

# VISÃO ROBÓTICA NA CONSTRUÇÃO CIVIL: EFICIÊNCIA, PRECISÃO E PRODUTIVIDADE COM SEGURANÇA APRIMORADA

*Data de aceite: 02/05/2024*

### **Márcio Mendonça**

Universidade Tecnológica Federal do  
Paraná  
PPGEM-CP - Programa de Pós-  
Graduação em Engenharia Mecânica PP/  
CP  
Cornélio Procópio - PR  
<http://lattes.cnpq.br/5415046018018708>

### **Fabio Rodrigo Milanez**

UniSENAI PR Campus Londrina  
Londrina-PR  
<http://lattes.cnpq.br/3808981195212391>

### **Francisco de Assis Scannavino Junior**

Universidade Tecnológica Federal do  
Paraná Departamento Acadêmico de  
Engenharia Elétrica (DAELE) – Cornélio  
Procópio - Pr  
<http://lattes.cnpq.br/4513330681918118>

### **Marcio Jacometti**

Universidade Tecnológica Federal do  
Paraná  
Departamento acadêmico das ciências  
humanas e sociais aplicadas (DACHS)  
Cornélio Procópio – PR  
<http://lattes.cnpq.br/8509336134084374>

### **Iago Maran Machado**

Universidade Tecnológica Federal do  
Paraná  
Mestrando - PPGEM-CP - Programa de  
Pós-Graduação em Engenharia Mecânica  
PP/CP  
Cornélio Procópio - PR  
<http://lattes.cnpq.br/4733940365047328>

### **Henrique Franciz Ximenes de Andrade Bilbao**

Universidade Tecnológica Federal do  
Paraná  
Campo Mourão-PR  
<https://www.linkedin.com/in/henrique-ximenes-14512b113/>

### **Henrique Cavalieri Agonilha**

Graduando na Universidade Filadélfia  
(Unifil)  
Londrina - PR  
<http://lattes.cnpq.br/9845468923141329>

### **Rodrigo Rodrigues Sumar**

Universidade Tecnológica Federal do  
Paraná,  
Departamento Acadêmico de Engenharia  
Elétrica (DAELE)  
Cornélio Procópio – PR  
<http://lattes.cnpq.br/1461760661483683>

**Marcos Banheti Rabello Vallim**

Universidade Tecnológica Federal do Paraná,  
Departamento Acadêmico de Engenharia Elétrica (DAELE)  
Cornélio Procópio – PR  
<http://lattes.cnpq.br/2326190172340055>

**Wesley Candido da Silva**

UniSENAI PR Campus Londrina  
Londrina-PR  
<http://lattes.cnpq.br/6740629293449940>

**Emerson Ravazzi Pires da Silva**

Universidade Tecnológica Federal do Paraná Departamento Acadêmico de Engenharia  
Elétrica (DAELE)  
Cornélio Procópio - Pr  
<http://lattes.cnpq.br/3845751794448092>

**Gustavo Henrique Bazan**

Instituto Federal do Paraná, Campus Jacarezinho  
Jacarezinho - PR  
<http://lattes.cnpq.br/7076940949764767>

**Gabriel Henrique Oliveira Uliam**

Egresso Universidade Tecnológica Federal do Paraná Departamento Acadêmico de  
Engenharia Elétrica (DAELE)  
Cornélio Procópio - Pr  
<http://lattes.cnpq.br/9917773125320806>

**André Luiz Salvat Moscato**

Instituto Federal do Paraná, Campus Jacarezinho  
Jacarezinho - PR  
<http://lattes.cnpq.br/1744149363927228>

**João Maurício Hypólito**

Centro Paula Souza  
Departamento Computação-FATEC  
<http://lattes.cnpq.br/5499911577564060>

**Wagner Fontes Godoy**

Universidade Tecnológica Federal do Paraná Departamento Acadêmico de Engenharia  
Elétrica (DAELE)  
Cornélio Procópio - Pr  
<http://lattes.cnpq.br/7337482631688459>

**RESUMO:** A visão robótica na construção civil representa uma abordagem inovadora que visa melhorar a eficiência, precisão e produtividade dos processos construtivos, ao mesmo tempo em que aprimora a segurança dos trabalhadores. Por meio da utilização de tecnologias avançadas, como câmeras, sensores e algoritmos de processamento de imagem, os robôs são capazes de realizar tarefas complexas de forma autônoma e precisa. Isso não apenas acelera os projetos de construção, mas também reduz erros e riscos associados à intervenção humana. O resultado é um ambiente de trabalho mais seguro e eficiente, onde a tecnologia desempenha um papel fundamental na transformação do setor da construção civil. Este artigo se encerra com uma conclusão das inferências obtidas e sugere futuros trabalhos

