE YEHIA\*\*\*\*\*

**RESUMO** As redes e linhas aéreas de energia elétrica são vistas, muitas vezes, como algo danoso ao ambiente, mesmo levando qualidade de vida e progresso à sociedade. Poucas pessoas concordam em ter uma rede ou linha de energia cruzando suas terras. O monitoramento ambiental de redes e linhas de energia possibilita à sociedade verificar pela internet o que está ocorrendo na região das redes e das linhas aéreas de energia, o que promove uma aproximação entre a sociedade e as empresas que instalam essa infraestrutura vital para o desenvolvimento econômico e social. Neste trabalho, o monitoramento ambiental se dá pela detecção de incêndios, eventos que provocam estragos nas redes e linhas aéreas de energia e trazem prejuízos para todas as populações – humana, animal e vegetal – ao seu redor. Essa detecção de incêndio é feita utilizando aprendizado profundo de máquina, que é capaz de atingir precisões da ordem de 99% ao detectar fogo e fumaça em situações adversas.

**PALAVRAS-CHAVE** Monitoramento ambiental. Interação com a sociedade. Detecção de incêndio.

## WILDFIRE MONITORING FROM ELECTRIC NETWORKS AND TRANSMISSION LINES

**ABSTRACT** Electric networks and transmission lines are many times seen as something hazardous, even when bringing life quality and progress to society. Few people agree to have an electric network or line crossing their lands. The environmental monitoring of electric networks and lines allows society to see in the internet what is happening around electric networks and lines and, hence, promotes a closer relation between society and utilities vital to economic and social development. In this work, the environmental monitoring is made using fire detection, a phenomenon that damages not only electric networks and lines, but also humans, animals and plants around. Such wildfire detection is performed using deep learning, which can achieve precisions of about 99% and detect fire and smoke in adverse situations.

**KEYWORDS** Environmental monitoring. Interaction with society. Wildfire detection.

\* Gaia Soluções em Engenharia - [adriano.lisboa@gaiasd.com](mailto:adriano.lisboa@gaiasd.com); \*\* Gaia Soluções em Engenharia - [pedro.venancio@gaiasd.com](mailto:pedro.venancio@gaiasd.com); \*\*\* Universidade Federal dos Vales do Jequitinhonha e Mucuri (UFVJM) - [arlindo.neto@ict.ufvjm.edu.br](mailto:arlindo.neto@ict.ufvjm.edu.br); \*\*\*\* Universidade Federal de Minas Gerais (UFMG) - [hermesaguiar@ufmg.br](mailto:hermesaguiar@ufmg.br); \*\*\*\*\* Companhia Energética de Minas Gerais S/A (Cemig) - [caxandre@cemig.com.br](mailto:caxandre@cemig.com.br); \*\*\*\*\* Universidade Federal de Minas Gerais (UFMG) - [hani@ufmg.br](mailto:hani@ufmg.br)

## Introdução

As redes e linhas aéreas de energia elétrica são vistas, muitas vezes, como algo danoso ao ambiente, mesmo levando qualidade de vida e progresso para a sociedade. Poucas pessoas concordam em ter uma rede ou linha de energia cruzando suas terras. O monitoramento ambiental por meio das redes e linhas aéreas de energia possibilita à sociedade ter conhecimento sobre o que está ocorrendo no entorno dessas instalações e, assim, promover uma aproximação entre a população e as empresas do setor de distribuição e transmissão de energia elétrica.


Neste trabalho, o monitoramento ambiental se dá pela detecção de incêndios, eventos que provocam estragos para as empresas de distribuição e transmissão de energia e trazem prejuízos para todas as populações – humana, animal e vegetal – ao seu redor.

