



Grupo de Estudo de Desempenho Ambiental de Sistemas Elétricos-GMA

Interação com a sociedade por meio de sistema de visão computacional para monitoramento ambiental de linhas de transmissão

ADRIANO CHAVES LISBOA(1,2); HANI CAMILLE YEHIA(1); CARLOS ALEXANDRE MEIRELES NASCIMENTO(3); HERMES AGUIAR MAGALHÃES(1); PEDRO VINÍCIUS ALMEIDA BORGES DE VENÂNCIO(1, 2); ARLINDO FOLLADOR NETO(4); UFMG(1);Gaia(2); Cemig D(3); UFMG(4)

RESUMO

As linhas de transmissão de energia elétrica são muitas vezes vistas como agentes nocivos ao meio ambiente e raramente alguém não se incomoda em tê-las por perto. Isso acontece mesmo sabendo que elas trazem consigo uma qualidade de vida para as pessoas e desenvolvimento para a região por meio do abastecimento de energia elétrica. O monitoramento ambiental com interface web é uma forma de aproximar a sociedade das linhas de transmissão ao fornecer imagens das áreas no entorno das linhas de transmissão e com detecção automática de incêndios. Ele envolve uma rede de captação com câmeras e conexão com a internet, uma plataforma web para acesso público às imagens e servidores rodando a identificação automática de incêndio. Essa é a ideia fundamental de um projeto de pesquisa e desenvolvimento que vem sendo desenvolvido junto à CEMIG D com instalações protótipo no Parque Tecnológico de Belo Horizonte (BH-Tec) e na Universidade Federal de Minas Gerais (UFMG), e com planejamento de instalações de teste no Parque do Rola Moça e na Cidade Administrativa, com site web experimental já disponível para acesso público. O site permite saber a localização de cada câmera, ver a imagem da câmera em tempo real e fornecer feedback em relação a ocorrências. A detecção de incêndios roda ao fundo e pode ser auxiliada pelo feedback de ocorrências das pessoas no site. A versão atual da detecção automática de incêndios 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, 1 classificação foi falso positivo e 758 marcações foram identificadas corretamente, levando a uma precisão de 99,86% e uma revocação de 99,60%. Em teste real com a câmera filmando o dia inteiro durante um fim de semana, a frequência de falsos positivos foi de 1 a cada 4 horas em média. Esses números mostram a confiabilidade e exatidão que se pode ter no sistema de identificação automática de incêndios, e está perto de superar a visão humana, além de evitar fazer 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), a qual pode elevar muito seu desempenho. Sem GPU, a detecção pode levar até 10 segundos para ser concluída, enquanto testes com GPU levaram esse tempo a cerca de um terço de segundo. A identificação de incêndios continua sendo investigada e experimentando avanços significativos, e o site para monitoramento ambiental será atualizado em breve. Espera-se que a aproximação com a sociedade traga benefícios para ambas as partes, permitindo o acesso a imagens de monitoramento ambiental ao redor de linhas de transmissão por parte da sociedade enquanto conquista acesso mais livre a áreas urbanas para passar linhas de transmissão por parte do agente distribuidor de energia elétrica, contribuindo para o equilíbrio do sistema.

PALAVRAS-CHAVE

Visão computacional, detecção de incêndio, interação com sociedade

1. INTRODUÇÃO

Ao longo dos anos, empresas do setor de energia elétrica no Brasil vêm lidando com danos provocados por incêndios em áreas próximas à rede de transmissão. De acordo com a Agência Nacional de Energia Elétrica (ANEEL), queimadas irregulares em áreas limítrofes e desastres naturais, como temporais rompendo as linhas por quedas de postes ou de árvores, são os principais motivos das ocorrências.

Independente de como foram originados, incêndios podem ocasionar desde pequenas a grandes interrupções de distribuição de energia, afetando diretamente a sociedade. Em indústrias, desligamentos de curta duração, mesmo que por poucos segundos, implicam em atrasos na produção e, conseqüentemente, prejuízos financeiros. Sob a perspectiva da população, cria-se muita insegurança e desconforto, visto que escolas, hospitais, bancos e trânsito são potencialmente afetados.

