

# Classificador de Imagens Termográficas usando Transferência de Aprendizagem

Fausto O. e Silva, Gustavo M. de Almeida, Flávio B. B. da Silva

**Resumo** O presente trabalho propõe desenvolver uma ferramenta para classificar imagens geradas a partir de inspeções termográficas em equipamentos elétricos. A proposta é classificar a situação dos equipamentos como normal e crítica. Para o desenvolvimento desse classificador foram utilizadas técnicas de transferência de aprendizagem utilizando redes neurais convolucionais já treinadas e de reconhecimento no ambiente da inteligência artificial. Essas redes estão sendo utilizadas em diversas aplicações que envolvem a classificação de imagens. Por fim, o trabalho apresenta uma comparação de uma rede neural convolucional básica e das redes VGG-16 e ResNet-50 já amplamente difundidas no meio do aprendizado profundo.

## 1 Introdução

A manutenção elétrica tem evoluído bastante nos últimos anos principalmente quando se trata de manutenção preditiva, pois ela avalia o estado real dos equipamentos, recorrendo, para isto, a equipamentos específicos, tendo por finalidade ajustar o planejamento da manutenção preventiva, detectar precocemente possíveis falhas, evitar o surgimento de problemas e contribuir na tomada de decisões com base em dados reais (CAMPOS, 2010).

Nesse contexto as principais técnicas de manutenção preditiva tais como: análise de vibração, análise de óleos, aplicação de ultrassons, detecção de fugas e termografia, trazem o benefício de se tirar o melhor aproveitamento dos equipamentos sem correr o risco de uma parada inesperada para correção de defeitos.

A termografia de painéis elétricos, transformadores e motores elétricos vem se destacando como uma grande ferramenta de manutenção preditiva permitindo o reconhecimento precoce de falhas diminuindo o tempo de inatividade de sistemas, custos de manutenção e evitando quebras

---

Fausto O. e Silva

Programa de Pós-Graduação em Engenharia de Controle e Automação, Instituto Federal do Espírito Santo (IFES), Manguinhos – Serra, Espírito Santo, Brasil.

e-mail: faustogv@yahoo.com.br

Gustavo M. de Almeida

Programa de Pós-Graduação em Engenharia de Controle e Automação, Instituto Federal do Espírito Santo (IFES), Manguinhos – Serra, Espírito Santo, Brasil.

e-mail: gmaia@ifes.edu.br

Flávio B. B. da Silva

Programa de Pós-Graduação em Engenharia de Controle e Automação, Instituto Federal do Espírito Santo (IFES), Manguinhos – Serra, Espírito Santo, Brasil.

e-mail: flavio Barcelos@ifes.edu.br

---

*Anais do XV Encontro Anual de Ciência da Computação (EnAComp 2020)*. ISSN: 2178-6992.

Catalão, Goiás, Brasil. 25 a 27 de Novembro de 2020.

Copyright © autores. Publicado pela Universidade Federal de Catalão.

Este é um artigo de acesso aberto sob a licença CC BY-NC (<http://creativecommons.org/licenses/by-nc/4.0/>).

desastrosas (BAGAVATHIAPPAN et al., 2013) e indicando o momento certo de atuar nesses equipamentos, detectando falhas, melhorando sua confiabilidade, garantindo uma maior integridade e diminuindo os custos de manutenção. Ela se transformou em uma inovação vital e poderosa para diagnosticar problemas internos e externos, observando o estado térmico dos equipamentos elétricos, de uma maneira confiável e sem contato, fornecendo dados subjetivos visuais rápidos sobre a confiabilidade do material (CHELLAMUTHU; SEKARAN, 2019). Entre as falhas relacionadas a altas temperaturas em equipamentos podem-se citar: mau contato, sobrecarga, desalinhamento, falta de lubrificação, enfim, uma variedade de falhas que, sendo identificadas antes de uma parada definitiva do equipamento proporcionarão um ganho na atividade de manutenção. Um sobreaquecimento em um equipamento ou instalação elétrica pode ser facilmente identificado conforme pode ser visto na Figura 1.




Figura 1: Termografia indicando sobreaquecimento.

A Figura 1 mostra que no local mais quente a temperatura é maior que 70° C, o que representar um risco à integridade dos cabos que alimentam o disjuntor, podendo ser causa até de um incêndio no local.

A partir desse sobreaquecimento detectado na termografia, uma inspeção no local evidencia a falha, conforme pode ser visto na Figura 2.

