

Elói Martins Senhoras
(Organizador)

Políticas públicas

para ciência, tecnologia e inovação 2



Elói Martins Senhoras
(Organizador)

Políticas públicas

para ciência, tecnologia e inovação 2



Editora chefe

Profª Drª Antonella Carvalho de Oliveira

Editora executiva

Natalia Oliveira

Assistente editorial

Flávia Roberta Barão

Bibliotecária

Janaina Ramos

Projeto gráfico

Bruno Oliveira

Camila Alves de Cremo

Daphynny Pamplona

Luiza Alves Batista

Natália Sandrini de Azevedo

Imagens da capa

iStock

Edição de arte

Luiza Alves Batista

2022 by Atena Editora

Copyright © Atena Editora

Copyright do texto © 2022 Os autores

Copyright da edição © 2022 Atena Editora

Direitos para esta edição cedidos à Atena Editora pelos autores.

Open access publication by Atena Editora



Todo o conteúdo deste livro está licenciado sob uma Licença de Atribuição *Creative Commons*. Atribuição-Não-Comercial-NãoDerivativos 4.0 Internacional (CC BY-NC-ND 4.0).

O conteúdo dos artigos e seus dados em sua forma, correção e confiabilidade são de responsabilidade exclusiva dos autores, inclusive não representam necessariamente a posição oficial da Atena Editora. Permitido o *download* da obra e o compartilhamento desde que sejam atribuídos créditos aos autores, mas sem a possibilidade de alterá-la de nenhuma forma ou utilizá-la para fins comerciais.

Todos os manuscritos foram previamente submetidos à avaliação cega pelos pares, membros do Conselho Editorial desta Editora, tendo sido aprovados para a publicação com base em critérios de neutralidade e imparcialidade acadêmica.

A Atena Editora é comprometida em garantir a integridade editorial em todas as etapas do processo de publicação, evitando plágio, dados ou resultados fraudulentos e impedindo que interesses financeiros comprometam os padrões éticos da publicação. Situações suspeitas de má conduta científica serão investigadas sob o mais alto padrão de rigor acadêmico e ético.

Conselho Editorial**Ciências Humanas e Sociais Aplicadas**

Prof. Dr. Adilson Tadeu Basquerote Silva – Universidade para o Desenvolvimento do Alto Vale do Itajaí

Prof. Dr. Alexandre de Freitas Carneiro – Universidade Federal de Rondônia

Prof. Dr. Alexandre Jose Schumacher – Instituto Federal de Educação, Ciência e Tecnologia do Paraná

Prof. Dr. Américo Junior Nunes da Silva – Universidade do Estado da Bahia

Profª Drª Ana Maria Aguiar Frias – Universidade de Évora

Profª Drª Andréa Cristina Marques de Araújo – Universidade Fernando Pessoa



Prof. Dr. Antonio Carlos da Silva – Universidade Católica do Salvador
Prof. Dr. Antonio Carlos Frasson – Universidade Tecnológica Federal do Paraná
Prof. Dr. Antonio Gasparetto Júnior – Instituto Federal do Sudeste de Minas Gerais
Prof. Dr. Antonio Isidro-Filho – Universidade de Brasília
Prof. Dr. Arnaldo Oliveira Souza Júnior – Universidade Federal do Piauí
Prof. Dr. Carlos Antonio de Souza Moraes – Universidade Federal Fluminense
Prof. Dr. Crisóstomo Lima do Nascimento – Universidade Federal Fluminense
Prof^o Dr^a Cristina Gaio – Universidade de Lisboa
Prof. Dr. Daniel Richard Sant’Ana – Universidade de Brasília
Prof. Dr. Deyvison de Lima Oliveira – Universidade Federal de Rondônia
Prof^o Dr^a Dilma Antunes Silva – Universidade Federal de São Paulo
Prof. Dr. Edvaldo Antunes de Farias – Universidade Estácio de Sá
Prof. Dr. Elson Ferreira Costa – Universidade do Estado do Pará
Prof. Dr. Eloi Martins Senhora – Universidade Federal de Roraima
Prof. Dr. Gustavo Henrique Cepolini Ferreira – Universidade Estadual de Montes Claros
Prof. Dr. Humberto Costa – Universidade Federal do Paraná
Prof^o Dr^a Ivone Goulart Lopes – Istituto Internazionele delle Figlie de Maria Ausiliatrice
Prof. Dr. Jadilson Marinho da Silva – Secretaria de Educação de Pernambuco
Prof. Dr. Jadson Correia de Oliveira – Universidade Católica do Salvador
Prof. Dr. José Luis Montesillo-Cedillo – Universidad Autónoma del Estado de México
Prof. Dr. Julio Candido de Meirelles Junior – Universidade Federal Fluminense
Prof. Dr. Kárpio Márcio de Siqueira – Universidade do Estado da Bahia
Prof^o Dr^a Keyla Christina Almeida Portela – Instituto Federal do Paraná
Prof^o Dr^a Lina Maria Gonçalves – Universidade Federal do Tocantins
Prof^o Dr^a Lucicleia Barreto Queiroz – Universidade Federal do Acre
Prof. Dr. Luis Ricardo Fernandes da Costa – Universidade Estadual de Montes Claros
Prof. Dr. Lucio Marques Vieira Souza – Universidade do Estado de Minas Gerais
Prof^o Dr^a Natiéli Piovesan – Instituto Federal do Rio Grande do Norte
Prof^o Dr^a Marianne Sousa Barbosa – Universidade Federal de Campina Grande
Prof. Dr. Marcelo Pereira da Silva – Pontifícia Universidade Católica de Campinas
Prof^o Dr^a Maria Luzia da Silva Santana – Universidade Federal de Mato Grosso do Sul
Prof. Dr. Miguel Rodrigues Netto – Universidade do Estado de Mato Grosso
Prof. Dr. Pedro Henrique Máximo Pereira – Universidade Estadual de Goiás
Prof. Dr. Pablo Ricardo de Lima Falcão – Universidade de Pernambuco
Prof^o Dr^a Paola Andressa Scortegagna – Universidade Estadual de Ponta Grossa
Prof^o Dr^a Rita de Cássia da Silva Oliveira – Universidade Estadual de Ponta Grossa
Prof. Dr. Rui Maia Diamantino – Universidade Salvador
Prof. Dr. Saulo Cerqueira de Aguiar Soares – Universidade Federal do Piauí
Prof. Dr. Urandi João Rodrigues Junior – Universidade Federal do Oeste do Pará
Prof^o Dr^a Vanessa Bordin Viera – Universidade Federal de Campina Grande
Prof^o Dr^a Vanessa Ribeiro Simon Cavalcanti – Universidade Católica do Salvador
Prof. Dr. William Cleber Domingues Silva – Universidade Federal Rural do Rio de Janeiro
Prof. Dr. Willian Douglas Guilherme – Universidade Federal do Tocantins



Políticas públicas para ciência, tecnologia e inovação 2

Diagramação: Camila Alves de Cremo
Correção: Maiara Ferreira
Indexação: Amanda Kelly da Costa Veiga
Revisão: Os autores
Organizador: Elói Martins Senhoras

Dados Internacionais de Catalogação na Publicação (CIP)

P769 Políticas públicas para ciência, tecnologia e inovação 2 /
Organizador Elói Martins Senhoras. – Ponta Grossa -
PR: Atena, 2022.