De forma a evitar grandes desastres, é essencial que redes elétricas sejam monitoradas. As soluções mais típicas para detecção de incêndios provêm de vigilância humana e de sistemas baseados em sensores. No entanto, pessoas podem se distrair ou até mesmo não terem visibilidade para identificar determinadas situações, por exemplo, pequenos focos e incidentes a longas distâncias. Já a instalação e manutenção de sensores geralmente demandam alto investimento, uma vez que o custo está associado inerentemente às características da área a ser monitorada, tais como extensão e acessibilidade.

Uma alternativa mais interessante é realizar monitoramento por vídeos. Diante do avanço tecnológico, o cenário atual atingiu um estágio em que câmeras são fáceis de se adquirir e o que se torna mais dispendioso é o recurso humano responsável por realizar a vigilância. Tal conjuntura instigou pesquisadores a estudarem possibilidades de automatização do processo, o que proporcionou grande destaque à área de visão computacional.

Os primeiros estudos tiveram seus princípios baseados em engenharia de recursos manuais, onde os algoritmos buscavam aplicar regras elaboradas por especialistas para modelar as componentes essenciais de um incêndio. Diversas técnicas foram utilizadas e as características mais exploradas foram cor, brilho tremeluzente, expansão temporal, textura e movimento.

Em [1], os autores propõem um método para detecção de fogo baseado em análise de intensidade e saturação dos pixels no espaço de cores RGB. Além de avaliarem a taxa de crescimento dos potenciais pixels no decorrer do tempo. Os autores de [2] também investigaram propriedades semelhantes, porém no espaço de cores YUV. No trabalho [3], três estratégias foram combinadas para classificação do fogo: subtração de fundo, classificação de pixels e variações temporais.

Ainda que a associação de regras tenha aumentado significativamente a precisão das detecções, a presença notável de chammas normalmente indica situações de incêndio mais descontroladas, no qual muito dano já foi sustentado. Portanto, com o intuito de garantir detecções precoces e subseqüentes supressões instantâneas, muitos pesquisadores julgaram pertinente identificar também focos de fumaça em estágios iniciais.

Em [4], ao extrair pequenos envelopes de pixels, os autores consideraram propriedades espaço-temporais e análises de cinza no espaço de cores YUV para distinguir a fumaça de alguns objetos dinâmicos comuns em cenas de vigilância. Em uma seqüência de trabalhos [5][6], a construção dos métodos para detectar fumaças foram baseadas na perda de altas frequências usando Transformada Discreta de Wavelet e Modelo Oculto de Markov, respectivamente.

Durante anos, a abordagem tradicional da engenharia de recursos, um processo manual, tedioso, demorado e propenso a erros, foi utilizado na tentativa de representar fenômenos complexos. Entretanto, por mais que fossem específicas, as regras elaboradas nunca eram totalmente discriminativas. Em outras palavras, sempre surgiam objetos com propriedades semelhantes provocando falsos alarmes e o número de exceções à regra se tornava cada vez maior.

Por essa razão, a engenharia automatizada de recursos, ainda recente, ganhou visibilidade em diversos âmbitos. Sua capacidade de aprimorar o fluxo de trabalho padrão, ao extrair recursos úteis e significativos de um conjunto de dados, permitiu uma redução significativa de tempo e bons resultados àqueles que a consideram em sua topologia. As redes neurais convolucionais, uma das vertentes mais promissoras do aprendizado profundo de máquina, por exemplo, aprendem a reconhecer padrões a partir dos pixels brutos das imagens. O conhecimento adquirido é então empregado na análise e interpretação de situações inéditas.