A Figura 2 mostra o tipo de falha detectada a partir da inspeção termográfica. Um mau contato na conexão entre o cabo e o disjuntor resultou num sobreaquecimento neste ponto. No entanto, essa situação só foi encontrada após um retorno à instalação, por indicação do relatório da inspeção, que foi elaborado a partir da realização da termografia.

O relatório de inspeção é que informará as diretrizes que o setor de manutenção de uma indústria ou empresa deve seguir para manter de forma íntegra as suas instalações. Nas inspeções termográficas realizadas na indústria de uma forma geral, a quantidade de imagens geradas é elevada, pois existem muitos equipamentos que necessitam passar por esse tipo de avaliação, exigindo um tempo precioso na elaboração do relatório. Neste caso, um classificador que diferencie equipamentos com um risco potencial, daqueles que estão em condições normais proporcionaria um ganho de tempo e agilidade na elaboração do relatório de inspeção.



Figura 2: Identificação da falha.

## 2 Trabalhos Correlatos

As pesquisas em processamento de imagens, incorporadas a algum tipo de sistema inteligente com o propósito de diagnosticar a condição dos equipamentos elétricos, estiveram em seus estágios iniciais por volta do ano de 2010 (JADIN; TAIB, 2012).

Como o produto de uma inspeção termográfica são imagens, vários estudos estão sendo feitos com o objetivo de usar o processamento digital dessas imagens e os sistemas inteligentes para identificar os equipamentos que apresentam algum tipo de risco por superaquecimento e os que estão em condições normais de funcionamento. Um estudo de Ahmed, Huda e Mat Isa (2015) utilizou a transformação das imagens em escala de cinza e em seguida realizou a segmentação destas, obtendo apenas a parte definida como quente. Posteriormente, desenvolveu através da lógica fuzzy seu classificador, inicialmente, com duas situações de saída: normal e com defeito; e posteriormente, com três situações de saída: normal, atenção e crítica. O sistema proposto avaliou automaticamente as condições dos componentes visualizando as anormalidades de componentes elétricos nas condições definidas. O aproveitamento do sistema construído com duas situações de saída ficou em 92,3%, e com três situações o aproveitamento foi de 80%, demonstrando a viabilidade de se elaborar através da lógica fuzzy um classificador para as imagens obtidas a partir da termografia.

Em outro caso, Huda e Taib (2013) discutiram um sistema de classificação inteligente para as condições dos equipamentos. Nesse estudo, as redes neurais artificiais (RNA) foram utilizadas para classificar as condições térmicas do equipamento em duas classes, nomeadas como normais e defeituosas. O sistema empregava as redes *Multilayer Perceptron* (MLP) usando os algoritmos de treino *Resilient back propagation* (RP), *Bayesian Regularization* (BR), *Levenberg-Marquardt* (LM) e *Scale conjugate gradiente* (SCG). As características de entrada para as re-

des MLP foram avaliadas analisando o desempenho de três conjuntos de características: características de primeira ordem de histograma, características de matriz de ocorrência de níveis de cinza e características de intensidade dos componentes conectados. A acurácia foi de 82,89% na fase de treinamento e 74,25% para a fase de teste, indicando também a viabilidade de se classificar as imagens termográficas através das redes neurais.

Já Mlakić, Nikolovski e Baus (2017) propuseram que a Aprendizagem Profunda (*Deep Learning*) era um campo novo e digno de nota no aprendizado de máquina, destacando a Rede Neural Convolutiva (CNN).

Ainda Guo et al. (2017) demonstrou o funcionamento das redes convolucionais e suas aplicações, destacando sua importância em tratamento de imagens, classificação, detecção e segmentação a partir de características que essas redes podem extrair para aprender determinados padrões. No entanto, a utilização das CNN exige grandes quantidades de imagens para treinamento que nem sempre estão disponíveis. Porém, essa limitação de imagens pode ser resolvida através das técnicas de Transferência de Aprendizagem, que consiste em usar os dados gerados por uma CNN previamente treinada em um novo classificador para que seja treinado com esses dados ou utilizá-los como entrada para uma próxima camada de classificação.

Na área do Deep Learning, Yosinski et al. (2014) afirmaram que a transferência de aprendizagem ficou ainda mais explorada por conta da capacidade de reutilizar modelos pré-treinados em bases de dados mais abundantes em problemas mais específicos, contornando, assim, a limitação de dados em quantidades expressivas para o treinamento dos modelos.