Formato: PDF

Requisitos de sistema: Adobe Acrobat Reader

Modo de acesso: World Wide Web

Inclui bibliografia

ISBN 978-65-258-0344-9

DOI: <https://doi.org/10.22533/at.ed.449222906>

1. Tecnologia. I. Senhoras, Elói Martins (Organizador).

II. Título.

CDD 601

Elaborado por Bibliotecária Janaina Ramos – CRB-8/9166

Atena Editora

Ponta Grossa – Paraná – Brasil

Telefone: +55 (42) 3323-5493

www.atenaeditora.com.br

contato@atenaeditora.com.br



Atena
Editora
Ano 2022

DECLARAÇÃO DOS AUTORES

Os autores desta obra: 1. Atestam não possuir qualquer interesse comercial que constitua um conflito de interesses em relação ao artigo científico publicado; 2. Declaram que participaram ativamente da construção dos respectivos manuscritos, preferencialmente na: a) Concepção do estudo, e/ou aquisição de dados, e/ou análise e interpretação de dados; b) Elaboração do artigo ou revisão com vistas a tornar o material intelectualmente relevante; c) Aprovação final do manuscrito para submissão.; 3. Certificam que os artigos científicos publicados estão completamente isentos de dados e/ou resultados fraudulentos; 4. Confirmam a citação e a referência correta de todos os dados e de interpretações de dados de outras pesquisas; 5. Reconhecem terem informado todas as fontes de financiamento recebidas para a consecução da pesquisa; 6. Autorizam a edição da obra, que incluem os registros de ficha catalográfica, ISBN, DOI e demais indexadores, projeto visual e criação de capa, diagramação de miolo, assim como lançamento e divulgação da mesma conforme critérios da Atena Editora.



DECLARAÇÃO DA EDITORA

A Atena Editora declara, para os devidos fins de direito, que: 1. A presente publicação constitui apenas transferência temporária dos direitos autorais, direito sobre a publicação, inclusive não constitui responsabilidade solidária na criação dos manuscritos publicados, nos termos previstos na Lei sobre direitos autorais (Lei 9610/98), no art. 184 do Código penal e no art. 927 do Código Civil; 2. Autoriza e incentiva os autores a assinarem contratos com repositórios institucionais, com fins exclusivos de divulgação da obra, desde que com o devido reconhecimento de autoria e edição e sem qualquer finalidade comercial; 3. Todos os e-book são *open access*, *desta forma* não os comercializa em seu site, sites parceiros, plataformas de *e-commerce*, ou qualquer outro meio virtual ou físico, portanto, está isenta de repasses de direitos autorais aos autores; 4. Todos os membros do conselho editorial são doutores e vinculados a instituições de ensino superior públicas, conforme recomendação da CAPES para obtenção do Qualis livro; 5. Não cede, comercializa ou autoriza a utilização dos nomes e e-mails dos autores, bem como nenhum outro dado dos mesmos, para qualquer finalidade que não o escopo da divulgação desta obra.



APRESENTAÇÃO

O objetivo desta obra é apresentar a riqueza existente nos estudos de Ciência, Tecnologia e Inovação a partir de uma abrangente agenda de estudos que valoriza a pluralidade temática, metodológica e teórica para analisar a realidade empírica, partindo do ambiente escolar até se chegar ao meio empresarial.

A proposta implícita nesta obra valoriza a pluralidade teórica e metodológica por meio de um trabalho coletivo de pesquisadoras e pesquisadores de distintas formações acadêmicas e expertises, o que repercutiu em uma rica oportunidade para explorar as fronteiras do conhecimento sobre a Ciência, Tecnologia e Inovação.

Escrito por um conjunto diversificado de profissionais brasileiros advindos de diferentes estados macrorregiões do país, o presente livro expressa uma rica pluralidade de agendas de pesquisas construídas em diferentes instituições de ensino e pesquisa públicas e privadas e com base em distintas realidades e experiências.

O livro oferece um total de doze capítulos que abordam distintas realidades empíricas, por meio de estudos de caso que possibilitam um olhar multidisciplinar sobre temas relevantes sobre Ciência, Tecnologia e Inovação a partir das contribuições analíticas advindas dos campos epistemológicos de Educação, Administração e Engenharia de Produção.

Com base nas discussões e resultados obtidos nesta obra, uma rica construção epistemológica sobre Ciência, Tecnologia e Inovação fundamentada em relevantes análises de estudos de casos que corroboram para a produção de novas informações e conhecimentos sobre a realidade da escola à empresa.

A indicação deste livro é recomendada para um extenso número de leitores, uma vez que foi escrito por meio de uma linguagem fluída e de uma abordagem didática, acessível, tanto para um público leigo não afeito a tecnicismos, quanto para um público especializado de acadêmicos ou de profissionais que lidam com Ciência, Tecnologia e Inovação.

Excelente leitura!

Elói Martins Senhoras

SUMÁRIO

CAPÍTULO 1..... 1

A IMPORTÂNCIA DO CLIMA ORGANIZACIONAL PARA UMA GESTÃO EFICAZ DA ESCOLA

Dirceu Fernando Belotto

Rosimeire Martins Régis dos Santos

 <https://doi.org/10.22533/at.ed.4492229061>

CAPÍTULO 2..... 16

CULTURA POPULAR E EDUCAÇÃO POPULAR: UM OLHAR PARA O SISTEMA EDUCACIONAL DE JOVENS E ADULTOS ABARCADO PELO EDUCADOR PAULO FREIRE

Renata Maria Oliveira Mendes

Antônio Carlos Frasson

 <https://doi.org/10.22533/at.ed.4492229062>

CAPÍTULO 3..... 27

NÍSIA FLORESTA E A LUTA PELA EDUCAÇÃO FEMININA

Bárbara Lúcia Takei Barbieri Azevedo

 <https://doi.org/10.22533/at.ed.4492229063>

CAPÍTULO 4..... 40

PERCEPÇÕES SOBRE A PROGRAMAÇÃO E A ROBÓTICA EDUCACIONAL COMO POTENCIAIS GERADORA DE SITUAÇÕES DIDÁTICAS

Clodogil Fabiano Ribeiro dos Santos

Nilcéia Aparecida Maciel Pinheiro

Jussara Rodrigues Ciappina

 <https://doi.org/10.22533/at.ed.4492229064>

CAPÍTULO 5..... 58

A SEMIÓTICA PEIRCEANA, OS NÍVEIS DE COMPREENSÃO DO CONHECIMENTO QUÍMICO E AS MÚLTIPLAS REPRESENTAÇÕES: UM ESTUDO ENVOLVENDO OS TRÊS REFERENCIAIS E O CONTEÚDO SOLUBILIDADE QUÍMICA

