

Deep Learning para Detecção de Componentes em Alimentadores de Subestações

Bruno Alberto Soares Oliveira, Abilio Pereira de Faria Neto, Roberto Márcio Arruda Fernandino, Diego de Proença Costa e Frederico Gadelha Guimarães

Resumo—A cada ano que se passa aumenta o consumo de energia elétrica no Brasil e no mundo, tornando-se necessária a adoção de medidas como a construção de novas usinas e a instalação de estruturas elétricas. O monitoramento para gestão de obras em empresas ainda é feito de forma presencial e manual, acarretando despesas que poderiam ser evitadas. O objetivo deste estudo é viabilizar uma prova de conceito ao se aplicar o detector de objetos Yolo em um conjunto de imagens que correspondem a dispositivos que compõem alimentadores em subestações. Os resultados demonstraram que é possível contribuir no monitoramento para gestão de obras com pesquisas deste ramo.

Palavras-Chave—Detector de objetos, Gestão de obras, Monitoramento.

Abstract—With each passing year, the consumption of electric energy in Brazil and in the world increases, making it necessary to adopt measures such as the construction of new plants and the installation of electrical structures. The monitoring of construction management in companies is still done in person and manually, resulting in expenses that could be avoided. The objective of this study is to enable a proof of concept by applying the Yolo object detector to a set of images that correspond to devices that make up bays in substations. The results show that it is possible to contribute to the monitoring of construction sites with research in this field.

Keywords—Object detector, Construction management, Monitoring.

I. INTRODUÇÃO

Acredita-se que nas próximas décadas o mundo irá consumir muito mais energia do que atualmente, afinal, sempre que houver acesso e disponibilidade de energia confiável, as pessoas irão desfrutar cada vez mais desse bem que nos dias de hoje tornou-se indispensável. Infelizmente existe uma enorme parcela da população mundial que ainda não tem acesso aos serviços básicos de energia. Além disso, as mudanças climáticas que vem ocorrendo nos últimos anos contribuem para que esse quadro perpetue, o que gera uma demanda crescente por novos empreendimentos no setor elétrico [17].

O auxílio da tecnologia para automação e otimização de problemas na indústria tornou-se hoje indispensável [16].

Bruno Alberto Soares Oliveira, Programa de Pós-Graduação em Engenharia Elétrica - Universidade Federal de Minas Gerais, Belo Horizonte-MG, brunoalbertobambui@ufmg.br; Abilio Pereira de Faria Neto, SVA Tech, Belo Horizonte-MG, abilio.faria@svatech.com.br; Roberto Márcio Arruda Fernandino, SVA Tech, Belo Horizonte-MG, roberto.fernandino@svatech.com.br; Diego De Proença Costa, CPFL Energia, Campinas-SP, diegocosta@cpfl.com.br; Frederico Gadelha Guimarães, Programa de Pós-Graduação em Engenharia Elétrica - UFMG, Belo Horizonte-MG, fredericoguimaraes@ufmg.br. A atual pesquisa é financiada pelo Programa P&D ANEEL (PD-00063-3073/2020) através da CPFL Energia e com parceria da empresa SVA Tech.

Uma das possíveis ferramentas que podem ser utilizadas na resolução desses problemas são os métodos de aprendizado de máquina, que são algoritmos que analisam dados, aprendem com esses e aplicam o que aprenderam para tomar decisões de forma autônoma. O aprendizado de máquina pode ser encontrado em diversas aplicações nas mais variadas áreas, como na medicina, nas ciências agrárias, engenharias, no setor de energia elétrica, telecomunicações entre outras [18].

O grande volume de empreendimentos realizados pelo grupo da CPFL Energia demanda cada vez mais recursos humanos para realizar a gestão de obras. Anualmente o time de engenharia realiza a gestão de mais de 85 obras, das quais aproximadamente 20% (por volta de 15 obras) são de instalação de alimentadores de 15kV, que apresenta um custo médio de R\$ 320 mil por obra. Os alimentadores são conjuntos de elementos com funções específicas no sistema elétrico, que permitem a composição da subestação em módulos.