**PALAVRAS-CHAVE:** Visão Robótica, Construção Civil, Tecnologia na Segurança

## ROBOTIC VISION IN CIVIL CONSTRUCTION: EFFICIENCY, PRECISION, AND PRODUCTIVITY WITH ENHANCED SAFETY

**ABSTRACT:** Robotic vision in civil construction represents an innovative approach aimed at improving the efficiency, precision, and productivity of construction processes while enhancing worker safety. By utilizing advanced technologies such as cameras, sensors, and image processing algorithms, robots are capable of autonomously and accurately performing complex tasks. This not only accelerates construction projects but also reduces errors and risks associated with human intervention. The result is a safer and more efficient working environment where technology plays a fundamental role in transforming the construction industry. This article concludes with a summary of the inferences obtained and suggests future work.

**KEYWORDS:** Robotic Vision; Civil Construction; Data Analysis, Enhanced Safety

## INTRODUÇÃO

A integração da visão robótica na construção civil representa uma abordagem inovadora e transformadora, com o objetivo de aprimorar a eficiência, precisão e produtividade dos processos de construção, ao mesmo tempo em que eleva os padrões de segurança dos trabalhadores. Através da incorporação de tecnologias de ponta, como câmeras, sensores e algoritmos de processamento de imagem, os robôs demonstram a capacidade de executar tarefas complexas de forma autônoma e precisa. Essa abordagem não apenas acelera os projetos de construção, mas também reduz os erros e os riscos associados à intervenção humana, promovendo assim um ambiente de trabalho mais seguro e eficiente. Conseqüentemente, essa mudança de paradigma destaca o papel fundamental da tecnologia na remodelação da indústria da construção civil, alinhando-a com as demandas e desafios do século XXI.

Visão robótica é uma área da robótica e da inteligência artificial que se concentra no desenvolvimento de sistemas que permitem aos robôs “ver” e interpretar o ambiente ao seu redor. A visão robótica envolve a utilização de câmeras e sensores para capturar imagens e informações visuais, e em seguida, processar essas informações para tomar decisões ou realizar tarefas específicas (SILVA, SANTOS e OLIVEVEIRA, 2023).

Existem várias aplicações para a visão robótica em diversos campos, incluindo:

**Manufatura automatizada:** Em linhas de produção, os sistemas de visão robótica são usados para inspecionar peças, orientar robôs em tarefas de montagem e garantir a qualidade dos produtos.

**Navegação autônoma:** Em robótica móvel, como carros autônomos e drones, a visão robótica é essencial para identificar obstáculos, reconhecer sinais de trânsito e mapear o ambiente.

**Robótica de serviço:** Robôs de serviço, como os usados em hospitais e hotéis, podem utilizar a visão robótica para interagir com pessoas, reconhecer rostos e objetos, e realizar tarefas como entrega de itens.

**Agricultura de precisão:** Em aplicações agrícolas, a visão robótica pode ser usada para monitorar o crescimento das plantas, detectar pragas e doenças, e otimizar a aplicação de pesticidas e fertilizantes, segundo Scaria, Aziz e Siddiqi (2019).

**Medicina e saúde:** Na área médica, a visão robótica é usada em cirurgias assistidas por robô, diagnóstico por imagem e monitoramento de pacientes Marie (2021).

Para alcançar essas aplicações, os sistemas de visão robótica dependem de algoritmos avançados de processamento de imagem e aprendizado de máquina para interpretar e extrair informações úteis das imagens capturadas. Isso inclui técnicas como reconhecimento de padrões, segmentação de imagens, detecção de objetos e reconhecimento facial.

À medida que a tecnologia continua a evoluir, a visão robótica desempenhará um papel cada vez mais importante na automação de uma ampla gama de tarefas e na criação de robôs mais capazes e autônomos.

De um modo geral somente o reconhecimento de capacetes, um dos principais, senão o principal E.P.I. (Equipamentos de Proteção Individual) na construção civil pode promover inúmeras vantagens como:

O reconhecimento de capacetes por visão computacional oferece diversas vantagens em comparação aos métodos tradicionais de monitoramento de segurança, como:

## **Maior eficiência e precisão**

A visão computacional automatiza o processo de detecção e reconhecimento de capacetes, eliminando a necessidade de inspeção manual, que pode ser demorada, trabalhosa e propensa a erros humanos.