Desde então, diversos trabalhos foram e continuam sendo realizados utilizando-se dos recursos oferecidos das redes pré-treinadas tornando algumas muito famosas no ambiente do *Deep Learning*. Entre as mais conhecidas se destacam a LeNet, AlexNet, VGG-16, ResNet-50, Yolo, Inception, entre outras.

Diante do exposto, o trabalho propõe a utilização da transferência de aprendizagem para classificar imagens termográficas a fim de proporcionar mais facilidade para técnicos e engenheiros que trabalham com manutenção preditiva, tendo como objetivo realizar um comparativo entre três redes: uma elaborada a partir dos conceitos de criação das CNN, chamada nesse trabalho de Alfa, e outras duas pré-treinadas, sendo elas a VGG-16 e a ResNet-50; a fim de se avaliar a eficácia da utilização dessas redes em um conjunto de imagens bem mais específico, como o de termografia de equipamentos elétricos.

### 3 Desenvolvimento

Uma CNN é um tipo de rede neural normalmente utilizada para classificação de imagens. Ela pode ser dividida em duas partes: extração de características e uma rede neural tradicional. A parte de extração de características é composta por camadas de convolução que possuem funções distintas, mas que permitem um treinamento significativamente mais rápido. A Figura 3 ilustra a composição de uma CNN básica.

Na CNN básica ilustrada na Figura 3 temos a entrada das imagens (*Input*), seguida das camadas de convolução (*Conv*), onde são extraídos os mapas de características das imagens a partir de filtros (kernels), que são matrizes que se deslocam por toda a imagem; função de ativação (ReLU) que permite que a CNN detecte e aprenda características não-lineares; *pooling* (Pool),



Figura 3: Composição de uma CNN básica.

utilizada para reduzir o tamanho das matrizes resultantes da convolução, porém, mantendo as características mais importantes; e a camada completamente conectada, *Fully Connected* (FC), onde ocorre o aprendizado dessas características. Por fim, temos a saída das imagens (*Output*).

A rede Alfa elaborada para a classificação das imagens termográficas possui uma arquitetura bem mais simples que a das redes pré-treinadas VGG-16 e ResNet-50 que foram utilizadas e que serão descritas a seguir.

### 3.1 Alfa

Toda CNN nova elaborada é dividida em duas partes: extração de características e uma rede neural tradicional. A parte de extração de características é composta por camadas que possuem funções distintas, mas que permitem um treinamento significativamente mais rápido. A rede Alfa que foi utilizada nesse trabalho possui a seguinte estrutura:

- Camada de convolução 1, com 32 mapas de filtros (3 x 3), e função de ativação ReLu;
- Aplicação do MaxPooling 1, com um filtro (2 x 2);
- Camada de convolução 2, com 64 mapas de filtros (3 x 3), e função de ativação ReLu;
- Aplicação do MaxPooling 2, com um filtro (2 x 2)
- Camada de convolução 3, com 128 mapas de filtros (3 x 3) e função de ativação ReLu;
- Aplicação do MaxPooling 3, com um filtro (2 x 2);
- Aplicação do Flatten, para que os dados sejam aplicados a uma rede neural tradicional;
- Aplicação da função Dense para utilização da rede neural tradicional, com função de ativação sigmoid, pois deseja-se na saída um valor binário.

Essa estrutura está ilustrada na Figura 4.

### 3.2 VGG-16

A Visual Geometry Group (VGG) é um modelo de CNN proposto por K. Simonyan e A. Zisserman, da Universidade de Oxford, no artigo “Very Deep Convolutional Networks for Large-Scale Image Recognition”. Ela possui variações de 11, 13, 16 e 19 camadas, das quais as três últimas camadas são do tipo totalmente conectadas, com 4096, 4096 e 1000 neurônios, respectivamente, e as primeiras camadas são camadas convolucionais (MIGUEL WANDERLEY; RICARDO PRUDÊNCIO, 2018). A Figura 5 ilustra a arquitetura da VGG-16.

Na Figura 5 podem ser identificadas as diversas camadas de convolução e função de ativação ReLu, *max pooling* e a *fully connected*, seguida função *softmax* utilizada quando se tem mais estados de saída.