Devido à padronização dos projetos, as atividades executadas tornam-se recorrentes e processuais, criando oportunidades para utilização de recursos tecnológicos para a automação de processo de gestão, e, portanto, ganho de produtividade do recurso humano empregado. Logo, o objetivo principal desse estudo é viabilizar uma prova de conceito implementando um modelo de aprendizado de máquina que seja capaz de detectar os principais elementos que compõem alimentadores em subestações de energia elétrica, visando, futuramente, utilizar esse modelo treinado como parte de um sistema que servirá para otimizar as atividades de gestão de obras em subestações.

II. REFERENCIAL TEÓRICO

A. Problema de Interesse

Atualmente o monitoramento das distribuidoras de energia que gerenciam as atividades das obras nas subestações de distribuição tem sido realizado de forma presencial e manual, estando suscetível a erros técnicos ou até mesmo à má fé do funcionário. Regularmente, em curtos períodos definidos pela empresa, os responsáveis devem se deslocar a cada subestação para realizar o processo de monitoramento e avanço das obras.

Alimentadores de subestações tem como principais componentes: painel, transformadores de corrente, transformadores de potência, chaves seccionadoras e isoladores. A Figura 1 apresenta dois alimentadores instalados um ao lado da outro.

B. Visão Computacional

A visão computacional é definida como um campo da ciência da computação que se concentra em produzir as mesmas



Fig. 1. Exemplo de dois alimentadores instalados em série.

tarefas que um olho humano é capaz de realizar, permitindo que os computadores identifiquem e processem objetos em imagens e vídeos [5] [8].

De acordo com [22], um dos fatores determinantes e que mais contribui para o crescimento da visão computacional é a quantidade de dados (imagens ou vídeos) disponíveis que são gerados hoje em dia. Aliado a isso, com os avanços da inteligência artificial e do aprendizado profundo (*deep learning*), a visão computacional tem conseguido inclusive superar os seres humanos em algumas tarefas relacionadas a identificação de objetos.

Atualmente existe uma infinidade de aplicações de visão computacional tanto na indústria quanto no dia a dia das pessoas. Carros autônomos que compreendem o ambiente e conseguem tomar decisões de forma automática, reconhecimento facial para identificação de rostos, aplicações na área da saúde que visam contribuir para o diagnóstico de doenças entre outras.

C. Deep Learning

O aprendizado profundo envolve uma classe de algoritmos de aprendizado de máquina que têm como principal objetivo extrair recursos de forma que o computador possa aprender a partir de exemplos e, posteriormente, tomar decisões para um determinado problema [7].

No aprendizado profundo, um modelo aprende a executar tarefas de classificação de imagens, texto ou som. Tais modelos de aprendizado profundo podem, muitas vezes, alcançar resultados bastante precisos, às vezes excedendo o desempenho dos próprios seres humanos.

Embora o aprendizado profundo tenha sido teorizado na década de 1980 [12], veio a ser difundido somente nos últimos anos por duas razões: a grande quantidade de dados disponível atualmente e o avanço das pesquisas na área de hardware, aumentando os recursos computacionais existentes [24].

D. Yolo

No campo da visão computacional existem dezenas de métodos que buscam solucionar basicamente três tipos de problemas: classificação, detecção e segmentação [25]. Cada problema tem sua particularidade e é necessário tratá-los de maneira diferente.

Um modelo classificador é capaz de dizer se um determinado objeto está ou não contido em uma imagem. Um modelo detector consegue localizar o objeto, classificando e criando uma caixa delimitadora em volta do mesmo. No caso de um modelo que segmenta objetos, o mesmo consegue classificar cada pixel da imagem, resultando em um objeto extraído sem seu fundo, diferente de como ocorre na detecção [9].