A tecnologia é capaz de analisar imagens em tempo real, permitindo a identificação instantânea de trabalhadores sem capacete, possibilitando uma resposta rápida e direcionada.

A precisão da detecção é significativamente alta, com sistemas modernos atingindo taxas de acerto acima de 95%, minimizando o risco de falsos positivos e negativos.

## Melhoria da segurança no trabalho

A detecção e o alerta em tempo real de trabalhadores sem capacete permitem que medidas corretivas sejam tomadas instantaneamente, reduzindo o risco de acidentes e lesões.

A tecnologia contribui para a criação de um ambiente de trabalho mais seguro e consciente, promovendo a cultura de prevenção de acidentes.

O uso da visão computacional pode auxiliar na investigação de acidentes, fornecendo imagens e dados precisos sobre o evento.

## Redução de custos

A automação do processo de monitoramento de *E.P.I* (Equipamento de Proteção Individual) por meio da visão computacional gera economia de tempo e recursos humanos.

A diminuição do número de acidentes de trabalho também contribui para a redução de custos com indenizações, tratamento médico e outros.

A tecnologia pode ser utilizada em diversos ambientes de trabalho, como canteiros de obras, fábricas, minas e outros locais com alto risco de acidentes.

## Maior escalabilidade

A visão computacional é uma solução escalável que pode ser facilmente implementada em diferentes ambientes de trabalho, independentemente do tamanho ou da complexidade da operação.

O sistema pode ser adaptado às necessidades específicas de cada empresa, permitindo a personalização das regras de detecção e dos alertas.

A tecnologia é facilmente integrada a outros sistemas de segurança existentes, como sistemas de monitoramento por câmeras e sistemas de controle de acesso.

## Flexibilidade e adaptabilidade

A visão computacional oferece flexibilidade para diferentes tipos de capacetes, incluindo capacetes de segurança industrial, capacetes de ciclismo, capacetes de motociclistas e outros.

O sistema pode ser ajustado para diferentes condições de iluminação e ambientes de trabalho, garantindo a precisão da detecção em qualquer situação.

A tecnologia é constantemente aprimorada com o desenvolvimento de novos algoritmos e técnicas de inteligência artificial, tornando-a cada vez mais eficiente e precisa.

## Integração com outros sistemas

O reconhecimento de capacetes por visão computacional pode ser integrado a outros sistemas de segurança, como sistemas de controle de acesso, sistemas de monitoramento de câmeras e sistemas de gestão de *E.P.I.*

Essa integração permite a criação de um sistema de segurança completo e abrangente que garante a proteção dos trabalhadores em todos os momentos.

A integração com outros sistemas também facilita a análise de dados e a geração de relatórios sobre a segurança no trabalho.

## Geração de dados e insights

A visão computacional gera dados valiosos sobre o uso de E.P.I pelos trabalhadores, como frequência de uso, tipos de capacetes utilizados e áreas de maior risco.

Esses dados podem ser utilizados para identificar áreas de melhoria na segurança no trabalho, direcionar ações de conscientização e treinamento, e avaliar a efetividade das medidas de segurança implementadas.

A geração de dados e *insights* também contribui para a tomada de decisões mais inteligentes e estratégicas em relação à segurança no trabalho.

Em resumo, o reconhecimento de capacetes por visão computacional é uma tecnologia inovadora oferece diversas vantagens para a segurança no trabalho, como maior eficiência e precisão, redução de custos, maior escalabilidade, flexibilidade e adaptabilidade, integração com outros sistemas e geração de dados e *insights*. A motivação desse trabalho está na possibilidade de redução de acidentes na indústria da construção civil que em 2020 **No Brasil:**

- **2020:**
  - **Total de acidentes:** 717.533
  - **Óbitos:** 1.770
  - **Taxa de mortalidade:** 2,47 por 100 mil trabalhadores
  - **Participação da construção civil:** 22% dos acidentes e 23% dos óbitos
  - **Fonte:** Anuário Estatístico de Acidentes de Trabalho (Ministério do Trabalho e Previdência)
  
- **2022:**
  - **Total de acidentes:** 577.470
  - **Óbitos:** 1.419
  - **Taxa de mortalidade:** 2,46 por 100 mil trabalhadores
  - **Participação da construção civil:** 19% dos acidentes e 20% dos óbitos
  - **Fonte:** Observatório Digital de Saúde e Segurança do Trabalho (Ministério do Trabalho e Previdência)

## MATERIAIS E MÉTODOS

A tecnologia é uma ferramenta poderosa que pode auxiliar empresas na criação de um ambiente de trabalho mais seguro e consciente, promovendo a cultura de prevenção de acidentes e protegendo a saúde e o bem-estar dos trabalhadores.