Maysa de Fátima Moraes Frauzino

Elaine da Silva Ramos

Carlos Eduardo Laburú

 <https://doi.org/10.22533/at.ed.4492229065>

CAPÍTULO 6..... 70

DESENVOLVIMENTO DE SOLUÇÃO IOT PARA SENSORIAMENTO HÍDRICO EM TEMPO REAL

Jorge Otta Júnior

Leandro Augusto de Carvalho

Pedro Luiz de Paula

 <https://doi.org/10.22533/at.ed.4492229066>

CAPÍTULO 7	88
UMA APLICAÇÃO DE RANDOM SURVIVAL FORESTS NA AVALIAÇÃO DE DADOS DE FALHA DE BOMBAS CENTRÍFUGAS SUBMERSAS	
Ricardo de Melo e Silva Accioly	
Rafael de Olivaes Valle dos Santos	
 https://doi.org/10.22533/at.ed.4492229067	
CAPÍTULO 8	102
RESEARCH OF 3D PRINTING TECHNIQUES WITH METALS	
Rômulo da Costa Delmondes	
Marcelo Antonio Adad de Araújo	
 https://doi.org/10.22533/at.ed.4492229068	
CAPÍTULO 9	119
APLICAÇÃO DE REDES NEURAIS CONVOLUCIONAIS EM LINHAS DE DISTRIBUIÇÃO DE ENERGIA	
Milena Lucas dos Santos	
Fabiana Frata Furlan Peres	
Valéria Nunes dos Santos	
Claudio Roberto Marquette Mauricio	
 https://doi.org/10.22533/at.ed.4492229069	
CAPÍTULO 10	132
O TRABALHO DE CATADORES DE MATERIAL RECICLADO COMO INSTRUMENTO PARA SENSIBILIZAR A PARTICIPAÇÃO NA COLETA SELETIVA	
Paola de Cassia Ferreira Borges	
Rosemari Castilho Foggiatto Siveira	
 https://doi.org/10.22533/at.ed.44922290610	
CAPÍTULO 11	144
PREVALÊNCIA DA SÍNDROME DE BURNOUT ENTRE PROFISSIONAIS DE SAÚDE QUE ATUAM EM UNIDADES DE TERAPIA INTENSIVA	
Vanessa Paula da Silva Oliveira	
 https://doi.org/10.22533/at.ed.44922290611	
CAPÍTULO 12	155
A GESTÃO FINANCEIRA E SUA IMPORTÂNCIA NAS PEQUENAS E MÉDIAS EMPRESAS	
Edivaldo Braga de Oliveira	
Gabriel Babichi Siqueira	
Moises da Silva Martins	
 https://doi.org/10.22533/at.ed.44922290612	
SOBRE O ORGANIZADOR	167
ÍNDICE REMISSIVO	168

APLICAÇÃO DE REDES NEURAIS CONVOLUCIONAIS EM LINHAS DE DISTRIBUIÇÃO DE ENERGIA

Data de aceite: 01/06/2022

Data de submissão: 12/04/2022

Milena Lucas dos Santos

Universidade Estadual do Oeste do Paraná
Foz do Iguaçu, Paraná
<http://lattes.cnpq.br/7448020278417626>

Fabiana Frata Furlan Peres

Universidade Estadual do Oeste do Paraná
Foz do Iguaçu, Paraná
<http://lattes.cnpq.br/4134919454057451>

Valéria Nunes dos Santos

Fundação Parque Tecnológico Itaipu
Foz do Iguaçu, Paraná
<http://lattes.cnpq.br/5967941336003154>

Claudio Roberto Marquette Mauricio

Universidade Estadual do Oeste do Paraná
Foz do Iguaçu, Paraná
<http://lattes.cnpq.br/9614304238454186>

RESUMO: A energia elétrica é algo essencial para todas as áreas de produção. Sendo assim, a condição dos equipamentos é essencial para a distribuição de uma energia de qualidade. Contudo, as redes elétricas se estendem por quilômetros e ainda por trechos de difícil acesso, comprometendo encontrar equipamentos danificados. Neste artigo, apresenta-se uma solução de detecção e classificação de objetos das linhas de distribuição de energia utilizando Redes Neurais Convolucionais. A solução foi treinada para detectar e classificar quatro tipos

de objetos que fazem parte da rede elétrica. A rede neural artificial selecionada para detectar e classificar os objetos foi a YOLOv3. Para compor o banco de imagens de teste e treinamento, foi utilizado um drone e efetuadas coletas de imagens em 10 locais distintos. Após o treinamento, a Rede Neural Convolucional alcançou um IoU de 60,38%.

PALAVRAS-CHAVE: YOLOv3; Redes Neurais Convolucionais; Distribuição de energia.

APPLICATION OF CONVOLUTIONAL NEURAL NETWORKS IN ENERGY DISTRIBUTION LINES

ABSTRACT: Electric power is essential for all areas of production. Therefore, the condition of the power line distribution equipment is essential for energy quality. However, the power grids extend for miles and even stretches of difficult access, compromising the search for damaged equipment. This article presents a solution for detection and classification of objects in power distribution lines using Convolutional Neural Networks. The solution was trained to detect and classify four types of objects that are part of the power grid. YOLOv3 was the artificial neural network selected to detect and classify objects. To compose the test and training image bank, a drone was used, and image collections were made in 10 distinct locations. After the training, Convolutional Neural Networks achieved a IoU of 60.38%.

KEYWORDS: YOLOv3; Convolutional Neural Networks; Energy Distribution.

1 | INTRODUÇÃO

No Brasil, as redes de distribuição de energia elétrica são compostas por um complexo sistema de elementos que transportam a energia de onde é criada para onde será consumida. Essas redes intrincadas conectam geradores de eletricidade, linhas de transmissão, canais de distribuição e usuários finais (RIBEIRO, 2022).

As redes de transmissão, inicialmente, geram a energia e armazenam em geradores antes de ser entregue por cabos aéreos ligados a grandes torres metálicas. Como as redes elétricas são trifásicas, as torres de transmissão normalmente incluem três conjuntos de cabos. Esses cabos são acompanhados por um cabo mais alto, que fica posicionado no topo da torre, chamado de cabo para-raios (MATTEDE, 2022).

As redes de distribuição de energia abastecem consumidores industriais, comerciais e residenciais. No Brasil são mais de 140.000 km de linhas de transmissão (ONS, 2020). As redes de distribuição de energia são divididas em três categorias: linhas de alta, média e baixa tensão. As subestações de transformação, que incluem transformadores, equipamentos de proteção e controle, fazem parte das redes de distribuição de energia além das linhas de transmissão. Os componentes principais de uma subestação de distribuição são: o transformador, chaves, seccionadores, disjuntores e equipamentos de mediação e proteção contra raios ou curtos-circuitos (RIBEIRO, 2022).