De acordo com seu criador [20], *You Only Look Once* (Yolo), em português, você olha apenas uma vez, é um sistema de detecção de objetos de última geração que pode ser utilizado tanto para imagens estáticas quanto em tempo real, processando vídeos a 30 frames por segundos (FPS) e possuindo um *mean average precision* (mAP) de 57,9% no conjunto de dados COCO.

Até o desenvolvimento do Yolo, os sistemas de detecção utilizavam classificadores ou localizadores para conseguir encontrar as coordenadas do objeto na imagem, aplicando diferentes modelos na figura variando os locais da busca e, com isso, partem da premissa que regiões com alta pontuação da imagem são consideradas detecções.

No trabalho de [20] foi utilizado uma premissa totalmente diferente, em que se aplica um único modelo de rede neural artificial (RNA) na imagem como um todo. A RNA faz a divisão da figura em várias regiões e realiza a previsão de caixas delimitadoras e suas respectivas probabilidades, para cada uma das regiões. Com isso, essas caixas delimitadoras são ponderadas pelas probabilidades previstas e conseqüentemente é possível detectar os objetos de interesse.

E. Trabalhos Relacionados

Não foram encontrados trabalhos que tenham utilizado aprendizado profundo e redes neurais convolucionais para resolver especificamente o problema de monitoramento para gestão de obras em subestações. Existem alguns trabalhos que aplicam o aprendizado profundo com o objetivo de detectar falhas em subestações de maneira geral, e alguns outros que classificam objetos presentes em determinada obra de construção civil.

Na pesquisa desenvolvida por [14] foi discutido que o aumento substancial de imagens de infravermelho no sistema elétrico de subestações apresenta um novo desafio, exemplificando a forma como a avaliação do status dos dispositivos é feita tradicionalmente. Para superar esse problema, o trabalho de [14] propõe um método de análise automática de imagens de infravermelho. O algoritmo implementado primeiro segmenta imagens em superpixels e, em seguida, adota redes neurais convolucionais para classificação dos objetos. Foi alcançado bons resultados em comparação com outros métodos de treinamento não supervisionado testados.

A utilização de aprendizado profundo e o detector de objetos Yolo pode ser encontrado na pesquisa de [6], em que os

autores aplicaram o método para detecção e reconhecimento inteligente de quadros de distribuição de alta tensão. O sistema proposto tem como objetivo executar algumas tarefas, como identificar o posicionamento de uma chave, assim como reconhecer e determinar seu estado.

No trabalho de [23] foi proposta uma nova abordagem de reconhecimento de estados baseado em redes neurais convolucionais de comutadores em subestações. Foi empregado aprendizado por transferência no modelo, em que os autores usaram o conjunto de imagens ILSVRC2012, retreinando o modelo com suas próprias imagens da subestação estudada. Em seus experimentos, obtiveram resultados bastantes satisfatórios e concluíram que a abordagem proposta pode ser aplicada a subestação analisada, podendo reduzir o custo de operação caso a indústria decida implantar o sistema.

A utilização do equipamento de proteção individual (EPI) e do equipamento de proteção coletiva (EPC) é uma importante medida de segurança que tem como objetivo proteger os funcionários no ambiente de trabalho. Infelizmente, por falta de responsabilidade, ainda existem trabalhadores que persistem em não utilizar tais equipamentos sujeitando-se a um maior risco de acidente fatal. Visando automatizar o processo de detecção de tais funcionários, no artigo de [3] foi aplicado o detector de objetos R-CNN mais rápido, com o intuito de detectar trabalhadores que não estão com o EPI. Os resultados experimentais demonstraram que o método obteve alta precisão na detecção de pessoas que estão indo contra as políticas de segurança da empresa.

Para o gerenciamento adequado de obras e as revisões do plano durante a construção, é preciso que se entenda o status da obra em tempo real. Visando auxiliar no desenvolvimento de soluções para a construção civil, os autores de [10] propõem um método de aprendizado profundo que tem como objetivo reconhecer com precisão equipamentos de construção. Pela falta de imagens disponíveis dos objetos abordados, foi utilizado o aprendizado por transferência que classifica cinco classes: caminhão basculante, escavadeira, carregadeira, caminhão betoneira e rolo compactador. Os resultados atingiram um valor de 96,33% para a precisão média. O método proposto pode ser utilizado para inferir o contexto das operações de construção civil, gerando dados como o progresso da obra, produtividade e segurança.