As queimadas são causadoras de interrupções no fornecimento de energia elétrica e também responsáveis por grande parte da destruição da flora e da fauna brasileiras. De acordo com o Instituto Nacional de Pesquisas Espaciais (Inpe, 2019), Minas Gerais registrou 4.487 focos de incêndio durante o ano de 2018 (FIG. 1), dos quais a grande

maioria concentra-se nos meses de agosto a outubro (FIG. 2). De forma a ilustrar a concentração de focos de incêndio na região de Minas Gerais, a Figura 3 mostra o mapa com o risco de incêndios no Brasil em janeiro de 2019. Mais do que as causas naturais, a crescente demanda do agro-negócio tem causado uma extensa substituição de áreas florestais por áreas de criação de gado e plantio, segundo estudos da World Wildlife Fund (WWF, 2018).

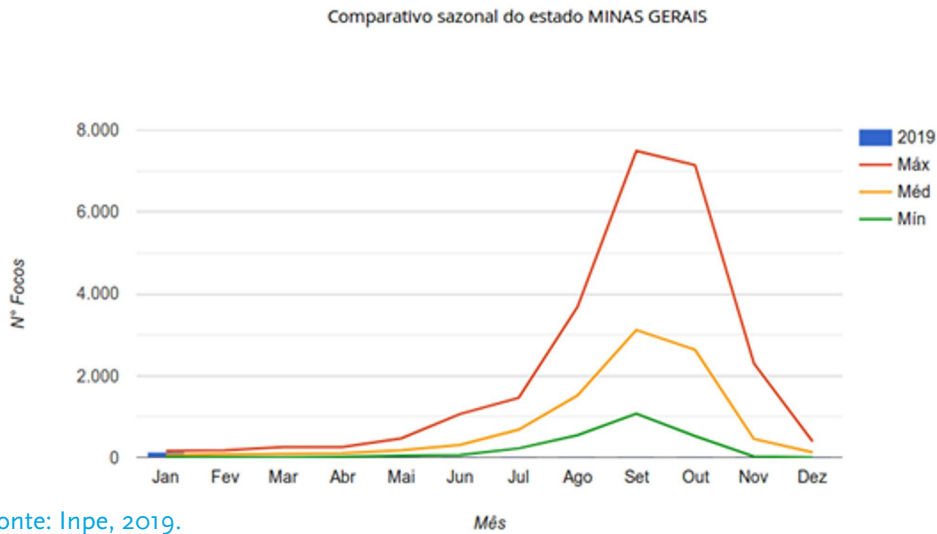
Figura 1- Série histórica do total de focos ativos de incêndio detectados pelo satélite de referência do Inpe no período de janeiro de 1998 até janeiro de 2019

Série histórica do estado MINAS GERAIS




Fonte: Inpe, 2019.

Figura 2 - Valores máximos, médios e mínimos do número de focos de incêndio ao longo dos meses do ano com base no período de 1998 a 2018



Fonte: Inpe, 2019.

Figura 3 - Risco de incêndio no Brasil em 30 de janeiro de 2019



Fonte: Inpe, 2019.

De acordo com levantamento da Companhia Energética de Minas Gerais (Cemig, 2017), a principal causa de incêndios florestais em Minas é a queima preparatória de pastos e de terrenos para plantio, quando o fogo é usado como uma ferramenta eficiente e barata de preparo do solo, especialmente em períodos de altas temperaturas e baixa umidade do ar. Outras causas são a queima de lixo, tocos de cigarros jogados em beiras de estradas, que atingem a vegetação seca, e descargas atmosféricas.

Ao atingir redes e linhas aéreas de energia, os incêndios podem provocar o rompimento dessas estruturas e dos cabos condutores com a queima de postes e cruzetas de madeira e, conseqüentemente, interromper o fornecimento de energia elétrica. Nesses casos, para religar os circuitos atingidos, é necessário recompor os materiais, atividade que exige um tempo maior para ser executada. Há, ainda, o risco de curtos-circuitos em redes e linhas aéreas de energia elétrica, causados pelo aquecimento dos cabos condutores acima dos valores de projeto.