Os autores de [7] extraem características relevantes do fogo através de uma rede convolucional e as utiliza para treinar um classificador global e um de granulação fina, cuja atuação conjunta proporciona identificação e localização das chammas. Outro trabalho de destaque propôs a integração de uma rede convolucional de 8 camadas de aprendizado com o circuito fechado de televisão (CFTV) para assegurar monitoramento autônomo e em tempo real [8]. Os resultados apresentaram uma taxa de falsos positivos inferior a 10% e supremacia em relação a dez métodos clássicos da literatura baseados em cores e movimento, inclusive o [1].

O presente trabalho desenvolve uma aplicação do algoritmo estado da arte para detecção de objetos em tempo real You Only Look Once (YOLO). Em sua terceira versão (YOLOv3) e com uma arquitetura de rede composta por 106 camadas convolucionais, YOLO foi treinado para detectar ocorrências de fogo e fumaça, obtendo uma precisão média de 99,97% e com apenas 1 falso alarme no conjunto de testes. Além disso, o modelo foi avaliado em testes reais no Parque Tecnológico de Belo Horizonte (BH-Tec) e obteve uma taxa de 1 falso positivo a cada 4 horas.

O conteúdo do artigo está organizado da seguinte forma: a seção 2 consiste em descrever quais possibilidades de interação a ferramenta computacional promove à sociedade, bem como os locais de implantação; a seção 3 apresenta os detalhes do algoritmo utilizado para detecção de incêndios e seus respectivos resultados; por fim, o trabalho é encerrado na seção 4 com as conclusões.

2. INTERAÇÃO COM A SOCIEDADE

Monitorar linhas de transmissão e o ambiente à sua volta cria naturalmente uma forma de aproximação com a sociedade, a qual normalmente também quer saber o que está acontecendo ao seu redor, especialmente em relação a eventos ambientais como queimadas. Foi nesse sentido que se pensou em disponibilizar imagens de monitoramento ambiental de linhas de transmissão para interação com a sociedade, de modo a informar o que está acontecendo em tempo real em uma região e obter retorno da sociedade sobre eventos ambientais.

2.1. Sítio para monitoramento ambiental

A principal funcionalidade do sítio de monitoramento ambiental é permitir à sociedade acesso a imagens em tempo real das áreas monitoradas. Essa funcionalidade está ilustrada na tela mostrada na Figura 1 esquerda. Nessa tela o usuário pode escolher a imagem de qual câmera ele quer ver por meio da seleção de ícones rotulados com o nome da câmera na parte interior ao vídeo principal. Ao clicar em um desses ícones, o vídeo carregado será o da respectiva câmera selecionada.



Figura 1 – Tela para visualização em tempo real das imagens de monitoramento (esquerda) e tela para retorno da sociedade sobre eventos ambientais (direita).

A segunda maior funcionalidade fornecida pela sítio de monitoramento ambiental é permitir que o usuário forneça um retorno sobre os eventos ambientais, conforme ilustrado na tela da Figura 1 direita. Nesse sentido, o usuário entra com seu nome e email e envia a descrição do evento observado.

2.2. Lugares monitorados

Apesar do sistema ter sido motivado por linhas de transmissão, sua instalação não se limita a áreas em seu entorno, podendo ser instalado especialmente em parques de preservação natural para monitoramento de áreas verdes.

2.2.1. Parque Tecnológico de Belo Horizonte

O primeiro local monitorado foi o Parque Tecnológico de Belo Horizonte, o qual possui uma boa área verde e constitui um ótimo lugar para testes por ser sede da empresa Gaia e próxima à UFMG. A estrutura instalada é composta de duas câmeras instaladas em um mini poste no terraço do prédio institucional do bh.tec. Nesse lugar foram conduzidos os primeiros testes artificiais, como forma de controlar o aparecimento de fogo e fumaça para a realização de testes em tempo real do algoritmo de detecção. Nele também foram detectados os primeiros focos de incêndios naturais, originados de diversas causas no ambiente ao redor.