De forma similar, em [4] os autores desenvolveram um sistema para monitoramento de gestão de obras na construção civil, realizando a detecção automática de trabalhadores e escavadeiras em um determinado canteiro de obras. Foi utilizado o método R-CNN mais rápido que obteve resultados bastante satisfatórios, detectando a presença de trabalhadores e escavadeiras com um alto nível de precisão (91% e 95%). De acordo com os autores, a precisão do método de aprendizado profundo proposto excede a dos métodos atuais na detecção de objetos em canteiros de obras.

No trabalho de [1] foi desenvolvida uma solução baseada em aprendizado profundo para detecção de equipamentos de construção, partindo de um loteamento vago até a obra totalmente concluída. A análise dos resultados confirma o desempenho superior em tempo real da solução proposta com uma taxa de precisão acima de 90%. O presente estudo valida

a praticidade de soluções de detecção de objetos baseadas em aprendizado profundo para cenários de construção. Além disso, a solução pode ser empregada para diversas finalidades, como monitoramento de segurança, avaliações de produtividade e decisões gerenciais.

Conforme citado anteriormente, na atual literatura não se encontra trabalhos que utilizem técnicas de aprendizado profundo na detecção de componentes em alimentadores de subestações. A atual pesquisa se trata de uma prova de conceito na aplicação do método Yolo em um conjunto de dados sintéticos, que tem como objetivo viabilizar o aprofundamento da pesquisa e desenvolver futuramente uma aplicação real que poderá auxiliar a gestão de obras para a construção de alimentadores em subestações.

III. MATERIAL E MÉTODOS

A. Conjunto de Dados

As imagens utilizadas neste estudo podem ser coletadas usando três tipos de processos. Primeiro, o conjunto de imagens pode ser criado a partir de outros conjuntos de dados disponíveis em grande escala, como o *ImageNet* [21], *Common Objects in Context (COCO)* [13] e o *Open Image Dataset* [11]. Segundo, os dados podem ser coletados a partir de técnicas de rastreamento na Web [19]. E por fim, a terceira opção se trata da aquisição dos dados em campo, capturados no local da aplicação por pesquisadores ou engenheiros. Apenas a segunda abordagem foi adotada neste estudo, uma vez que não foi encontrado um conjunto de dados em grande escala que possuísse os objetos que compõem um alimentador. A terceira abordagem foi descartada em razão do trabalho se tratar de uma prova de conceito, ficando a coleta de dados em campo para uma pesquisa futura.

Após a coleta das imagens, inspeção, correção e seleção, o conjunto de dados foi anotado pelos autores, criando caixas delimitadoras em torno dos objetos abordados. Em seguida, foi desenvolvido um *script* na linguagem de programação Python para a aplicação de técnicas de aumento de dados nas imagens rotuladas. Foram adotadas operações de rotação, cisalhamento, espelhamento, corte, mudança de escala entre outras. A utilização de técnicas de aumento de dados é extremamente importante para que algoritmos de aprendizado profundo alcancem um desempenho satisfatório. Com isso foram gerados dois conjuntos de imagens: o primeiro contendo 3600 imagens e o segundo contendo 1500 imagens.

Importante salientar que as imagens originais não fazem parte do conjunto de dados utilizado para o treinamento e validação. Foi definido que o conjunto de treinamento terá 80% das imagens e o conjunto de validação 20%. Os objetos escolhidos para este estudo são quatro, sendo eles: suporte de concreto para painel, painel, grade de proteção e transformador de corrente. A Figura 2 apresenta alguns exemplos de imagens que compõem o conjunto de dados.