Um exemplo correlato para reconhecimento facial foi utilizado recentemente na época da pandemia, neste caso

### Reconhecimento Facial com Máscaras na Pandemia de COVID-19

O uso de máscaras durante a pandemia de COVID-19 representou um desafio para o reconhecimento facial, uma tecnologia que se baseia em características faciais para identificar pessoas. As máscaras cobrem parte do rosto, ocultando características importantes para o reconhecimento, como nariz e boca.

#### Impacto da Pandemia no Reconhecimento Facial:

**Redução da Precisão:** Estudos indicam que a precisão do reconhecimento facial pode cair drasticamente com o uso de máscaras, chegando a 50% de taxa de erro em alguns casos.

**Desafios Tecnológicos:** Desenvolver algoritmos que reconheçam rostos com máscaras é um desafio para os pesquisadores. Soluções como análise da área dos olhos e da textura da pele estão sendo exploradas.

**Preocupações com Privacidade:** A coleta e o armazenamento de dados biométricos, como imagens faciais, levantam preocupações com a privacidade e o potencial para uso indevido.

**Tecnologias Multimodais:** A integração do reconhecimento facial com outras tecnologias, como reconhecimento de íris ou voz, pode aumentar a segurança e a confiabilidade da identificação.

**Sensores Térmicos:** A medição da temperatura corporal pode ser utilizada como medida de triagem em conjunto com o reconhecimento facial.

**Máscaras com Reconhecimento Facial:** Empresas estão desenvolvendo máscaras que incluem aberturas para os olhos ou tecnologias que permitem a identificação mesmo com a máscara.

O reconhecimento facial com máscaras ainda está em desenvolvimento, e sua implementação exige atenção à segurança, à privacidade e à ética.

A escolha da tecnologia deve ser feita com base nas necessidades específicas de cada aplicação.

É importante buscar soluções que sejam confiáveis, seguras e que protejam a privacidade dos indivíduos.

## Deep Learning Convolutacional (YOLO)

A *Deep Learning Convolutacional*, ou CNN (*Convolutional Neural Network*), é uma classe especial de redes neurais profundas projetadas especificamente para lidar com dados de alta dimensionalidade, como imagens. As CNNs têm sido extremamente bem-sucedidas em tarefas de visão computacional, incluindo reconhecimento de objetos, classificação de imagens, detecção de objetos e segmentação semântica. Ressalta-se que não é escopo desse artigo discorrer sobre maiores detalhes computacionais e matemáticos, e sim a aplicação delas.

A principal característica das CNNs é a aplicação de operações de convolução nas camadas de entrada da rede. Essas operações de convolução consistem em aplicar um conjunto de filtros ou kernels a uma janela deslizante sobre a imagem de entrada. Cada filtro captura padrões específicos da imagem, como bordas, texturas ou características mais complexas.

Aqui estão alguns conceitos-chave relacionados à CNN:

**Camadas convolucionais:** As camadas convolucionais aplicam operações de convolução aos dados de entrada. Cada camada possui vários filtros, e a saída de cada filtro é chamada de mapa de características.

**Camadas de *pooling*:** Após as camadas convolucionais, geralmente são aplicadas camadas de *pooling* para reduzir a dimensionalidade dos mapas de características, preservando as informações mais importantes. O *pooling* mais comum é o *max-pooling*, que extrai o valor máximo de uma região da imagem.

**Camadas totalmente conectadas:** Depois de várias camadas convolucionais e de *pooling*, os mapas de características resultantes são achatados e passados para camadas totalmente conectadas, que são semelhantes às camadas em redes neurais tradicionais.

**Funções de ativação:** As funções de ativação, como ReLU (*Rectified Linear Unit*), são aplicadas após as operações de convolução e *pooling* para introduzir não linearidades na rede, permitindo que ela aprenda relações mais complexas nos dados.

**Aprendizado de características:** Uma das vantagens das CNNs é sua capacidade de aprender características diretamente dos dados, sem a necessidade de extração manual de características. Isso é alcançado por meio do treinamento supervisionado, em que a rede é alimentada com pares de entrada-saída e ajusta seus pesos por meio do algoritmo de retropropagação.