2.2.2. Parque Serra Verde

Foram instaladas duas câmeras separadas por cerca de 100 metros no terraço do prédio Gerais da Cidade Administrativa de Minas Gerais para monitoramento do parque Serra Verde, conforme ilustrado na Figura 2. Tais câmeras farão enlace de internet com o servidor que fica na UFMG através de uma rede privada virtual (VPN) e também terão suas imagens divulgadas no sítio para interação com a sociedade. Cada caixa contém uma camera, uma fonte, 2 ventiladores e 2 clampers.




Figura 2 – Instalação na Cidade Administrativa para monitoramento do Parque Serra Verde.

Trata-se de uma localidade com características realistas de monitoramento ambiental. Nela serão testadas características da iluminação e condições ambientais (e.g. chuva e vento) na detecção de incêndio, além de características mecânicas do sistema (e.g. infiltrações e resistência mecânica contra chuva e sol).

3. DETECÇÃO DE INCÊNDIO

A tarefa de detecção consiste em determinar a localização de objetos específicos em uma imagem, bem como classificá-los. Os métodos comumente utilizados apresentam abordagem de múltiplas tarefas sequenciais. No entanto, isso pode ser muito lento para executar, inviabilizando a detecção em tempo real nos quadros de vídeo. Em situações que são necessárias intervenções de cunho preventivo, como é o caso do monitoramento ambiental de linhas de transmissão, a detecção deve ser praticamente instantânea, a fim de acionar a brigada de incêndio. YOLO utiliza uma rede neural para prever caixas delimitadoras para os objetos e as suas respectivas probabilidades de classe em uma única avaliação, o que o torna extremamente rápido.

3.1. Rede neural

As redes neurais artificiais (RNAs) são modelos computacionais treinados para aprender relacionamentos subjacentes em um conjunto de dados através de um processo que imita o modo como o sistema nervoso funciona. Sua estrutura é composta por inúmeras unidades de processamento (neurônios artificiais) altamente interconectadas e dispostas em camadas.

Quando em processo de aprendizado ou de aplicação, os padrões de informação são alimentados na rede através das unidades de entrada, que repassam o conteúdo processado às unidades ocultas e estas, por sua vez, chegam às unidades de saída (Figura 3 esquerda). Cada unidade recebe entradas das unidades à sua esquerda, realiza uma multiplicação com os pesos das conexões e soma o resultado. Essa soma ponderada é então passada para uma função de ativação não-linear, a qual aciona as unidades conectadas à direita se o valor ultrapassar um limiar.

O termo aprendizado profundo é utilizado para redes que são compostas por múltiplas camadas ocultas (Figura 3 direita). As primeiras arquiteturas de redes neurais, como os perceptrons, eram superficiais, compostas de uma camada de entrada e uma de saída e, no máximo, uma camada oculta intermediária. Em redes profundas, cada camada treina um conjunto disjuntivo de recursos com base na saída da camada anterior. Quanto mais se aprofunda na rede, maior é a complexidade das características que se pode reconhecer.




Figura 3 – Topologia de uma rede neural simples (esquerda) e rede neural profunda (direita).

Diante de sua notável capacidade de extrair recursos significativos de dados com determinada imprecisão, as redes profundas podem ser utilizadas para detectar tendências que são complexas demais para serem constatadas por humanos ou por outras técnicas computacionais. Assim, uma rede neural treinada com dados suficientes pode ser considerada como uma especialista na categoria de informação que lhe foi apresentada, permitindo fornecer projeções dadas novas situações de interesse.

3.2. Detector de objetos YOLO

Um classificador pode ser transformado em um detector de objetos ao dispor de uma pequena janela que percorra a imagem. Em cada etapa, aplica-se o classificador para que seja possível obter uma previsão de qual objeto está contido na janela atual. Ao final do processo, várias janelas e suas respectivas previsões terão sido geradas, mas apenas as que apresentarem maior confiabilidade permanecerão.