B. Implementação do Algoritmo

Para implementação do algoritmo proposto foi utilizado o Google Colab, que é um serviço em nuvem empregado no desenvolvimento de algoritmos de aprendizado de máquina na



Fig. 2. Exemplos de imagens contidas no conjunto de dados.

linguagem de programação Python [2]. O Google Colab tem algumas limitações em sua versão gratuita, fazendo com que não fosse possível executar um maior número de experimentos e utilizar um conjunto de imagens mais robusto. Apesar disso, sua escolha é justificada pelo fato do mesmo oferecer suporte a GPU.

O ImageAI é uma biblioteca para a linguagem de programação Python que foi desenvolvida visando capacitar desenvolvedores, pesquisadores e estudantes a criarem aplicativos e sistemas com recursos independentes de aprendizado profundo e visão computacional [15]. Suporta uma lista de algoritmos de aprendizado de máquina para classificação e detecção de objetos em imagens, dentre eles o utilizado neste trabalho: o detector de objetos Yolo.

C. Experimentos

Conforme mencionado anteriormente, o Google Colab tem suas limitações e por isso não é possível realizar um maior número de experimentos. Ele é capaz de executar o treinamento de um modelo ininterrupto por 12 horas, o que é um problema quando se trata de aprendizado profundo.

Foram definidas quatro configurações diferentes de experimentos para o treinamento, conforme indicado na Tabela I.

TABELA I
CONFIGURAÇÃO DE TREINAMENTO PARA CADA EXPERIMENTO.

Configuração	1	2	3	4
Número de imagens	3000	3000	1200	1200
Aprendizado por transferência?	Sim	Não	Sim	Não
Número de épocas	18	18	25	25
batch_size	32	32	16	16

O aprendizado por transferência pode ser definido como a prática em utilizar o conhecimento adquirido ao resolver determinado problema, aplicando-o a um problema diferente. Para as configurações que utilizam o aprendizado por transferência foi adotado um modelo Yolo pré-treinado no conjunto de dados COCO. Para os demais, os pesos de cada neurônio se inicializaram aleatoriamente.

O número de épocas é um hiperparâmetro que define o número de vezes que o algoritmo de aprendizado funcionará durante todo o conjunto de dados de treinamento. Já tamanho do lote (batch_size) é um hiperparâmetro que define o número de amostras (imagens) a serem analisadas antes de atualizar os parâmetros internos do modelo.

Iniciado o treinamento, o ImageAI gera automaticamente as melhores caixas de ancoragem que correspondem ao conjunto de imagens e, além disso, ao fim de cada época é salvo o modelo com os parâmetros definidos para aquela determinada época.

Após a conclusão do treinamento, é avaliada a pontuação do mAP para cada um dos modelos salvos de cada configuração da Tabela I, sendo possível escolher os que obtiveram um valor de mAP mais próximo a um.

Em seguida, é realizado testes aplicando novas imagens não vistas nem no treinamento nem na validação, isso para cada um dos melhores modelos selecionados para cada configuração da Tabela I, definindo o percentual de probabilidade mínima de detecção. Por fim, é feita uma análise comparativa entre o melhor modelo de cada configuração proposta.

IV. RESULTADOS E DISCUSSÃO

A Tabela II apresenta o valor de mAP para os três melhores modelos de cada configuração proposta.

TABELA II
VALORES DE MAP OBTIDOS.

Conf.	1			2		
Época	13	15	17	14	15	17
mAP (%)	99.97	99.98	99.98	100	97.24	99.99
Conf.	3			4		
Época	21	22	25	21	23	24
mAP (%)	99.86	99.88	99.87	99.89	97.22	99.43

Conforme apresentado na Tabela II, é possível perceber que o valor de mAP obtido na etapa de validação é bem próximo para os modelos das últimas épocas do treinamento independente da configuração proposta.

O que foi percebido durante o treinamento é que, para as configurações em que se foi adotado o aprendizado por transferência, o modelo convergiu para um menor erro de treinamento mais rapidamente conforme é esperado quando se decide utilizar tal técnica.