Com uma rede de distribuição de mais de 500 mil quilômetros de extensão, a Cemig é responsável por distribuir energia elétrica para mais de 8 milhões de consumidores em Minas Gerais. Dessa forma, pode-se pensar no uso de ativos da empresa para auxiliar no monitoramento ambiental e, assim, utilizar o importante ativo de linhas e redes aéreas para a nobre função adicional de detectar focos de incêndio em seus estágios iniciais. Esse é o objetivo central deste trabalho, o qual está sendo desenvolvido por meio do projeto de pesquisa e desenvolvimento da Agência Nacional de Energia Elétrica (P&D Aneel) “Monitoramento ambiental por visão computacional aplicado a situações reais” (Do619), financiado pela Cemig-D e executado em parceria entre a Universidade Federal de Minas Gerais (UFMG) e a Gaia, soluções sob demanda.

A detecção precoce de incêndios é uma tarefa vital por razões econômicas, sociais e ambientais. A identificação de focos de incêndio em seus estágios iniciais é um fator crítico na determinação da quantidade de danos causados. Em áreas abertas, essa tarefa é tipicamente realizada por humanos – seguranças, por exemplo –, que devem estar atentos a possíveis ocorrências. No entanto, pessoas podem se distrair, ou simplesmente não ter a visão necessária, o que faz um incêndio ser identificado somente após um período considerável de tempo, quando já não é possível evitar danos consideráveis.

Um sistema mais confiável é o alarme de incêndio instalado em edifícios, baseado em sensores de fumaça, o qual detecta a presença de partículas de fumaça no ar, possivelmen-

te originadas de um incêndio. No entanto, seu uso é limitado, uma vez que os sensores precisam estar próximos à fonte e, portanto, não podem ser usados em grandes áreas abertas, onde a fumaça leva tempo considerável até atingir sua posição. Além disso, não fornecem informações adicionais sobre o incêndio, como a dimensão e a localização. Considerando essas necessidades, o monitoramento assistido por câmeras ganhou grande destaque, principalmente em situações que utilizam câmeras estáticas, tais como os sistemas de vigilância baseados em circuitos fechados de televisão (CFTV) (STEFFENS, 2015).

Em um monitoramento ambiental de larga escala, é necessária uma quantidade significativa de câmeras para a cobertura da área de interesse. Diante disso, a ideia de se utilizar uma quantidade menor de câmeras, porém móveis, é consideravelmente mais interessante, principalmente pela redução de custos e pelo ganho de varredura. Ainda assim, a utilização de câmeras móveis implica maior complexidade do sistema de detecção, visto que inclui rotação em três eixos, maior número de trepidações e variações no fundo e na luminosidade.

Dessa forma, a ideia de deixar que máquinas detectem automaticamente esses eventos sempre foi uma possibilidade mais interessante. Ao longo dos anos, diferentes abordagens para detecção de fogo e fumaça por computador foram desenvolvidas (DIOS et al., 2008). Inicialmente, eles eram todos baseados em regras. O processo geralmente envolvia duas etapas: extrair recursos projetados com base em conhecimento especializado para capturar alguma particularidade de fogo ou fumaça, como cor, movimento ou comportamento temporal, e aplicar algoritmos tradicionais para classificar imagens com base nesses recursos (KONG et al., 2016).

Entretanto, as trepidações causadas no suporte de fixação da câmera ou durante o seu movimento de rotação interferem diretamente na qualidade das gravações. Assim, algoritmos que utilizam combinações da análise estatística de recursos visuais e análise temporal de informações de movimento tornam-se totalmente inviáveis, visto que a instabilidade também compromete a extração de características (VIEIRA et al., 2015). Essa extração de características, por sua vez, depende de especialistas e, quando mal projetada, pode levar a erros na criação de modelos baseados em regras e na seleção de recursos discriminativos. Na maioria das vezes, quando técnicas de extração de características mostram bom desempenho, os recursos projetados geralmente são para dados específicos (HOHBERG, 2015).

Uma abordagem diferente para esse problema é usar um algoritmo de aprendizado de máquina para extrair as características úteis, em vez de usar um especialista para defini-las. Redes neurais convolucionais, variante da aprendizagem profunda, possibilitam extrair propriedades topológicas de cada quadro dos vídeos e, portanto, aprender essas características para detectar fogo e fumaça sem dependência alguma da estabilidade da câmera.