Espera-se que estas linhas de transmissão estejam operantes e em bom estado de manutenção para garantir energia aos consumidores, porém a inspeção desses componentes é custosa devido a extensão das linhas de transmissão, pelo difícil acesso a certos trechos e pelos riscos de segurança. Desse modo é muito importante a investigação de novas abordagens explorando tecnologias que possam contribuir com o processo de inspeção, que facilite o acesso aos locais de forma segura.

Neste contexto, foi desenvolvido uma solução para inspeção dos componentes da rede elétrica de forma automatizada, utilizando drones e Rede Neural Convolutiva (CNN). A inspeção considera o modelo treinado para detecção e classificação de alguns componentes da rede elétrica. Os componentes considerados são: transformador, isolador, para-raios e chave fusível. As imagens são capturadas pelo drone e posteriormente é feita a análise das imagens adquiridas, considerando o modelo treinado. A seguir é descrito os detalhes do treinamento da rede CNN para a detecção e classificação dos quatro tipos de componentes presentes nas linhas de distribuição de energia.

2 | CONCEITOS GERAIS

a. Redes Neurais Artificiais

Rede Neural Artificial (RNA) expõe que a máquina tem a capacidade de aprender sem interferência externa e tem a habilidade de generalizar a informação aprendida (PEDRINI;

SCHWARTZ, 2008). Uma RNA pode ser comparada com o cérebro humano; direcionada no processamento de informações computacionais, ela busca simular a maneira que o cérebro realiza alguma tarefa, aprendendo através de exemplos. Esse processo é chamado de treinamento, onde os pesos sinápticos dos neurônios e a forma como se relaciona com o seu ambiente são ajustados de acordo com o algoritmo de aprendizagem.

Há duas maneiras básicas de aprendizado da RNA: aprendizado supervisionado e aprendizado não-supervisionado. No aprendizado supervisionado, o agente externo apresenta um conjunto de padrões de entrada e suas saídas de acordo com a entrada para RNA. Para cada entrada, o agente externo determina se a resposta calculada é boa ou ruim, então a resposta da RNA e a resposta esperada são comparadas, o erro é apontado e então a RNA ajusta os pesos para melhorar suas próximas respostas. Na aprendizagem não-supervisionada, não há agente externo, a RNA aprende através de padrões de exemplos apresentados na entrada (SOARES, 2019).

A forma mais simples de RNA é a *perceptron*. Ela possui uma única camada contendo uma unidade neural. As RNAs com várias camadas são chamadas de *multilayer perceptron*, de maneira que possuem uma camada de entrada, outra de saída e uma ou mais camadas ocultas (SOARES, 2019).

As redes *multilayer perceptron* possuem algumas variações como as Redes Neurais Convolucionais (CNN) (SOARES, 2019). Elas fazem parte do subconjunto de algoritmos baseados em *deep learning*. Os algoritmos de *deep learning* têm a capacidade de instanciar camadas para aprender um item de entrada em vários níveis de representação. Cada nível é responsável por converter o objeto de entrada em uma representação mais geral de si mesmo (MARQUES, 2019).

As CNNs se destacam por sua capacidade de generalização; sendo capaz de extrair automaticamente as características de objetos (MARQUES, 2019). Recentemente diferentes pesquisas demonstraram a capacidade das CNNs para detecção e classificação de objetos, como por exemplo, a CNN Faster R-CNN, a CNN SSD, RetinaNet, entre outras.

A CNN Faster R-CNN é baseada em propostas de região, onde utiliza-se duas CNN's multicamadas executadas em paralelo. A primeira é a Fast R-CNN, responsável pela extração de características das regiões da segunda CNN, chamada de Region Proposal Networks (RPN). A RPN gera as regiões de interesse que contém os possíveis objetos. Essas regiões de interesse são usadas para ajustar o posicionamento do bounding box no objeto e na última fase do modelo de detecção para classificação dos objetos (LIN et al., 2017).

A CNN Single-Shot MultiBox Detector (CNN SSD) possui uma arquitetura baseada em *Region Proposal Networks* (RPN), *anchor boxes* e representação multi-escala (MAZZETTO, 2019). A CNN SSD ajusta as previsões dos *feature maps* de variadas resoluções para trabalhar com objetos de diversos tamanhos. Ela gera um número x de *anchor boxes* de tamanhos diferentes, que formam um conjunto de *bounding boxes*, inicialmente para a

detecção de objetos. Durante o treinamento essas *bounding boxes* são ajustadas para estarem de acordo com a posição do objeto. No final, o algoritmo *Non-Maximum Supression* reduz as *boxes* para a detecção (MAZZETTO, 2019; SOARES, 2019).

A CNN RetinaNet (LIN et al., 2017) é outra rede de detecção. Esta rede possui um estágio que procura alcançar o desempenho das redes de dois estágios (Faster R-CNN), mantendo a complexidade computacional reduzida. Uma das dificuldades da CNN SSD, que também é de um estágio, está em lidar com a detecção densa de objetos, pois o processamento é feito em uma etapa só. Entretanto, a RetinaNet possui duas sub-redes convolucionais: uma para a classificação das detecções e a outra para a regressão das *bounding boxes* ligadas ao objeto reconhecido. A principal contribuição da CNN RetinaNet foi o desenvolvimento da função de Perda Focal, resolvendo o problema de desbalanceamento de classes (MARTINS, 2019).

b. Métricas de desempenho

Os algoritmos de detecção de objetos são avaliados através de seu desempenho em relação aos resultados de validação. As métricas utilizadas para a avaliação do desempenho da CNN são *Intersection over Union* (IoU) e *Mean Average Precision* (mAP).

Intersection over Union é uma métrica que define quanto a predição da localização de um objeto na imagem coincide com sua verdadeira localização (MARQUES, 2019). Essa métrica consiste basicamente em dividir a interseção pela união de dois *bounding boxes*. Quanto maior o valor do IoU, mais preciso é a seleção de um objeto na imagem, como apresentado na Figura 1.

O mAP é a média sobre o *Average Precision* (AP). O AP refere-se à capacidade de um modelo reconhecer apenas os objetos essenciais. É a porcentagem de previsões positivas que estão corretas. A média do AP calculada para todas as classes é usada para determinar o mAP para detecção de objetos (MARQUES, 2019).

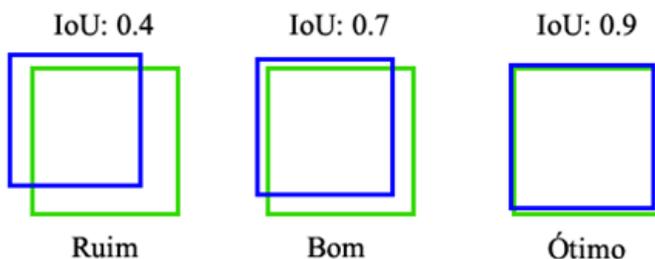


Fig. 1. Componentes escolhidos para a execução do projeto.

3 | TRABALHOS RELACIONADOS

Desde a geração até o uso de fato da energia, ocorre um trabalho complexo, que

vai desde a inspeção e a manutenção das redes de transmissão e distribuição de energia elétrica. A degradação dos componentes da rede de transmissão provém de ações de agentes ambientais como a temperatura, umidade, poluição e radiação ultravioleta, mas também pode provir de vandalismo, entre outros (RIBEIRO, 2017).