Apesar de funcionar, executar o classificador várias vezes demanda bastante tempo e inviabiliza a detecção em tempo real. Uma abordagem um pouco mais eficiente tem como princípio definir as regiões de interesse para depois aplicar o classificador, dando origem à classe de detectores baseados em regiões. Entretanto, o classificador ainda é executado um número significativo de vezes.

Recentemente, o YOLO (You Only Look Once), detector de objetos baseado em aprendizado profundo, foi apresentado com uma proposta bastante diferente das demais [10]. Além de não ser um classificador reaproveitado para a tarefa de detecção de objetos, ele realmente visualiza a imagem apenas uma vez, porém de modo extremamente inteligente.

A princípio, YOLO divide a imagem em uma grade de tamanho $S \times S$ células (Figura 4 esquerda). Cada uma dessas células é responsável por prever 5 caixas delimitadoras, sendo uma referente ao retângulo que envolve o objeto identificado.

O YOLO também utiliza uma pontuação de confiança, cuja responsabilidade é informar o quão certa está a caixa delimitadora predita ao indicar que inclui algum objeto. As caixas delimitadoras são apresentadas na Figura 4 centro-esquerda, onde quanto maior a pontuação de confiança, maior a espessura da borda da caixa.




Figura 4 – SxS células de entrada (esquerda), caixas delimitadoras e confiança (centro-esquerda), mapa de probabilidades de classe (centro-direita), e detecção final (direita).

Contudo, a pontuação não diz nada a respeito de qual possível objeto está na caixa. Para isso, a célula também prevê uma classe em cada caixa delimitadora. O funcionamento ocorre semelhante ao de um classificador, no qual é fornecido uma distribuição de probabilidade sobre todas as classes possíveis. Como o intuito do modelo é detectar incêndios, apenas probabilidades das classes fogo e fumaça. O mapa de probabilidades apresentado na Figura 4 centro-direita demonstra a probabilidade das células conterem um indicativo de incêndio, onde as mais azuladas apresentam maior probabilidade e as vermelhas menor probabilidade.

A pontuação de confiança e a previsão de classe definidas para cada caixa delimitadora são então combinadas em uma pontuação final, que indica a probabilidade da caixa conter um tipo específico de objeto. Com relação ao exemplo, existem $14 \times 14 = 196$ células e cada célula prevê 5 caixas delimitadoras, resultando em um total de 980 caixas delimitadoras. No entanto, a maioria das caixas terá pontuações de confiança extremamente baixas, fazendo com que a rede descarte todas as caixas com pontuações finais abaixo de um determinado limiar previamente especificado (Figura 4 direita).

É interessante notar que das 980 caixas delimitadoras, apenas uma obteve resultado relevante. E embora houvesse 980 previsões, todas elas foram realizadas ao mesmo tempo, posto que a rede neural processou um único quadro.

3.3. Banco de imagens

O banco de imagens utilizado para treinar e testar o modelo foi um banco próprio denominado D-Fire dataset [9], cuja última atualização ocorreu em Junho de 2018. Atualmente, ele é composto por 5.169 imagens rotuladas, abrangendo situações em que existem apenas ocorrências de fogo (258), apenas de fumaça (3.138), ambas (1.164) ou nenhuma (609). No caso das imagens sem ocorrências de incêndio, a incorporação à base de dados teve como propósito ensinar o modelo a discriminar as classes dos objetos com propriedades semelhantes.

Outra característica interessante é que, na maioria das imagens, existem mais de uma ocorrência de fogo e fumaça. Isso pode ser facilmente comprovado pelo número total de caixas delimitadoras no banco de dados, onde existem 5.418 para fumaça e 2.826 para fogo, excedendo o número total de imagens em quase 38%. Cenários assim permitem ao modelo identificar ocasiões em que múltiplos focos de incêndio estão ocorrendo simultaneamente.