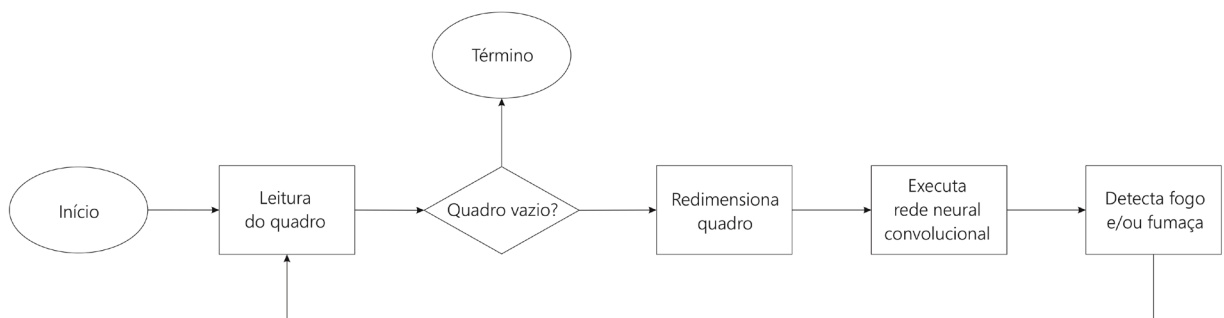
## 1 Desenvolvimento

### 1.1 Estratégia adotada

Garantir que a câmera execute rotação ou translação sem que haja consequências relevantes na detecção de incêndios em tempo real é de extrema importância para que uma abordagem seja robusta e confiável. Ao contrário de algumas ferramentas de *hardware* para uso comercial, como estabilizadores, a estratégia menos dispendiosa encontrada não garante estabilidade das câmeras envolvidas no monitoramento, mas possibilita que a detecção seja totalmente independente dela.

Por meio da segmentação do vídeo em uma sequência de quadros, o método investigado realiza uma análise quadro a quadro. Essa análise consiste em prever uma lista de detecções com suas respectivas probabilidades para cada quadro presente no vídeo, de forma independente. O processo, ilustrado na Figura 4, possibilita que movimentos da câmera ou de objetos durante as gravações não influenciem no desempenho do sistema.

Figura 4 - Fluxograma do sistema de detecção



Fonte: elaborado pelos autores.

A principal premissa que precisa ser levada em conta é o questionamento do tempo de execução para cada quadro. É normal pensar que se o tempo de execução para análise do quadro for alto, a detecção em tempo real se tornará completamente inviável. No entanto, a rede neural convolucional adotada realiza tarefas em paralelo para reduzir esse tempo e pode atingir, em sua versão original, 45 quadros por segundo. Uma versão alternativa ainda mais rápida, porém, com uma precisão de detecção relativamente pior, pode atingir até 155 quadros por segundo. Portanto, detectar fogo por meio de uma análise de quadros é uma solução promissora, em razão da flexibilidade de uso, ubiquidade e crescente qualidade de resolução das câmeras de segurança. Além disso, o mesmo sistema usado para detectar o fogo também é capaz de detectar a fumaça, que é o indicador visual mais óbvio do fogo e, muitas vezes, o único, especialmente em longas distâncias.

Identificar a presença de fogo ou fumaça não é uma tarefa fácil. Ambas as classes são abstratas e podem assumir diversas cores e formas, o que dificulta o aprendizado do modelo ao tentar generalizá-las. Com isso, o sistema pode realizar alarmes falsos (falsos positivos) ou até mesmo deixar de detectar situações reais de incêndio (falsos negativos). Para evitar esses problemas de detecção, torna-se essencial um banco de dados representativo e balanceado. Esse conjunto especial de dados rotulados fornece informações úteis para o aprendizado supervisionado e, conseqüentemente, para a construção de um modelo que seja capaz de detectar incêndios nas circunstâncias apresentadas a ele. Assim, empregar maior diversidade aos dados com situações distintas de ocorrência de fogo e fumaça também garante maior robustez às variações de fundo e iluminação, provocadas pelo movimento e pelo ambiente no qual a câmera está localizada.