Na literatura, há vários estudos e métodos para a detecção de componentes em linhas de distribuição (FERREIRA et al., 2009; GODOI et al., 2005; SANTOS, 2017), sendo que alguns exploram técnicas de inteligência artificial e processamento digital de imagens, como também radiografias e tomografias. O trabalho apresentado em (GODOI et al., 2005), notabiliza uma maneira de detectar e classificar os defeitos de isoladores poliméricos através de processamento digital de imagens radiográficas. São realizados raios-x em isoladores poliméricos a fim de montar um *dataset* de imagens. Em seguida é realizado um pré-processamento nas imagens, onde a área de interesse é extraída, por fim classificados componente a componente no qual só então são usadas para treinamento de uma RNA.

A termografia infravermelha aplicada no sistema elétrico pode ser muito efetiva para prevenção de falhas e ausência de produção, o trabalho de (SANTOS, 2017), propõe o uso de algoritmos de RNAs para indicar possíveis falhas em transformadores, através das temperaturas marcadas nas imagens termográficas. A abordagem apresentada em (FERREIRA et al., 2009) tem o foco em manter a qualidade de energia nas redes de distribuição. O método proposto também utiliza processamento digital de imagens, como o pré-processamento e RNA para a classificação dos eventos, ou seja, ter o monitoramento em barras de subestações, através das oscilografias. Os algoritmos utilizados foram o *MultiLayer Perceptron* (MLP) e *Support Vector Machines* (SVM). A pesquisa de (RIBEIRO, 2017) utilizou a radiação ultravioleta e a termografia como parâmetros para determinar o estado da degradação de isoladores poliméricos, auxiliando na tomada de decisões para intervenção e manutenção do componente, utilizando processamento digital de imagens e RNA.

Publicações mais recentes utilizam drones para a inspeção automática, como o (TILAWAT; THEERA-UMPON; AUEPHANWIRIYAKUL, 2010) que sugeriram um método para reconhecer postes de energia em sequências aéreas de vídeo. Primeiro, um filtro bidimensional separável *Infinite Impulse Response* (IIR) e *Non-Maximum Supression* foram usados para recuperar pixels de linha reta. A transformada de *Hough* foi então usada para encontrar linhas retas. Finalmente, as linhas de energia descobertas foram usadas para detectar postes de energia. Sampedro et al. (SAMPEDRO et al., 2014) sugeriram um método de reconhecimento e classificação de torres elétricas para inspeção de linhas de transmissão baseado em características de HOG e redes neurais MLP.

Wang e Zhang (WANG; ZHANG, 2016) sugeriram um método para detectar isoladores a partir de fotos aéreas. Para supressão de fundo, uma técnica única baseada no limiar de Otsu e procedimentos morfológicos foi proposta. Em seguida, para categorizar os isoladores, um modelo de SVM foi treinado usando recursos coletados por filtros Gabor.

Liao e An (LIAO; AN, 2014) propuseram uma técnica robusta para encontrar isoladores em imagens aéreas. Para descobrir as características locais, uma abordagem aprimorada de seleção de *Harris corner* foi aplicada. Para representar feições locais, foi proposto um descritor *MultiScale and MultiFeature* (MSMF). Finalmente, Recursos de Ordens Espaciais (SOFs) foram descobertos para melhorar a robustez do algoritmo. Finalmente, a região dos isoladores foi determinada usando uma técnica de emparelhamento.

Os estudos apresentados trazem soluções com RNAs com diversas técnicas e aplicações. Este trabalho consiste em apresentar a detecção e classificação de componentes nas linhas de distribuição de energia elétrica utilizando algoritmos de CNN.

4 | MATERIAIS E MÉTODOS

Para criar o modelo capaz de detectar e classificar os componentes, foi utilizado a RNA YOLOv3 e o *framework* Darknet. O uso da YOLOv3 se deve por ela se destacar pela sua acurácia e velocidade para treinamento. A YOLOv3 foi proposta por Redmon e Farhadi (REDMON; FARHADI, 2018) em 2018. O algoritmo é baseado em Redes Neurais Convolucionais e se propõe a detectar objetos em imagens, em tempo real. Ela possui capacidade de generalização e sua arquitetura contém uma rede convolucional que prevê várias regiões da imagem ao mesmo tempo. Na camada de entrada, a imagem é subdividida em uma grade de tamanho $N \times N$, onde para cada célula da grade é predito um objeto. Para cada célula ela prediz um número limitado de *bounding boxes* entregando um valor de confiança relacionado a região identificada. A YOLOv3 (REDMON; FARHADI, 2018) possui 53 camadas convolucionais. Para melhorar a detecção de objetos pequenos, é realizado um conjunto de operações de convolução usando filtros 1×1 e 3×3 (SCALABRIN, 2019).

O Darknet é um *framework* de código aberto que permite ao pesquisador customizar parâmetros de acordo com sua capacidade de processamento (REDMON, [s.d.]). Ela não possui interface, porém sua utilização é simples. É possível visualizar o treinamento por iterações: a cada conjunto de imagens que entra na RNA, é exibido um conjunto de informações da RNA em relação a aquele conjunto. Além disso o Darknet permite uma subdivisão sobre o *batch*. Por exemplo, um *batch* de 64, são 64 imagens entrando ao mesmo tempo na RNA para extração de características comuns. O Darknet permite passar um parâmetro para dividir esse *batch* e assim diminuir o custo de processamento; ao final ele realiza uma operação para juntar as partes e retornar o valor total do *batch* inicial (REDMON, [s.d.]).

Para a execução do treinamento da rede e para realizar os testes de detecção e classificação dos componentes, foram coletadas imagens dos objetos em 10 locais diferentes da zona urbana de uma cidade. Foram obtidas ao todo 675 imagens contendo vários objetos de interesse em cada imagem, das quais 615 imagens foram utilizadas para o treinamento e testes e 50 imagens para a validação da CNN. Foram escolhidos quatro

tipos de objetos para detectar e classificar: isolador, chave fusível, transformador e para-raio. A escolha se deve pelo número de componentes no *dataset* serem relevantes para o treinamento. Conforme a limitação do *dataset*, alguns objetos não foram inseridos para treinamento. A figura 1 mostra um exemplo de cada objeto, porém há outros modelos e cores dos objetos inseridos no *dataset*.

A ferramenta Bbox-Label-Tool (S. QIU, 2017) é utilizada para gerar os rótulos de cada objeto demarcado, esse processo é essencial para tarefas de aprendizado preditivas. A CNN YOLO permite realizar mudanças em seus parâmetros, os principais parâmetros alterados são: *Batch* define o número de imagens no lote que será aplicado a normalização; *Subdivisions* permite dividir o valor do *Batch* para reduzir o número de imagens no lote; *Width* e *Height*, são usados para definir a dimensão das imagens de treinamento; *Filters* corresponde ao filtro da última camada de convolução; esse valor é calculado pela fórmula: $(classes+5) * 3$; por fim o parâmetro *Random* se alterado para 1, redimensiona as imagens a cada 10 iterações (SANTOS, 2018).

