

SISTEMA DE DETECÇÃO AUTOMATIZADA DE EQUIPAMENTOS DE PROTEÇÃO INDIVIDUAL POR VISÃO COMPUTACIONAL EM AMBIENTE DELIMITADO

AUTOMATED DETECTION SYSTEM OF PERSONAL PROTECTIVE EQUIPMENT USING COMPUTER VISION IN A DELIMITED ENVIRONMENT

Enzo de Souza Lima, Giovani Martinho do Nascimento, Kevin Bulgarelli Dossantos, Pedro Henrique Santos Silva, Raquel Galhardo de Carvalho Lopes Araújo e Luís Fernando Pompeo Ferrara

Universidade Santa Cecília, Faculdade de Engenharia, Curso de Engenharia da Computação
E-mail para contato: el156503@alunos.unisanta.br; gn170707@alunos.unisanta.br;
kd204515@alunos.unisanta.br; ps204483@alunos.unisanta.br;.

RESUMO– Este trabalho apresenta um sistema automatizado para detecção de Equipamentos de Proteção Individual (capacete, óculos e botas) em ambientes industriais por visão computacional. O modelo YOLOv8n foi treinado em 200 épocas e implementado em Raspberry Pi 4 com Coral Edge TPU, integrado ao Firebase e Telegram. A metodologia incluiu imagens reais, técnicas de aumento de dados e avaliação por métricas padrão de detecção. Os resultados mostraram precisão de 94,7%, revocação de 87,3% e mAP@0.5 de 93,9%, com desempenho em tempo real de 5 FPS. Conclui-se que o sistema é tecnicamente viável para monitorar EPIs como foi planejado e mostra que pode eventualmente dar suporte eficaz à fiscalização da segurança do trabalho.

Palavras-chave: EPI; visão computacional; YOLOv8n; segurança industrial; monitoramento.

***ABSTRACT** – This work presents an automated system for detecting Personal Protective Equipment (hard hat, safety glasses and boots) in industrial environments using computer vision. The YOLOv8n model was trained for 200 epochs and implemented on a Raspberry Pi 4 with a Coral Edge TPU, integrated with Firebase and Telegram. The methodology included real images, data augmentation techniques, and evaluation using standard detection metrics. The results showed 94.7% precision, 87.3% recall, and 93.9% mAP@0.5, with real-time performance of 5 FPS. It is concluded that the system is technically feasible for monitoring PPE as planned and shows that it may eventually provide effective support for occupational safety enforcement.*

Keywords: PPE; computer vision; YOLOv8n; industrial safety; monitoring.

1 INTRODUÇÃO

O projeto iniciou-se como uma proposta de auxiliar no monitoramento de trabalhadores que entrarão em uma área específica de uma empresa ou uma região de trabalho mais perigosa de se estar, como por exemplo, em um canteiro de obras onde há a área de concretagem. Nesse local, há vigas, materiais suspensos e diversos outros tipos de equipamentos e maquinários pesados, onde um capacete e botas com ponteira de aço são ótimos EPIs para proteger contra possíveis riscos. Outro exemplo de área que necessita do uso de EPIs é a de manutenção industrial, onde capacetes servem para proteger contra objetos que possam cair ou contra impactos acidentais com estruturas suspensas. Óculos de proteção evitam danos provocados por partículas metálicas ou faíscas, enquanto botas antiderrapantes com ponteira de aço reduzem ou eliminam danos caso uma peça pesada caia sobre os pés de um funcionário.

Existem diversos estudos relacionados à detecção de EPIs e outros equipamentos de segurança em áreas específicas utilizando o YOLO (ALI et al., 2022; HAYAT e MORGADO, 2022; WANG et al., 2021), que é a família de modelos de detecção utilizada no projeto, mais especificamente o YOLOv8n (nano). Há reforços para o uso de EPIs tanto pelo governo quanto por empresas privadas. Novos equipamentos de proteção são desenvolvidos por tais empresas, muitas vezes com funções para detectar se o usuário está ou não utilizando o equipamento. No entanto, diferentemente da proposta apresentada por Ali et al., 2022, tais soluções não realizam registros de ocorrência semelhantes aos que serão gerados neste projeto.