## *1.2 Aprendizado profundo de máquina*

Na última década, o interesse pelo aprendizado profundo de máquina cresceu consideravelmente. Uma das áreas mais afetadas foi a de visão computacional. A competição de reconhecimento visual em grande escala da organização ImageNet comprova isso (IMAGENET, 2019). Nela, os modelos de aprendizado de máquina competem para realizar a classificação de objetos, com milhares de classes e milhões de imagens. Desde a introdução da primeira rede neural convolucional em 2012, a precisão melhorou gradualmente, superando em média a de uma pessoa.



Inicialmente, a identificação de objetos foi realizada usando recursos codificados manualmente; projetistas especificaram relações referenciais (por exemplo, a forma triangular de dois olhos e um nariz), que foram buscadas pelo algoritmo e, assim, levaram a uma identificação. Naturalmente, isso apresentava problemas graves, como a necessidade de codificar explicitamente cada nova referência e a incapacidade de identificar imagens com pequenas variações de ângulo e forma. Com o ressurgimento das redes neurais na área de aprendizado profundo de máquina, esse cenário mudou completamente. As redes neurais convolucionais foram capazes de realizar a classificação de objetos com taxas de precisão consideráveis. Além disso, essa solução era elegante e altamente generalizável.

Com relação à detecção, existia uma dificuldade adicional: como identificar não apenas a existência de um objeto, mas também sua localização na imagem? A abordagem inicial era usar uma janela deslizante, que passava pela imagem até encontrar o objeto. Apesar de funcionar bem em algumas aplicações, as janelas deslizantes são ineficientes e demandam tempo. Em seguida, vieram os métodos de propostas de região, que primeiro tentavam identificar partes da imagem que pareciam pertencer ao mesmo objeto, para, posteriormente, determinar a existência e a identificação do objeto. Esse tipo de método ainda é muito usado atualmente. No entanto, se assumirmos que a rede tem informações suficientes para determinar se um objeto está em uma imagem, faz sentido acreditar que ela também tenha informações para encontrar a localização desse objeto.


### *1.2.1 Redes neurais artificiais*

As redes neurais artificiais (RNAs) são modelos computacionais matemáticos inspirados, ainda que vagamente, no sistema nervoso de animais, mais especificadamente no cérebro. Por meio de diversas unidades de processamento (neurônios artificiais) altamente conectadas e dispostas em camadas, elas visam processar informações e reconhecer padrões (DATA SCIENCE ACADEMY, 2018). Assim como o cérebro humano é capaz de aprender a tomar decisões baseadas em conhecimentos adquiridos, a rede neural também o é. A cada nova experiência, os neurônios artificiais envolvidos no processamento são aprimorados, podendo executar, ao final do aprendizado, tarefas de forma muitas vezes mais eficiente que os próprios seres humanos.

Matematicamente, cada entrada de um neurônio é multiplicada por um determinado peso  $w$  presente em cada conexão da rede. A soma ponderada das entradas é, então, encaminhada para o núcleo do neurônio, onde é modificada (viés  $b = r$ ) ou não (viés  $b = 0$ ), antes de ser processada por uma função de ativação  $f(x)$ , conforme demonstrado na Figura 5.


A primeira camada de uma rede neural é chamada de camada de entrada, enquanto a última é chamada de camada de saída. Todas as camadas entre as duas são referidas como camadas escondidas. Quando todos os neurônios de todas as camadas estão conectados entre si, a rede é dita totalmente conectada (FIG. 6). Além disso, redes neurais com mais de uma camada escondida são denominadas redes neurais profundas.

Figura 5 - Estrutura de uma rede neural de três camadas



Fonte: elaborada pelos autores.

Figura 6 - Rede neural simples totalmente conectada (esquerda) e rede neural profunda totalmente conectada (direita)



Fonte: elaborada pelos autores.