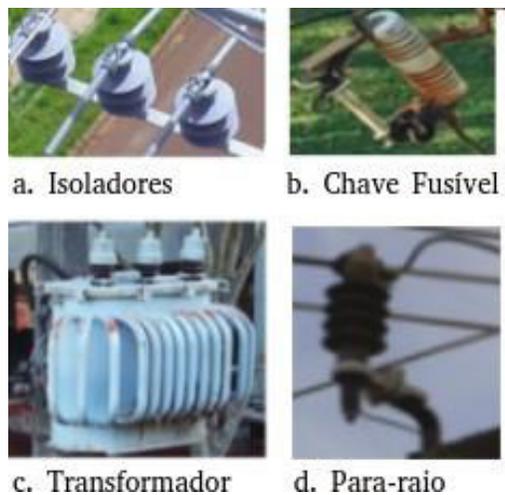


Fig. 2. Componentes escolhidos para a execução do projeto.

5 | RESULTADOS E DISCUSSÃO

A primeira etapa do processo de detecção e classificação da CNN é o pré treinamento, na qual a ferramenta BBox-Label-Tool foi usada para demarcar os objetos em suas respectivas classes, gerando as anotações necessárias. Essa etapa engloba todo o processo anterior ao treinamento. Posteriormente, as 615 imagens foram divididas em 75% para o treinamento e 25% para testes. Essa divisão foi feita de forma aleatória, o que pode ter interferido significativamente nos resultados, uma vez que a quantidade de cada componente ficou desproporcional, gerando um desbalanceamento de classes. A Tabela 1 apresenta o número dos componentes na fase de treinamento, testes e validação.

Classes	Treino	Teste	Validação
Transformador	170	150	21
Isolador	1364	288	152
Chave Fusível	549	172	56
Para-raio	424	214	37

TABELA I - NÚMERO DE COMPONENTES DAS FASES DE TREINAMENTO, TESTE E VALIDAÇÃO.

Para o treinamento, foram utilizados os pesos sinápticos já pré-treinados, sendo o modelo *darknet53*, como também foram realizados 2 treinamentos. A Tabela 2 apresenta os parâmetros do *darknet53* que foram alterados com o objetivo de melhorar a detecção e classificação da CNN.

	Treinamento 1	Treinamento 2
<i>Batch</i>	64	32
<i>Subdivisions</i>	16	8
<i>Width</i>	416	416
<i>Height</i>	416	416
<i>Filters</i>	36	36
<i>Random</i>	0	1

TABELA II - PARÂMETROS DOS 2 TREINAMENTOS REALIZADOS.

Classes	AP T1	AP V1	AP T2	AP V2
Transformador	80,22%	62,5%	74,87%	73,06%
Isolador	27,45%	32,66%	29,49%	38,12%
Chave Fusível	34,0%	18,02%	31,73%	20,85%
Para-raio	11,29%	8,71%	13,22%	3,6%

TABELA III - RESULTADOS OBTIDOS COM O PRIMEIRO E SEGUNDO TREINAMENTO.

O primeiro treinamento resultou em um mAP de 17,41% e média do IoU de 51,99%. Com o objetivo de melhorar os resultados, realizou-se um segundo treinamento, o valor resultante do mAP foi de 34% e média do IoU de 60,38%. Observa-se que o segundo treinamento atingiu o seu objetivo. Todas as métricas são apresentadas pelo próprio Darknet, com um comando é possível ter em mãos diferentes resultados calculados por suas respectivas métricas.

A Tabela III mostra a precisão média (AP) de cada classe para os dois treinamentos. As colunas “AP T1” e “AP V1” apresentam a AP obtida no teste e na validação do primeiro

treinamento e as colunas “AP T2” e “AP V2” a AP obtida no teste e na validação do segundo treinamento. A Figura 3 e a Figura 4 mostram os resultados obtidos. Pode-se observar que os *bounding boxes* coincidem aproximadamente com sua verdadeira localização.

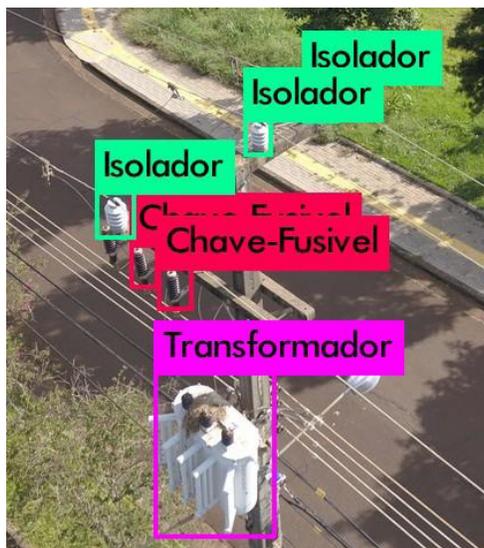


Fig. 3 Exemplo de imagem do segundo treinamento

Na Figura 3 a CNN detecta o transformador e os três isoladores com uma confiança de 100%, mas a CNN classifica o objeto para-raio como chave fusível. Na Figura 4, o componente para- raio é detectado duas vezes, entretanto o componente mais distante do transformador é uma chave-fusível. Este erro em ambos os treinamentos é conhecido como falso positivo. Vários fatores podem ter influenciado o mAP resultante, como a distância usada para obter as imagens, que pode ter dificultado o aprendizado da CNN; os diferentes modelos dos componentes; os parâmetros utilizados para o treinamento e/ou a divisão das imagens para treinamento e teste. Ou seja, vários fatores podem ter influenciado o resultado.

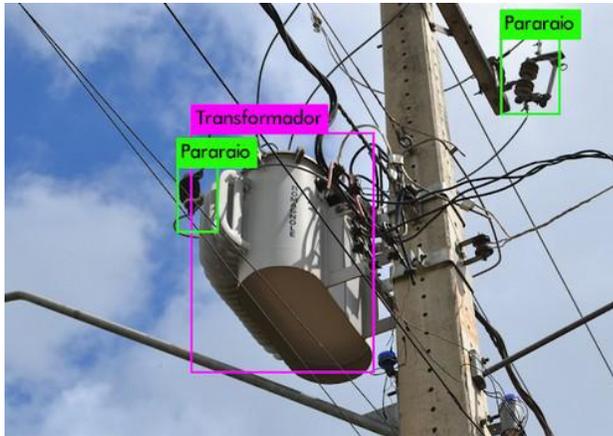


Fig. 4. Outro resultado visual do segundo treinamento.

É importante ressaltar que os dois treinamentos foram realizados com o mesmo número de imagens, pelo fato de não terem sido realizadas mais coletas de imagens, no entanto o ideal seria aumentar o número de imagens a cada treinamento. E por fim, na Figura 5 a CNN detecta o transformador com uma confiança de 82% e 99% os isoladores. No entanto, as chaves-fusível e os para-raios não são identificados pela CNN. Isso pode ocorrer, pois a imagem está em um ângulo mais distante, tornando a detecção mais difícil para a CNN.