As principais fontes de coleta das imagens foram sites nacionais e internacionais, como CNN, BBC, Globo e Folha de São Paulo, resultando em 85,72% da composição do banco de imagens. Além disso, foram obtidas imagens em testes de incêndio (8,76%) e edições gráficas (5,52%). Apesar de uma grande variedade de imagens com diversidade de cor, posição e forma, os registros mais encontrados foram de ocorrências de incêndio em florestas e em acidentes de trânsito. Dessa forma, técnicas de aumento de dados, em particular espelhamento e adição de ruído, foram usadas para expandir as 1.723 imagens em 5.169 imagens. Exemplos de imagens do D-Fire são apresentados na Figura 5.



Figura 5 – Exemplos de imagens presentes no banco de imagens D-Fire.

3.4. Planejamento e análise de experimentos

A versão do YOLO utilizada para realizar as detecções foi a terceira e mais atual (YOLOv3). Sua arquitetura é composta por 106 camadas convolucionais, sendo 53 pré-treinadas com uma base de dados denominada ImageNet. Ainda que a expansão do número de camadas convolucionais tenha atenuado um pouco a velocidade em relação à versão anterior (YOLOv2), os aperfeiçoamentos realizados permitiram a essa nova versão uma significativa melhoria na precisão, principalmente de objetos pequenos [11]. Tal característica foi fundamental para a aplicação em questão, visto que permitiu uma melhor detecção de focos de incêndio em estágios iniciais.

A metodologia adotada estabeleceu uma divisão no banco de dados em três subconjuntos distintos:

1. Conjunto de treinamento com 80% das imagens para obter os pesos das camadas da rede durante 80200 iterações.
2. Conjunto de validação com 10% das imagens para identificar o melhor conjunto de pesos e o melhor limiar obtidos durante o treinamento.
3. Conjunto de teste com o restante das imagens para avaliar o desempenho da rede com o melhor limiar e o melhor conjunto de pesos.

A divisão das imagens foi realizada proporcionalmente ao número de classes, ou seja, o percentual atribuído a cada conjunto também foi empregado às categorias das imagens (fogo, fumaça, fogo e fumaça, nada). Essa homogeneidade garante um aprendizado diversificado, visto que uma divisão aleatória poderia treinar o modelo com um viés ou uma fragilidade em situações específicas.

Os pesos das camadas da rede foram inicializados com pesos pré treinados disponíveis em [12]. O tamanho dos mini-lotes foi de 64 para a descida do gradiente. A taxa de aprendizagem durante o treinamento foi definida como 0,001, o momento 0,9 e o decaimento 0,0005. Além disso, a função de ativação considerada para as camadas convolucionais foi a ReLU com vazamento.

Após o treinamento, uma análise foi realizada para se obter o melhor conjunto de pesos, ou seja, o responsável por obter o menor erro no conjunto de validação (ponto de parada antecipada). Em um intervalo de 30.000 a 80.200 iterações, o conjunto de pesos com maior precisão média (mAP = 95,29%) e também maior interseção sobre união (IoU = 85,97%) foi o peso de 78.000 iterações. A validação do melhor limiar para o peso obtido no conjunto de validação foi realizada em seguida e, em um intervalo de 0,2 a 0,8, o limiar que assegurou maior medida F (F1 = 0,9921) foi o de 0,3.

Determinada a melhor combinação de pesos para as camadas da rede com o seu melhor limiar de detecção, foram realizados dois testes distintos para avaliar o desempenho do modelo. O primeiro teve como finalidade verificar o desempenho no subconjunto especificado para testes, isto é, em 518 imagens. Em um total de 761 marcações de caixas, a rede foi capaz de detectar corretamente 758 ocorrências (verdadeiros positivos) e produziu apenas 1 alarme falso (falsos positivos), como apresenta a matriz de confusão na Tabela 1.

Tabela 1 – Matriz de confusão.

		Detectou?	
		Positivo	Negativo
Havia fogo ou fumaça?	Positivo	758	3
	Negativo	1	-

Combinando os resultados apresentados, pode-se corroborar a qualidade do modelo em duas das métricas mais comuns em aprendizado de máquina: precisão (99,86%) e revocação (99,60%).