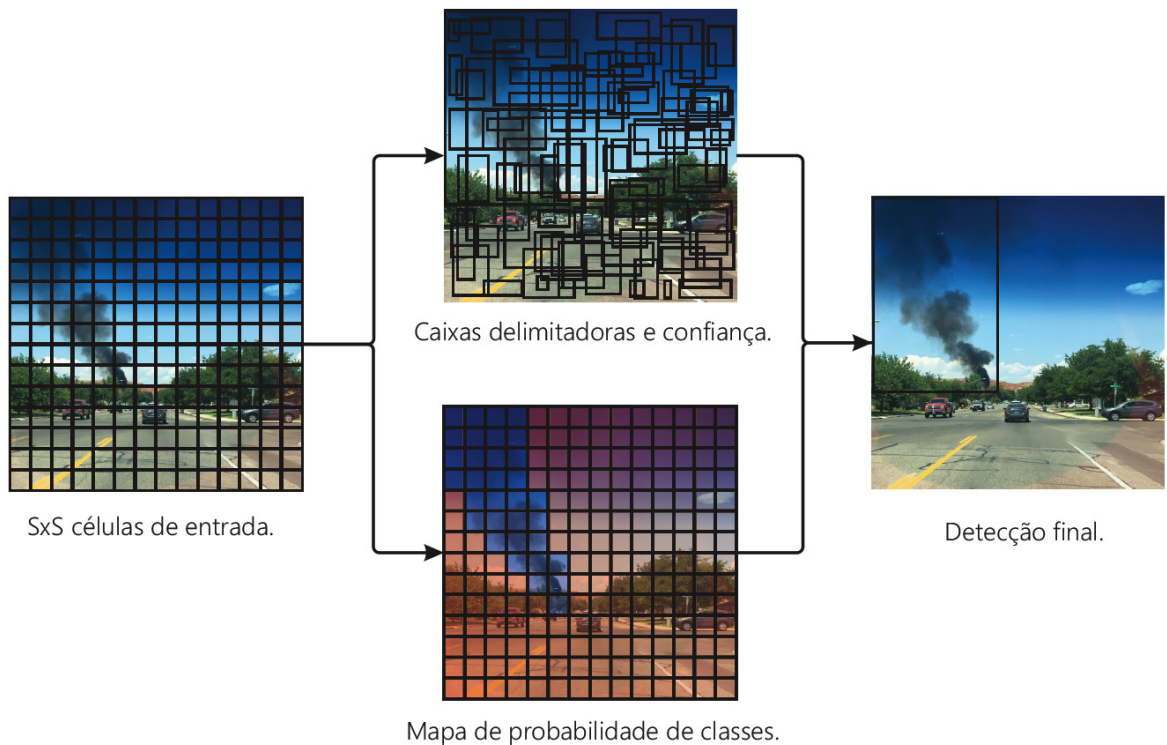
### 1.2.2 Algoritmo de detecção de objetos YOLO

Entre os melhores algoritmos de detecção de objetos que usam aprendizado profundo de máquina, está o YOLO – *You only look once* (Você só olha uma vez). Enquanto a maioria dos métodos separa a classificação da imagem das tarefas de identificação de localização, usando, por exemplo, janelas deslizantes, o algoritmo YOLO executa ambas as tarefas simultaneamente (o que justifica seu nome). Dessa forma, o YOLO inclui como variáveis a localização das caixas que delimitam os objetos, sendo, portanto, um método baseado em regressão. Essa abordagem conjunta o ajudou a se tornar o estado da arte, durante anos, em sistemas de reconhecimento de objetos em tempo real, em razão do compromisso entre velocidade e acurácia.

YOLO, já em sua terceira versão (YOLOv3), redimensiona a imagem de entrada para  $416 \times 416$ . Em seguida, divide a imagem em uma grade de células  $S \times S$  (ver Figura 7). Para cada uma das células  $S^2$ , são previstas  $B$  caixas delimitadoras de objetos, juntamente com probabilidades condicionais para a probabilidade de cada uma das classes  $C$  estar dentro dessa célula. (No caso específico do nosso problema, existem duas classes: fogo e fumaça.) Matematicamente, tem-se como predição um tensor de dimensão  $S \times S \times [3 \times (B + 1 + C)]$ .