***Transfer Learning*:** Devido ao alto custo computacional e de dados para treinar CNNs do zero, muitas vezes é empregado o *transfer learning*, onde uma CNN pré-treinada em um grande conjunto de dados é ajustada para uma tarefa específica com um conjunto de dados menor. Isso é especialmente útil quando os dados de treinamento são limitados.

As CNNs revolucionaram a área de visão computacional e têm sido amplamente adotadas em diversas aplicações, desde reconhecimento facial até diagnóstico médico,

passando por carros autônomos e muito mais. Sua capacidade de extrair e aprender características diretamente dos dados as torna extremamente poderosas em uma ampla gama de problemas de aprendizado de máquina.

Segundo Katyayani, Bhardwaj, e Poongodi, (2023). A definição da *deep learning* YOLO

“*You only live once*” (Você só vive uma vez): É um lema popular que incentiva as pessoas a viverem a vida ao máximo e aproveitarem todas as oportunidades. É semelhante à expressão latina “*carpe diem*” (aproveite o dia).

YOLO em visão computacional: YOLO também pode se referir a um algoritmo de ponta para detecção de objetos em tempo real. É conhecido por sua velocidade e precisão. Você pode encontrar mais informações sobre o algoritmo YOLO no site do autor Joseph Redmon: URL *yolo real time object detection*

## SSD (Single Shot MultiBox Detector)

Similaridade: Arquitetura similar ao YOLO, utilizando uma única rede neural para realizar detecção e classificação de objetos em tempo real.

Diferenças:

Usa uma estrutura de regressão linear para prever bounding boxes e classificações.

Permite a detecção de múltiplos objetos em diferentes escalas (NING, ET AL 2017).

## YOLOv5

Similaridade: Versão mais recente do YOLO, com melhor precisão e desempenho em comparação com as versões anteriores.

Diferenças:

Usa uma arquitetura de “*Bag of Freebies*” para melhorar a precisão e a robustez do modelo.

Permite a detecção de objetos em diferentes escalas e com diferentes graus de oclusão (KUAN, ET AL, 2022)

Observações: A escolha do algoritmo ideal depende de diversos fatores, como a precisão desejada, a velocidade de processamento e o tipo de objeto a ser detectado. É importante avaliar as diferentes opções e escolher a que melhor se adapta às suas necessidades. As referências acima são apenas alguns exemplos de algoritmos similares ao YOLO. Existem diversas outras opções disponíveis, que podem ser encontradas na literatura científica e em repositórios de código online

## RESULTADOS

Alguns dos resultados encontrados na internet com aplicações para detecção de E.P.I.

Na Figura 1 mostra a detecção de capacetes de dois funcionários, detectando até a cor do E.P.I., o que normalmente difere funções na construção civil.

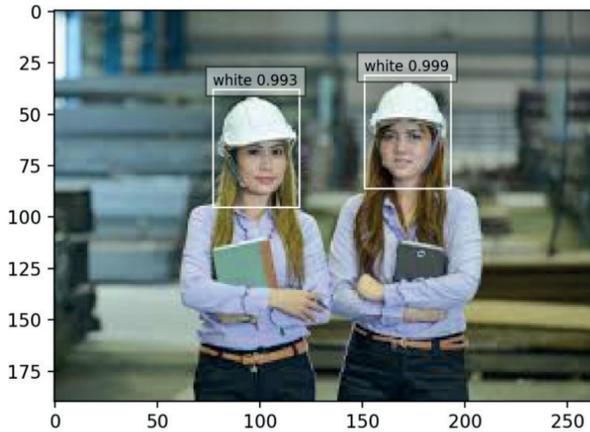


Figura 1 – Detecção de capacetes (cor branca)

Já a figura 2 mostra uma sequência de detecções, como, óculos, máscaras em ambientes agressivos a respiração. botas entre outros.

As imagens conferem uma alta precisão na detecção automática de diferentes E.P.Is, o que sugere um bom método a ser empregado, com as vantagens supracitadas

Já a figura 3, mostra a detecção de capacetes com operários em atividade.