O outro teste proposto consistiu em monitorar as áreas abertas do Parque Tecnológico de Belo Horizonte (BH-Tec) e as áreas externas a até 5km de distância. O modelo integrado à câmera IP giratória foi fixado no topo do prédio institucional localizado no próprio BH-Tec. Durante um final de semana, ou seja, 48 horas, a taxa de falsos positivos da rede foi de 0,25 por hora, comprovando a robustez do método também para vigilâncias em tempo real. A Figura 6 apresenta diversas situações que desafiam a tarefa de detecção de incêndios por visão computacional que foram tratadas pelo método proposto.



Figura 6 – (esquerda) Detecção de fumaça em uma ocorrência real no Parque Tecnológico de Belo Horizonte (BH-Tec). Além do ambiente noturno como adversidade, é possível observar também diversos reflexos de luzes artificiais, um dos principais responsáveis por falsos alarmes durante o monitoramento. (centro) Detecção de fumaça em uma ocorrência real próxima à Usiminas com vista do prédio institucional do BH-Tec. Nota-se que o foco identificado está longe e ainda em estágio inicial. (Direita) Detecção de fumaça em uma ocorrência simulada no BH-Tec. Nessa situação, a fumaça já foi dissipada pelo vento e parte dela é camuflada no céu.

4. CONCLUSÃO

A detecção de incêndio por aprendizado profundo e o retorno de usuários possuem uma boa sinergia, um complementando as falhas de detecção do outro e ajudando a montar um banco de dados de incêndio confiável para tornar a técnica ainda mais precisa. Além disso, o uso de monitoramento ambiental pode ajudar a diminuir o índice de rejeição de linhas de transmissão, aproximando a sociedade de novas expansões do setor elétrico e facilitando a coexistência.

5. REFERÊNCIAS BIBLIOGRÁFICAS

- (1) CHEN, Thou-Ho; WU, Ping-Hsueh; CHIOU, Yung-Chuen. An early fire-detection method based on image processing. In: 2004 International Conference on Image Processing, 2004. ICIP'04. IEEE, 2004. p. 1707-1710.
- (2) MARBACH, Giuseppe; LOEPFE, Markus; BRUPBACHER, Thomas. An image processing technique for fire detection in video images. Fire Safety Journal, v. 41, n. 4, p. 285-289, 2006.
- (3) CELIK, Turgay; DERIMEL, Hasan; OZKARAMANLI, Huseyin; UYGUROGLU, Mustafa. Fire detection using statistical color model in video sequences. Journal of Visual Communication and Image Representation, v. 18, n. 2, p. 176-185, 2007.
- (4) GUILLEMANT, Philippe; VICENTE, Jerome. Real-time identification of smoke images by clustering motions on a fractal curve with a temporal embedding method. Optical Engineering, v. 40, n. 4, p. 554-564, 2001.
- (5) TÖREYIN, B. Uğur; DEDEOĞLU, Yiğithan; ÇETIN, A. Enis. Wavelet based real-time smoke detection in video. 13th European Signal Processing Conference. IEEE, 2005. p. 1-4.
- (6) TÖREYIN, B. Uğur; DEDEOĞLU, Yiğithan; ÇETIN, A. Enis. Contour based smoke detection in video using wavelets. 14th European Signal Processing Conference. IEEE, 2006. p. 1-5.
- (7) ZHANG, Qingjie; XU, Jiaolong; XU, Liang; GUO, Haifeng. Deep convolutional neural networks for forest fire detection. In: 2016 International Forum on Management, Education and Information Technology Application. Atlantis Press, 2016.

(8) MUHAMMAD, Khan; AHMAD, Jamil; BAIK, Sung Wook. Early fire detection using convolutional neural networks during surveillance for effective disaster management. *Neurocomputing*, v. 288, p. 30-42, 2018.

(9) GAIA. D-Fire dataset, <http://gaiasd.com/d-fire-dataset.zip>.