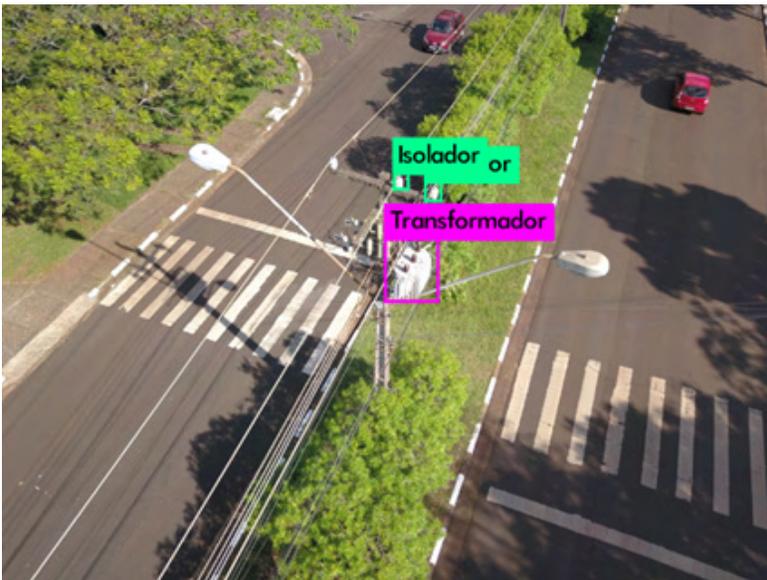


Fig. 5. Imagem de um ângulo mais distante no segundo treinamento.

6 | CONCLUSÕES

Conforme os resultados da validação e testes mostrados, a classe transformador é o componente com maior número de detecções pela CNN YOLOv3. Analisando o número de componentes, a classe transformador é o objeto com menor número de componentes para o treinamento, mas pelo fato de o objeto ser maior, a CNN tem mais facilidade de reconhecer. Os demais componentes são objetos menores, dificultando o aprendizado da CNN.(ONS, 2020)

Importante ressaltar que a YOLOv3 melhorou em relação a detecção de objetos pequenos, mas ainda é um desafio para CNNs de um estágio. A diferença da precisão média entre a classe transformador e a classe isolador (segunda classe mais detectada, segundo AP) é muito alta, diferença de 35%.

Um dos fatores importantes de serem citados que interferem na detecção e classificação dos componentes são o modelo, a cor e o ângulo variados nas imagens. Por exemplo, no banco de imagens contém figuras com diferentes modelos de isolador, sendo poliméricos, de vidro ou porcelana. Da mesma forma, acontece com os demais componentes das linhas de distribuição de energia.

Comumente, se o IoU é considerado maior que 0,5, então a predição é considerada verdadeira. Dessa maneira, o valor resultante do IoU é satisfatório. Acredita-se que a ampliação do *dataset* pode influenciar positivamente nos próximos treinamentos realizados com a CNN.

Os próximos passos deste trabalho, serão melhorar a CNN de acordo com o conhecimento e experiência que foram adquiridos e classificar os componentes como regulares ou com defeitos. Para isso o *dataset* será ampliado e será aplicado novos métodos de detecção de objetos nas imagens.

AGRADECIMENTOS

Os autores agradecem a Fundação Parque Tecnológico Itaipu (FPTI), Centro Internacional de Hidroinformática (CIH) por propor e financiar o projeto; ao Centro Latino Americano de Tecnologias Abertas (CELTA) pela disponibilização de material e conhecimento; também agradecemos à Itaipu pelo incentivo ao projeto.

REFERÊNCIAS

FERREIRA, V. et al. **Classificação de eventos em redes de distribuição de energia utilizando transformada wavelet e modelos neurais autônomo**. IX Congresso Brasileiro de Redes Neurais/ Inteligência Computacional. **Anais**. 2009.

GODOI, W. C. et al. Detecção de defeitos em isoladores poliméricos por meio da radiografia digital e reconhecimento de padrões. **Espaço Energia**, v. 1, n. 2, p. 5–11, 2005.

LIAO, S.; AN, J. A robust insulator detection algorithm based on local features and spatial orders for aerial images. **IEEE Geoscience and Remote Sensing Letters**, v. 12, n. 5, p. 963–967, 2014.

LIN, T.-Y. et al. **Focal loss for dense object detection**. Proceedings of the IEEE international conference on computer vision. **Anais**. 2017.

MARQUES, B. H. P. **Avaliação de algoritmos baseados em deep learning para localizar placas veiculares brasileiras em ambientes complexos**. Pernambuco, 2019. Disponível em: <<http://hdl.handle.net/123456789/8333>>. Acesso em: 11 abr. 2022.

MARTINS, R. A. P. **Aplicação de redes convolucionais profundas para detecção de massas em mamografias**. Monografia—Florianópolis: UFSC, 2019.

MATTEDE, H. **Redes de energia elétrica, tipos e características**.

MAZZETTO, M. **Detecção e classificação de múltiplos componentes em linha de montagem automotiva usando deep learning**. Dissertação—Pato Branco: UTFPR, 2019.

ONS. **Resultados da operação histórico da operação: Extensão das linhas de transmissão**.

PEDRINI, H.; SCHWARTZ, W. R. **Análise de imagens digitais: princípios, algoritmos e aplicações**. [s.l.] Cengage Learning, 2008.

REDMON, J.; FARHADI, A. **Yolov3: An incremental improvement**. Acesso em: 11 abr. 2022.

REDMON, J. **Darknet: Open source neural networks in c**. Disponível em: <<https://pjreddie.com/darknet/>>. Acesso em: 11 abr. 2022.

RIBEIRO, A. **Redes de distribuição de energia elétrica no Brasil**.

RIBEIRO, G. L. **Aprimoramento da classificação de isoladores poliméricos por medições termográficas e radiação UV usando processamento de imagens e RNA**. dissertação—Campina: UFCG, 2017.

S. QIU. **BBox-Label-Tool**.

SAMPEDRO, C. et al. **A supervised approach to electric tower detection and classification for power line inspection**. 2014 International Joint Conference on Neural Networks (IJCNN). **Anais**. 2014.

SANTOS, G. M. DOS. **Termografia e inteligência artificial na detecção de falhas em transformadores**. dissertação—Recife: UFPE, 2017.

SANTOS, V. N. DOS. **Reconhecimento de objetos em uma cena utilizando redes neurais convolucionais**. {B.S.} thesis—[s.l.] Universidade Tecnológica Federal do Paraná, 2018.

SCALABRIN, M. H. **Aplicação de redes neurais artificiais profundas na detecção de placas de pare**. Monografia—Francisco Beltrão: UTFPR, 2019.

SOARES, I. M. **Uma abordagem bottom-up completa para reconhecimento de atividades humanas em imagens através da pose estimada com redes convolucionais**. Goiânia: UFG, 2019.