Treinado e validado cada modelo, é possível detectar os objetos treinados em novas imagens, conforme exemplificado na Figura 3. A Tabela III fornece as informações que o sistema retorna após a imagem do exemplo ter sido submetida ao mesmo.

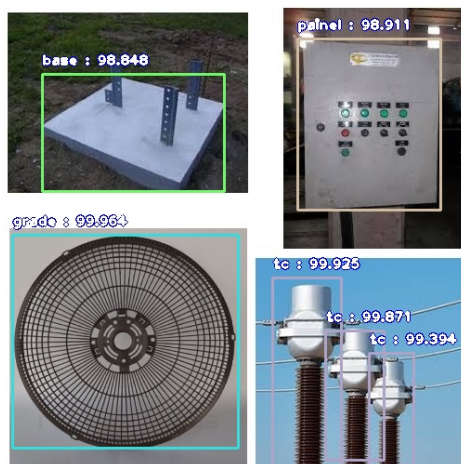


Fig. 3. Exemplo de imagem de teste.

TABELA III

RESULTADO DA APLICAÇÃO DO DETECTOR DE OBJETOS NA IMAGEM.

Classe	Probabilidade	Coordenadas
grade	99.9639	[10, 246, 253, 475]
base	98.8481	[42, 73, 238, 199]
painel	98.9105	[317, 35, 471, 219]
tc	99.9248	[290, 292, 364, 498]
tc	99.8711	[347, 349, 410, 488]
tc	99.3944	[394, 373, 442, 494]

A Tabela III mostra o resultado da aplicação do detector de objetos Yolo na imagem de exemplo da Figura 3, sem a marcação das caixas delimitadoras. No momento em que a imagem desconhecida é recebida pelo detector, ele realiza as detecções retornando a classe a qual tal objeto na imagem pertence (primeira coluna da Tabela III), com a probabilidade de confiança que varia de 0 a 100% do objeto pertencer a determinada classe prevista (segunda coluna da Tabela III) e as coordenadas do objeto na imagem no formato Pascal VOC (x-esquerda superior, y-esquerda superior, largura, altura) (terceira coluna da Tabela III).

Assim como ilustrado na Figura 3 e apresentado na Tabela III, é possível perceber que para qualquer configuração proposta, o modelo Yolo convergiu muito bem, alcançando resultados em torno de 99% para as imagens testadas.

V. CONSIDERAÇÕES FINAIS

O presente estudo teve como objetivo verificar uma prova de conceito que consistiu na aplicação do detector de objetos Yolo para identificação de quatro componentes em alimentadores de subestações, são eles: suporte de concreto para painel, painel, grade de proteção e transformador de corrente. Os resultados obtidos em torno de 99% para o valor de mAP demonstraram a eficiência do detector Yolo para o atual estudo.

Como trabalhos futuros, será coletado um conjunto de imagens em campo, além de ser testado outros detectores de objetos, como R-CNN e suas variações, SSD, RetinaNet entre outros. Acredita-se que a pesquisa desenvolvida possa servir de base para estudos futuros na gestão de obras de maneira geral, não apenas para alimentadores em subestações.