(10) REDMON, Joseph; DIVVALA, Santosh; GIRSHICK, Ross; FARHADI, Ali. You only look once: Unified, real-time object detection. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016. p. 779-788.

(11) REDMON, Joseph; FARHADI, Ali. YOLOv3: An incremental improvement. *arXiv preprint arXiv:1804.02767*, 2018.

(12) REDMON, Joseph. YOLOv3: Real-Time Object Detection, <https://pjreddie.com/darknet/yolo/>.

6. DADOS BIOGRÁFICOS



Adriano Chaves Lisboa possui graduação, mestrado e doutorado em engenharia elétrica pela Universidade Federal de Minas Gerais. É co-fundador das empresas ENACOM e Gaia, sendo atualmente diretor de pesquisa da Gaia. Seus interesses incluem otimização e modelagem computacional.



Hani Camille Yehia é graduado em engenharia eletrônica pelo ITA, mestre em engenharia eletrônica e computação pelo ITA e doutor em engenharia elétrica pela Universidade de Nagoya, Japão. Atualmente é professor titular do Departamento de Engenharia Eletrônica da UFMG. Em seus trabalhos, busca combinar pesquisa básica nas áreas de física, neurociência, linguística e música com pesquisa aplicada em tecnologia de codificação, reconhecimento e síntese audiovisual da fala e da música.



Carlos Alexandre Meireles do Nascimento graduou-se em engenharia plena pela PUC-MG, com mestrado em engenharia mecânica pela UFMG e doutorado em engenharia elétrica também pela UFMG. Atualmente trabalha na CEMIG D como engenheiro de tecnologia e normalização. Atua principalmente na área de monitoramento de ativos de energia, linhas de transmissão, projeto de linhas de transmissão, ampacidade, fibras ópticas, novos tipos de condutores e supercondutores.



Hermes Magalhães graduou-se Engenheiro Eletricista pela UFMG, com mestrado em Engenharia Eletrônica e Computação pelo ITA e MBA em Gestão Empresarial pela FGV. Ph.D em Engenharia Elétrica pela UFMG, com pós-doutorado em sistemas eletrônicos para ressonância magnética. Atuou na indústria por mais de 25 anos, em projetos de engenharia submarina e telecomunicações, processamento digital de sinais e imagens, como consultor, desenvolvedor e também executivo na direção de startups e gestão de grandes empresas. Atualmente é professor do Departamento de Engenharia Eletrônica da UFMG. Atua em projetos de pesquisa integrados com a indústria e coordena na UFMG a iniciativa transversal OPEI - Oficina de Projetos, Empreendedorismo e Inovação e o Convênio da UFMG com o Sutardja Center for Entrepreneurship and Technology - SCET da Universidade da Califórnia em Berkeley. Seus principais interesses são inteligência computacional, sistemas eletrônicos digitais, empreendedorismo e inovação.



Pedro Vinícius Almeida Borges de Venâncio é atualmente estudante de graduação em Engenharia de Sistemas pela Universidade Federal de Minas Gerais (UFMG), estagiário de pesquisa e desenvolvimento na Gaia e membro do grupo de pesquisa do Operations Research and Complex Systems Laboratory (ORCS Lab/UFMG). Seus principais interesses incluem aprendizado de máquina, otimização e ciência de dados.



Arlindo Follador Neto é Professor Adjunto do Instituto de Ciência e Tecnologia (ICT) da Universidade Federal dos Vales do Jequitinhonha e Mucuri (UFVJM), possui graduação em Adm. Hab. em Análise de Sistemas pelo Centro Universitário do Espírito Santo (2003). Especialista em Redes de Computadores pela Universidade Federal de Lavras (2005). Mestrado em Engenharia Elétrica na Universidade Federal de Minas Gerais (2009). Doutorado em Engenharia Elétrica na Universidade Federal de Minas Gerais (2018). Tem experiência profissional nas áreas de Redes de Computadores, Roteamento, Segurança, Banco de Dados e Gestão de TI.