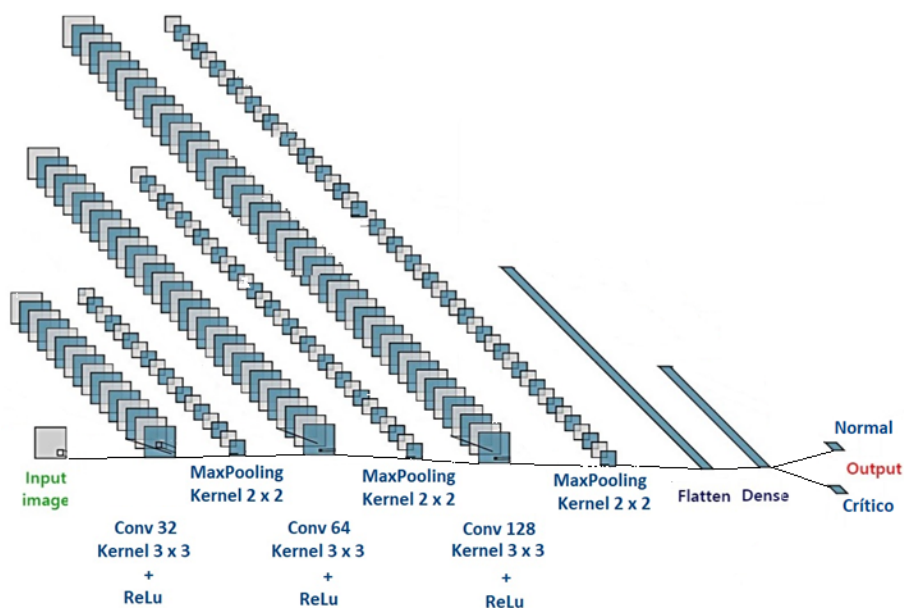


Figura 4: Estrutura da Alfa.




Figura 5: Estrutura da VGG-16.

A VGG-16 foi a rede convolucional vencedora do “ImageNet Large Scale Visual Recognition Challenge” (ILSVRC) em 2014, um concurso anual de Deep Learning que premia as melhores redes utilizadas na classificação e detecção de imagens, e passou a ser bastante referenciada e utilizada desde então.

### 3.3 ResNet-50

A Residual Network (ResNet) é um modelo de CNN desenvolvida pela Microsoft, sendo apresentada por Kaiming He, Xiangyu Zhang, Shaoqing Ren e Jian Sun no artigo “Deep Residual

Learning for Image Recognition". Ela foi construída por blocos residuais que têm uma entrada  $x$  que passa por uma série de operações de convolução-relu-convolução. O resultado da operação  $f(x)$  é adicionado à entrada original  $x$ . A Figura 6 ilustra uma parte arquitetura da ResNet-50.

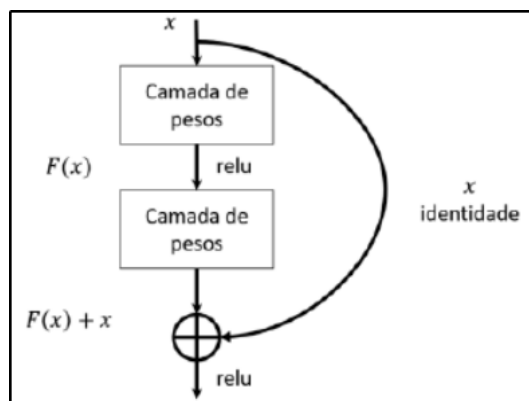


Figura 6: Bloco residual da ResNet-50.

Essas camadas adicionais são o mapeamento de identidade e as outras camadas são copiadas do modelo mais raso aprendido. Esta solução indica que um modelo mais profundo não deve produzir um erro de treinamento maior do que sua versão da rede mais rasa (HE et al., 2016).

A ResNet-50 foi vencedora do ILSRVC de 2015 e também vem sendo amplamente utilizada em trabalhos envolvendo classificação e detecção de imagens através da transferência de aprendizagem.

### 3.4 Implementação

As redes VGG-16 e ResNet-50 são redes que foram pré-treinadas a partir do ImageNet, que é um banco de dados de 1000 classes de imagens. Neste trabalho elas foram adaptadas para trabalharem com apenas duas classes, mas aproveitando os pesos alcançados no ImageNet. Essas três CNN passaram pelo mesmo dataset de imagens termográficas, previamente classificado em imagens que apresentam um comportamento térmico normal e em um comportamento térmico crítico. O dataset possui 150 imagens de situação normal e crítica, respectivamente, fazendo um total de 300 imagens para treinamento e 30 imagens de situação normal e crítica para validação, respectivamente, fazendo um total de 60 imagens de validação. Essas imagens são de situações reais encontradas na indústria e do local de trabalho de um dos autores. O particionamento das imagens de treinamento e validação foi feito aleatoriamente, também, por um dos autores do trabalho.