TILAWAT, J.; THEERA-UMPON, N.; AUEPHANWIRIYAKUL, S. **Automatic detection of electricity pylons in aerial video sequences**. (IEEE, Ed.)2010 International Conference on Electronics and Information Engineering. **Anais**. 2010.

WANG, X.; ZHANG, Y. **Insulator identification from aerial images using support vector machine with background suppression**. International Conference on Unmanned Aircraft Systems (ICUAS). **Anais**. 2016.

ÍNDICE REMISSIVO

A

Administração 11, 156, 157, 160, 163, 164, 165, 166, 167

Água 65, 70, 71, 75, 76, 81, 82, 87, 91

Aprendizagem 4, 11, 14, 42, 44, 45, 48, 50, 51, 53, 54, 55, 56, 58, 59, 60, 61, 65, 66, 67, 68, 69, 87, 121, 132

B

Brasil 17, 18, 19, 20, 21, 22, 26, 27, 28, 29, 30, 31, 32, 35, 37, 38, 57, 68, 71, 86, 87, 116, 118, 120, 130, 133, 135, 136, 142, 153, 157, 158, 162, 165, 166

C

Catadores 132, 133, 134, 135, 136, 137, 139, 141, 142

Centrífugas 88, 90, 91, 99, 100

Ciência 16, 20, 28, 40, 56, 60, 61, 62, 87

Clima organizacional 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14

Colaboradores 2, 3, 6, 9, 10, 11, 12, 158

Coleta seletiva 132, 133, 134, 135, 136, 138, 141, 142, 143

Conhecimento 29, 35, 37, 43, 44, 45, 46, 48, 49, 52, 53, 55, 58, 60, 62, 63, 64, 65, 66, 67, 69, 129, 132, 157, 158, 160, 161, 162, 163

Consultoria 160, 161, 164, 165

Cultura popular 16, 17, 18, 19, 20, 21, 22, 23, 24, 25, 26

E

Educação 1, 8, 12, 15, 16, 17, 19, 20, 21, 22, 23, 25, 26, 27, 28, 29, 30, 31, 32, 33, 34, 35, 36, 37, 38, 39, 49, 55, 56, 57, 58, 61, 68, 69, 132, 134, 138, 142, 143, 163, 164, 167

Empresas 2, 5, 7, 12, 116, 155, 156, 157, 158, 159, 160, 161, 162, 163, 164, 165, 166, 167

Energia 13, 71, 110, 111, 113, 116, 119, 120, 122, 123, 124, 129, 130

Ensino 11, 13, 14, 15, 16, 19, 20, 28, 35, 36, 38, 40, 41, 42, 43, 44, 45, 47, 48, 50, 52, 53, 55, 56, 58, 59, 60, 61, 62, 64, 65, 66, 67, 68, 69, 116, 134, 136, 139, 142

Escola 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 23, 28, 30, 31, 33, 36, 38, 45, 46, 47, 49, 52, 55, 56, 68, 167

Estresse 144, 145, 146, 153

F

Fabricação 86, 102, 103, 104, 105, 106, 107, 108, 111, 112, 113, 115, 116, 117, 118

Ferramenta 2, 12, 41, 44, 55, 113, 125

Finanças 155, 157, 164

G

Gestão 1, 2, 3, 4, 5, 6, 8, 9, 10, 11, 12, 13, 14, 15, 116, 117, 155, 156, 157, 158, 159, 160, 161, 162, 163, 164, 165, 166, 167

I

Impressão 3D 105, 116

Inovação 13, 102, 158, 159, 162, 167

Instituição 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 14, 147, 154

L

Liquidez 155, 160, 164

Lixo 133, 134, 136, 138, 141, 143

M

Material reciclado 132, 137, 142

Meio ambiente 133, 134, 140, 141, 142, 143, 146

Mercado 7, 10, 26, 104, 116, 118, 135, 155, 156, 157, 158, 159, 160, 162, 163, 164

Metal 102, 105, 110, 111, 112, 114, 116, 117, 118

Mulheres 23, 25, 27, 28, 29, 30, 31, 32, 33, 34, 35, 36, 37, 38, 39, 150

N

Negócio 30, 36, 157, 159, 160

Nísia Floresta 27, 28, 29, 30, 31, 37, 38, 39

O

Organização 2, 3, 5, 6, 7, 8, 10, 11, 12, 17, 19, 20, 21, 45, 52, 55, 69, 139, 145, 150, 158, 160, 161

P

Paulo Freire 16, 17, 18, 20, 22, 23, 24, 25, 26

Planejamento 2, 14, 15, 54, 65, 143, 145, 155, 156, 160, 161, 162, 163, 164

Programação 40, 41, 42, 43, 44, 45, 46, 47, 48, 52, 53, 54, 55, 56

Prototipagem 102, 104, 109, 118

Q

Química 58, 59, 60, 62, 64, 65, 66, 67, 68, 69, 106, 107

R

Random survival forests 88, 89, 99, 101

Recursos humanos 2, 3, 8, 14, 145

Redes neurais 119, 120, 121, 123, 124, 129, 130

Robótica 40, 41, 42, 43, 44, 45, 46, 47, 48, 52, 53, 54, 55, 56

S

Saúde 20, 22, 142, 144, 145, 146, 147, 149, 150, 151, 152, 153, 154

Semiótica 58, 61, 62, 63, 64, 66, 67, 68, 69

Sensibilização 132, 140, 141

Sensoriamento hídrico 70

Signo 58, 63, 64, 65, 66

Síndrome de Burnout 144, 146, 147, 149, 152, 153, 154

Sistema educacional 16, 20, 31

Solo 70, 71, 72, 73, 74, 75, 77, 78, 79, 80, 81, 82, 83, 84, 85, 86, 87

Solubilidade 58, 59, 60, 64, 65, 66, 67, 68

T

Tecnologia 4, 16, 40, 50, 56, 102, 105, 109, 110, 111, 113, 114, 116, 117, 165, 167

Trabalhador 144, 145, 152

U

Umidade 70, 71, 72, 73, 74, 75, 76, 77, 80, 81, 82, 83, 84, 85, 86, 87, 123

UTI 144, 145, 146, 148, 149, 150, 151, 152

V

Valores 3, 4, 5, 7, 8, 10, 11, 19, 21, 23, 24, 73, 75, 76, 77, 79, 80, 81, 82, 83, 84, 85, 86, 92, 94, 97, 98, 134, 148, 154

Y

YOLOv3 119, 124, 129, 130

Políticas públicas

para ciência, tecnologia e inovação 2

 www.atenaeditora.com.br

 contato@atenaeditora.com.br

 @atenaeditora

 www.facebook.com/atenaeditora.com.br



Políticas públicas

para ciência, tecnologia e inovação 2

-  www.atenaeditora.com.br
-  contato@atenaeditora.com.br
-  [@atenaeditora](https://www.instagram.com/atenaeditora)
-  www.facebook.com/atenaeditora.com.br