Além disso, para cada caixa delimitadora, existe um valor de confiança que prevê se existe algum objeto dentro dela, sem especificar exatamente qual deles é o objeto e quão precisa é a caixa delimitadora. Se o valor de confiança para uma caixa delimitadora específica estiver acima de certo limite, a classe prevista poderá ser obtida observando as probabilidades condicionais da célula e selecionando o maior valor (REDMON et al., 2016).

Figura 7 - Modelo de detecção baseado em regressão



Fonte: Elaborada pelo autores.

### 1.3 Resultados da detecção de incêndio

A versão atual da detecção automática de focos de incêndio utiliza aprendizado de máquina profundo em uma rede neural de 106 camadas convolucionais treinada com 80% de um banco de dados de 5.169 imagens, contendo 8.244 marcações de ocorrências de fogo e fumaça. Em teste com 10% dos dados, isto é, 518 imagens e 761 marcações, uma classificação foi falso positivo, e 758 marcações foram identificadas corretamente, levando a uma precisão de 99,86% e um *recall* de 99,60%. Em teste real com a câmera filmando o dia inteiro durante uma semana, a frequência de alarmes falsos foi de um a cada três dias em média. Esses números mostram a confiabilidade e exatidão que se pode ter no sistema de identificação automática de incêndios. Isso está perto de superar a visão humana e, assim, ajuda a evitar o trabalho entediante de olhar o dia inteiro ao redor à procura de incêndios.

O desempenho das redes convolucionais é altamente sensível ao uso de processadores gráficos (GPU), os quais podem elevar muito seu desempenho. Sem GPU, a detecção pode levar até 10 segundos para ser concluída, enquanto testes com GPU levaram esse tempo para cerca de um terço de segundo.

As figuras a seguir ilustram situações adversas que desafiam a detecção de incêndio por visão computacional. A Figura 8, acima, ilustra a capacidade de detectar desde focos pequenos e concentrados até focos grandes e esparsos. A Figura 9, a seguir, tem reflexos de luz, e o foco é pequeno. A Figura 11 apresenta fumaça esparsa (escura) com nuvens ao fundo que dificultam a detecção, uma vez que as próprias nuvens poderiam ser confundidas com fumaça. Finalmente, a Figura 12 contém vários focos de incêndio em uma mesma imagem.

Figura 8 - Detecção de fumaça em um foco artificial no Parque Tecnológico de Belo Horizonte (BH-TEC)




Note que a detecção ocorre desde quando o foco está pequeno e concentrado até quando está maior e espalhado.  
Fonte: Registrado pelos autores.

**Figura 9** - Detecção de fumaça em um foco real em frente à Usiminas vista do BH-TEC



Note que a imagem apresenta reflexos de luz e que o foco é pequeno: desafios à detecção.  
Fonte: Registro feito pelos autores.

**Figura 10** - Detecção de fumaça em um foco real no BH-TEC



Note que está de noite e a fumaça é iluminada apenas pelo fogo do foco.  
Fonte: Registro feito pelos autores.

**Figura 11** - Detecção de fumaça em um foco ensaiado feito em uma plantação de cana da Biosev



Note que o dia está nublado e que a fumaça é bem esparsa: desafios à detecção.  
Fonte: Registro feito pelos autores.

**Figura 12** - Detecção de fumaça em vários focos reais ao mesmo tempo no morro em frente ao BH-TEC



Fonte: registro feito pelos autores.

Figura 13 - Imagem de uma das câmeras no aplicativo WEB do projeto piloto



Fonte: Registro feito pelos autores.

## 1.4 Página interativa na Internet Cemig

Foi criada uma página experimental na Internet com o intuito de promover a interação entre a sociedade e o sistema de visão computacional. Por meio do *site*, as pessoas podem acessar as câmeras e gerar alarmes manuais que servem para o aprendizado do sistema.