As imagens passaram por um pré-processamento sendo redimensionadas para a escala 150 x 150 pixels e pelo aumento de dados, que é uma técnica que faz alterações nas imagens como rotações e ampliações, por exemplo, para aumentar a quantidade de dados de treinamento.

O treinamento foi realizado através da linguagem de programação Python com a biblioteca Keras, sendo executado dentro do ambiente do Google Colaboratory (Colab). Todos os testes foram realizados com os mesmos parâmetros de processamento: *batch size* = 20, *steps per*

$epoch = 10$  e  $epochs = 30$ . O critério de parada utilizado foi o dropout, sendo testados três valores diferentes e definido o valor que obteve o melhor desempenho nas três redes.

## 4 Análise dos resultados

Após o treinamento é feita a análise de desempenho. Neste trabalho foram analisadas as métricas de acurácia e  $log\ loss$  de cada rede. Os gráficos mostram o desempenho das CNN tanto na fase de treino e quanto na fase de validação.

### 4.1 Desempenho da CNN Alfa

O desempenho utilizando a CNN Alfa foi razoável, devido a simplicidade de sua arquitetura. Com uma acurácia chegando a 85,0% na 12ª época ela cumpriu o seu objetivo de classificar imagens termográficas. O desempenho de  $log\ loss$  chegou a um valor mínimo de 32,14%. As Figuras 7 (a) e (b) mostra o desempenho dessa rede através dos gráficos de acurácia e  $log\ loss$ .




Figura 7: (a) Acurácia e (b)  $Log\ loss$  da CNN Alfa.

Um ajuste nas camadas convolucionais pode melhorar ainda mais o desempenho da CNN Alfa e torna-la especialista em imagens termográficas.

### 4.2 Desempenho da CNN VGG-16

O desempenho da VGG-16 foi melhor que o da rede Alfa e com menos variações de amplitude. O valor máximo de acurácia foi de 100% na 13ª época, mas de uma forma geral a acurácia obteve um bom desempenho. Já os valores  $log\ loss$  tiveram uma maior variação de amplitude e o valor mínimo atingido foi de 2,64%. As Figuras 8 (a) e (b) mostra o desempenho dessa rede através dos gráficos de acurácia e de  $log\ loss$ .

Mesmo sendo pré-treinada em *dataset* bem maior que o deste trabalho, a VGG-16 demonstrou-se versátil sendo aplicada a um *dataset* menor e com características tão diferentes.






Figura 8: (a) Acurácia e (b) Log loss da CNN VGG-16.

### 4.3 Desempenho da CNN ResNet-50

O desempenho da ResNet-50 foi inferior que o das duas redes anteriores. Ele teve uma variação de amplitude menor, mas seu valor máximo de acurácia foi de 62,5% na 13ª época. Os valores de *log loss* também foram altos e ficaram acima de 50% sendo que o valor mínimo foi de 63,25% na 23ª época. As figuras 9 (a) e (b) mostra o desempenho dessa rede através dos gráficos de acurácia e da função perda.




Figura 9: (a) Acurácia e (b) Log loss da CNN ResNet-50.

O desempenho abaixo do esperado com essa rede mostra que nem todas as redes se adaptam bem a todos os tipos de *dataset*.

### 4.4 Comparação do Desempenho das Redes

Para uma melhor comparação a Tabela 1 mostra a acurácia das três redes em algumas das 30 épocas do processamento.

Analisando a tabela pode-se ver que o desempenho das redes foi bem diferente e que a Rede VGG-16 obteve o melhor resultado, apresentando um valor de 97,5%, valor esse considerado satisfatório para sua aplicação no problema destacado neste trabalho.

Rede	Épocas					
	05 epc	10 epc	15 epc	20 epc	25 epc	30 epc
<b>Alfa</b>	67,5%	75,0%	80,0%	75,0%	77,5%	80,0%
<b>VGG16</b>	82,5%	85,0%	87,5%	90,0%	92,5%	97,5%
<b>ResNet-50</b>	50,0%	50,0%	57,5%	55,0%	45,0%	50,0%

Tabela 1: Desempenho das CNN.

## 5 Conclusão

A aplicação da transferência de aprendizagem com o objetivo de classificar as condições de funcionamento dos equipamentos através da termografia foi a proposta desse estudo. Foram utilizadas três redes neurais convolucionais diferentes, uma elaborada a partir do zero e as outras duas são redes conhecidas e que serviram para a realização da transferência de aprendizagem.