Figura 3 – Detecção de diferentes E.P.Is

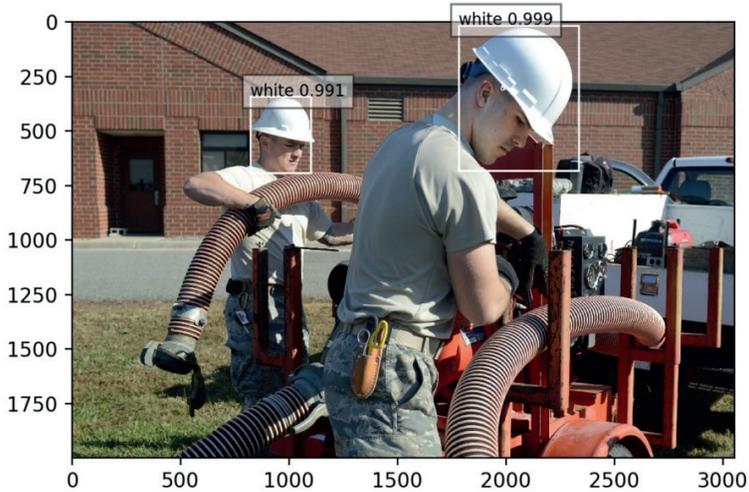


Figura 3 – Detecção de diferentes E.P.Is de forma dinâmica

Deste modo, as figuras mostram a viabilidade do uso do reconhecimento automático de E.P.Is

## CONCLUSÃO

Os resultados públicos divulgados por diferentes empresas encontrados mostram que a proposta é promissora.

A detecção automática do uso de Equipamentos Individuais de Proteção (*E.P.Is*) na indústria da engenharia civil representa uma inovação crucial para promover a segurança dos trabalhadores. Os altos índices de acidentes nesse setor ressaltam a urgência de implementar medidas eficazes para mitigar riscos ocupacionais. A utilização de tecnologias de detecção automática de *E.P.Is* oferece uma abordagem proativa e preventiva, garantindo o cumprimento das normas de segurança e reduzindo a incidência de lesões e acidentes.

Para futuros trabalhos, é essencial aprimorar ainda mais essas tecnologias, buscando integrações mais sofisticadas com sistemas de monitoramento e gestão de segurança. Além disso, a realização de estudos que avaliem a eficácia e o impacto a longo prazo da detecção automática de *E.P.Is* no ambiente de trabalho pode fornecer insights valiosos para o desenvolvimento de políticas e práticas de segurança mais eficientes. Investimentos em pesquisa e desenvolvimento nessa área são fundamentais para promover um ambiente de trabalho mais seguro e saudável para os profissionais da engenharia civil.

## REFERÊNCIAS

- MARIE, D. Noelle et al. A 2021 **Review on Recent Advancements in Robotic assisted Minimally Invasive Surgery**: The Philippines Perspective. In: 2021 IEEE 13th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management (HNICEM), 2021, Manila, Philippines. pp. 1-5. DOI: 10.1109/HNICEM54116.2021.9731947.
- Ministério do Trabalho e Previdência. Relatório Anual de Atividades. Brasília: Ministério do Trabalho e Previdência, 2023.
- NING, C. C., Zhou, H., Song, Y., & Tang, J. (2017). Inception Single Shot MultiBox Detector for object detection. In: **International Conference on Multimedia & Expo Workshops (ICMEW)**, 2017 IEEE, Hong Kong, China, pp. 549-554. DOI: 10.1109/ICMEW.2017.8026312.
- SILVA, J. C.; SANTOS, M. A.; OLIVEIRA, G. R. Visão Robótica: Uma Revisão Abrangente de Técnicas e Aplicações. In: **Anais do Simpósio Brasileiro de Robótica (SBR)**, São Paulo, SP, Brasil, 2023.
- SCARIA, B.; Aziz, N. A.; Siddiqi, M. A. M. "AI Based Robotic Systems for the quality control of Date Palm Fruits - A Review." In: **International Conference on Digitization (ICD)**, 2019, Sharjah, United Arab Emirates. pp. 227-231. DOI: 10.1109/ICD47981.2019.9105743.
- YU, X., Kuan, T. W., Zhang, Y., & Yan, T. (2022). YOLO v5 for SDSB Distant Tiny Object Detection. In: **Conferência Internacional sobre Tecnologia Laranja (ICOT)**, 10ª, 2022, Shanghai, China, pp. 1-4. DOI: 10.1109/ICOT56925.2022.10008164.
- KATYAYANI, K., Bhardwaj, B., & Poongodi, T. (2023). Deep Learning Approach for Multi-Object Detection Using Yolo Algorithm. In: **Conferência Internacional sobre Computação Contemporânea e Informática (IC3I)**, 6ª, 2023, Gautam Buddha Nagar, Índia, pp. 689-693. DOI: 10.1109/IC3I59117.2023.10398124.