REFERÊNCIAS

- [1] Arabi, Saeed, Arya Haghighat, and Anuj Sharma. "A deep learning based solution for construction equipment detection: from development to deployment." *arXiv preprint arXiv:1904.09021* (2019).
- [2] Bisong, Ekaba. "Google Colaboratory." *Building Machine Learning and Deep Learning Models on Google Cloud Platform*. Apress, Berkeley, CA, 2019. 59-64.
- [3] Fang, Qi, et al. "Detecting non-hardhat-use by a deep learning method from far-field surveillance videos." *Automation in Construction* 85 (2018): 1-9.
- [4] Fang, Weili, et al. "Automated detection of workers and heavy equipment on construction sites: A convolutional neural network approach." *Advanced Engineering Informatics* 37 (2018): 139-149.
- [5] Forsyth, David A., and Jean Ponce. *Computer vision: a modern approach*. Prentice Hall Professional Technical Reference, 2002.
- [6] Fu, Chen-Zhao, et al. "Research on a detection and recognition algorithm for high-voltage switch cabinet based on deep learning with an improved YOLOv2 Network." *2018 11th International Conference on Intelligent Computation Technology and Automation (ICICTA)*. IEEE, 2018.
- [7] Goodfellow, Ian, Yoshua Bengio, and Aaron Courville. *Deep learning*. MIT press, 2016.
- [8] Haralick, Robert M., and Linda G. Shapiro. *Computer and robot vision*. Vol. 1. Reading: Addison-wesley, 1992.
- [9] Hoffman, Richard, and Anil K. Jain. "Segmentation and classification of range images." *IEEE transactions on pattern analysis and machine intelligence* 5 (1987): 608-620.
- [10] Kim, Hongjo, et al. "Detecting construction equipment using a region-based fully convolutional network and transfer learning." *Journal of computing in Civil Engineering* 32.2 (2018): 04017082.
- [11] Kuznetsova, Alina, et al. "The open images dataset v4: Unified image classification, object detection, and visual relationship detection at scale." *arXiv preprint arXiv:1811.00982* (2018).
- [12] LeCun, Yann, Yoshua Bengio, and Geoffrey Hinton. "Deep learning." *nature* 521.7553 (2015): 436-444.
- [13] Lin, Tsung-Yi, et al. "Microsoft coco: Common objects in context." *European conference on computer vision*. Springer, Cham, 2014.
- [14] Lin, Ying, et al. "Deep learning for intelligent substation device infrared fault image analysis." *MATEC Web of Conferences*. Vol. 55. EDP Sciences, 2016.
- [15] Moses, John Olafenwa. "ImageAI, an open source python library built to empower developers to build applications and systems with self-contained Computer Vision capabilities." <https://github.com/OlafenwaMoses/ImageAI> (2018).
- [16] Oliveira, Bruno, et al. "Análise de Uso do Sistema Elétrico Auxiliar de Um Aquecedor Solar, Localizado Em Um Instituto Público no Centro-oeste de Minas Gerais." *Revista Mundi Engenharia, Tecnologia e Gestão (ISSN: 2525-4782)* 4.6 (2020).
- [17] Oliveira, Bruno Alberto Soares, Servílio Assis, and Carlos Noll. "Development of a prototype electrical energy monitoring system via internet/desenvolvimento de um protótipo de sistema de monitoramento de energia elétrica via internet." *Revista de Engenharia da Universidade Católica de Petrópolis* 12.1 (2019): 48-61.
- [18] Oliveira, Bruno Alberto Soares, et al. "Avaliação de uma rede neural artificial como estimador temporal pluviométrico no sistema de abastecimento cantareira." *Revista de Informática Aplicada* 14.1 (2018).
- [19] Olston, Christopher, and Marc Najork. "Web crawling." *Foundations and Trends® in Information Retrieval* 4.3 (2010): 175-246.
- [20] Redmon, Joseph, and Ali Farhadi. "Yolov3: An incremental improvement." *arXiv preprint arXiv:1804.02767* (2018).
- [21] Russakovsky, Olga, et al. "Imagenet large scale visual recognition challenge." *International journal of computer vision* 115.3 (2015): 211-252.
- [22] Voulodimos, Athanasios, et al. *Deep learning for computer vision: A brief review*. Computational intelligence and neuroscience 2018 (2018).
- [23] Wang, Jin. "Deep learning based state recognition of substation switches." *AIP Conference Proceedings*. Vol. 1971. No. 1. AIP Publishing LLC, 2018.
- [24] Yang, Wenming, et al. "Deep learning for single image super-resolution: A brief review." *IEEE Transactions on Multimedia* 21.12 (2019): 3106-3121.
- [25] Yao, Jian, Sanja Fidler, and Raquel Urtasun. "Describing the scene as a whole: Joint object detection, scene classification and semantic segmentation." *2012 IEEE conference on computer vision and pattern recognition*. IEEE, 2012.