Assim, o trabalho proposto mostra que é possível de se utilizar a transferência de aprendizagem na classificação de imagens termográficas de painéis elétricos e confirma a versatilidade de utilização de pesos já treinados em outros tipos de *dataset*, mesmo as imagens termográficas possuindo um estilo diferente das imagens utilizadas nas redes aqui testadas. O desempenho das redes já treinadas pode ser melhor se for aplicado a um *dataset* com maior número de imagens, pois estas foram treinadas com uma quantidade de imagens bem superior ao *dataset* utilizado.

Fica como proposta para trabalhos futuros a aplicação de uma rede neural convolucional específica para um *dataset* de imagens termográficas, de forma que sejam utilizados as convoluções que melhor se adéquam a esse tipo de imagem.

## Referências

- AHMED, Md. Manjur; HUDA, A.S.N.; MAT ISA, Nor Ashidi. Recursive construction of output-context fuzzy systems for the condition monitoring of electrical hotspots based on infrared thermography. **Engineering Applications of Artificial Intelligence**, v. 39, p. 120–131, 2015. ISSN 0952-1976. DOI: <https://doi.org/10.1016/j.engappai.2014.11.010>. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0952197614002826>.
- BAGAVATHIAPPAN, S. et al. Infrared thermography for condition monitoring – A review. **Infrared Physics & Technology**, v. 60, p. 35–55, 2013. ISSN 1350-4495. DOI: <https://doi.org/10.1016/j.infrared.2013.03.006>. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1350449513000327>.
- CAMPOS, D. C. M. P. **Implementação de Técnicas e Ferramentas Para Manutenção Preditiva na Colep**. 2010. Diss. (Mestrado) – Faculdade de Engenharia da Universidade do Porto. Disponível em: <https://repositorio-aberto.up.pt/handle/10216/61283>.
- CHELLAMUTHU, Shanmugam; SEKARAN, E. Chandira. Fault detection in electrical equipment's images by using optimal features with deep learning classifier. **Multimedia Tools and Applications**, v. 78, n. 19, p. 27333–27350, 2019. DOI: 10.1007/s11042-019-07847-z. Disponível em: <https://doi.org/10.1007/s11042-019-07847-z>.
- GUO, T. et al. Simple convolutional neural network on image classification. In: 2017 IEEE 2nd International Conference on Big Data Analysis (ICBDA). [S.l.: s.n.], 2017. p. 721–724. DOI: 10.1109/ICBDA.2017.8078730.
- HE, K. et al. Deep Residual Learning for Image Recognition. In: 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). [S.l.: s.n.], 2016. p. 770–778. DOI: 10.1109/CVPR.2016.90.
- HUDA, A.S.N.; TAIB, S. Suitable features selection for monitoring thermal condition of electrical equipment using infrared thermography. **Infrared Physics & Technology**, v. 61, p. 184–191, 2013. ISSN 1350-4495. DOI: <https://doi.org/10.1016/j.infrared.2013.04.012>. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1350449513001540>.
- JADIN, Mohd Shawal; TAIB, Soib. Recent progress in diagnosing the reliability of electrical equipment by using infrared thermography. **Infrared Physics & Technology**, v. 55, n. 4, p. 236–245, 2012. ISSN 1350-4495. DOI: <https://doi.org/10.1016/j.infrared.2012.03.002>. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1350449512000254>.
- MIGUEL WANDERLEY, D. S.; RICARDO PRUDÊNCIO, B. C. Transferring Knowledge From Texts to Images by Combining Deep Semantic Feature Descriptors. In: 2018 International Joint Conference on Neural Networks (IJCNN). [S.l.: s.n.], 2018. p. 1–7. DOI: 10.1109/IJCNN.2018.8489058.
- MLAKIĆ, D.; NIKOLOVSKI, S.; BAUS, Z. Detection of faults in electrical panels using deep learning method. In: INTERNATIONAL Conference on Smart Systems and Technologies (SST). [S.l.: s.n.], 2017. p. 55–61. DOI: 10.1109/SST.2017.8188670.
- YOSINSKI, Jason et al. How Transferable Are Features in Deep Neural Networks? In: PROCEEDINGS of the 27th International Conference on Neural Information Processing Systems - Volume 2. Montreal, Canada: MIT Press, 2014. (NIPS'14), p. 3320–3328.