Na Figura 13, é mostrada a entrada do site com uma explicação resumida da atividade do projeto, com a

chamada de monitoramento ambiental. É ressaltado o fato de que o sistema vai utilizar a sustentação das torres de transmissão para instalação das câmeras.

Atualmente existem pilotos instalados no Parque Tecnológico de Belo Horizonte (BH-TEC), na Universidade Federal de Minas Gerais (UFMG) e na subestação de — Bonsucesso da Cemig, em fase de implantação.

## Considerações finais

A detecção de incêndio utilizando aprendizado profundo de máquina está prestes a superar a visão humana, funcionando em situações em que o ser humano teria dificuldades em enxergar. Isso tem implicações diretas sobre a precisão e amplitude com que as redes e linhas aéreas de energia e seus entornos são monitorados, liberando mão de obra humana para atividades mais nobres.

Neste momento, existe a previsão de instalação do sistema para testes no Parque Serra Verde e no Parque do Rola Moça, ambos na Região Metropolitana de Belo Horizonte. O projeto está só começando e vai durar três anos: muita coisa vai se realizar até ser finalizado e vamos contar com o apoio voluntário da sociedade na Internet para fazermos os testes nos sistemas.

## Agradecimentos

Gostaríamos de agradecer o suporte técnico e financeiro da Cemig-D para a realização deste projeto.

## Referências

DATA SCIENCE ACADEMY. **Deep learning book**. [2018]. Disponível em: <http://deeplearningbook.com.br>. Acesso em: 11 nov. 2019.

INPE. [2019]. Disponível em: <http://queimadas.dgi.inpe.br/queimadas/portal-static/situacao-atual/>. Acesso em: 15 nov. 2019.

WWF. **Five things you need to know about our living planet in 2018**. [2018]. Disponível em: <https://www.dw.com/en/five-things-you-need-to-know-about-our-living-planet-in-2018/a-46074931>. Acesso em: 15 nov. 2019.

CEMIG. **Cemig alerta para aumento de queimadas nesta época do ano**. [2017]. Disponível em: <https://www.cemig.com.br/sites/Imprensa/pt-br/Paginas/cemig-queimadas-seguranca-alerta.aspx>. Acesso em: 15 nov. 2019.

DIOS, J. R. M. et al. **Computer vision techniques for forest fire perception**. *Image and Vision Computing*, v. 26, n. 4, p. 550-562, 2008. DOI: <https://doi.org/10.1016/j.imavis.2007.07.002>

HOHBERG, S. P. **Wildfire smoke detection using convolutional neural networks**. 2015. Master Thesis (Master of Science). Fachbereich Mathematik und Informatik, Freie Universitt Berlin, Berlin, 2015.

KONG, S. G. et al. Fast fire flame detection in surveillance video using logistic regression and temporal smoothing. *Fire Safety Journal*, v. 79, p. 37- 43, 2016. DOI: <https://doi.org/10.1016/j.fire-saf.2015.11.015>

STEFFENS, C. R. **Um sistema de detecção de fogo baseado em vídeo**. 2015. Dissertação (Mestrado em Engenharia da Computação) – Centro de Ciências Computacionais, Universidade Federal do Rio Grande, Rio Grande, 2015.

VIEIRA, D. A. G. et al. Visão computacional para monitoramento ambiental das áreas cobertas por linhas de transmissão utilizando reconhecimento de padrões. In: CONGRESSO DE INOVAÇÃO TECNOLÓGICA EM ENERGIA ELÉTRICA – CITENEL, 8., 2015, Costa do Sauípe. **Anais do CITENEL 2015**. Brasília, DF: ANEEL – Agência Nacional de Energia Elétrica, 2015. p. 1-8.

Imagenet. [2019]. Disponível em: <http://www.image-net.org/challenges/LSVRC/>. Acesso em: 15 nov. 2019.

REDMON, J. et al. You only look once: Unified, real-time object detection. In: CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 2016, Las Vegas. **Proceedings of the CVPR 2016**. Las Vegas: IEEE, 2016. p. 779-788. DOI: <https://doi.org/10.1109/CVPR.2016.91>