No estado atual da Indústria 4.0, pouco se discute sobre o monitoramento automatizado do uso de EPIs, já que o foco principal tem sido oferecer equipamentos de qualidade e verificar se as empresas cumprem a Norma Regulamentadora nº 6 – Equipamentos de Proteção Individual (BRASIL, 1978) e as portarias MTP nº 672 e MTE nº 3.906, que tratam dos procedimentos de avaliação e certificação de EPIs.

Existem inúmeros exemplos de EPIs salvando vidas. Apesar disso, ainda há muitas pessoas que não se sentem confortáveis usando tais vestimentas ou acessórios e, por conta dessa resistência, deixam de utilizá-los, o que resulta em acidentes e até em mortes. Considerando os avanços da tecnologia de reconhecimento de objetos utilizando aprendizado de máquina, o projeto propõe aplicar essa ferramenta em conjunto com um sistema de câmera e computador de placa única, explorando diversas funções e plataformas.

O objetivo do projeto, além de monitorar em tempo real o uso ou a ausência de EPIs pelos funcionários, é armazenar informações em um banco de dados ao qual a empresa contratante

terá acesso através de um site. Esse sistema apresentará todos os eventos registrados em que houver ausência de um ou mais EPIs designados para a área monitorada. Por exemplo, caso seja detectada a ausência do capacete, o sistema reconhecerá essa falta, registrará a imagem da ocorrência, o nível de confiança da detecção e a data. Dessa forma, a empresa terá mais uma ferramenta para fiscalizar, em uma área específica, o cumprimento do uso dos equipamentos de proteção, garantindo maior segurança e conformidade com as normas regulamentadoras.

2 MATERIAIS E MÉTODOS

Esta pesquisa é do tipo experimental, voltada para o desenvolvimento de um sistema de detecção automatizada de Equipamentos de Proteção Individual (EPIs) em tempo real.

O sistema foi implementado em um computador de placa única Raspberry Pi 4 (4 GB RAM), executando Raspberry Pi OS (versão 12 bookworm) e equipado com uma câmera USB Fire Phoenix 2 Mpx 1080p. O processamento local das imagens foi acelerado por um Coral USB Accelerator. O *software* foi desenvolvido em Python 3.9, utilizando uma extensão do TensorFlow, bibliotecas de visão computacional (OpenCV) e Firebase (Firestore, Hosting e Authentication) para armazenamento e visualização dos dados.

As figuras 1, 2 e 3 apresentam os componentes de *hardware* utilizados: a Raspberry Pi 4 atuando como unidade de processamento, figura 1, o Coral USB Accelerator responsável por acelerar as inferências do modelo YOLOv8n, figura 2 e a câmera USB montada em suporte adaptado no laboratório para ajuste de ângulo e distância de captura, figura 3.

Figura 1: Raspberry Pi 4 utilizada na implementação do sistema.



Figura 2: Coral USB Accelerator utilizado para aceleração do processamento.



Figura 3: Câmera montada em suporte em laboratório para testes.



O modelo de detecção utilizado foi o YOLOv8n (nano), treinado a partir de pesos pré-treinados no conjunto COCO. O treinamento foi realizado no *framework* Ultralytics YOLO, em um ambiente com GPU, empregando 200 épocas, tamanho de lote (batch size) de 32, resolução de entrada de 640×640 px, otimizador AdamW com taxa inicial de aprendizado de 0,0005 e decaimento de peso de 0,0005. As classes de interesse foram “pessoa”, “capacete”, “óculos” e “bota”. Foram aplicadas técnicas de aumento de dados, como mosaic, mixup, copy-paste,

ajustes HSV e transformações geométricas moderadas (rotação, translação, escala e cisalhamento).

Para avaliar o desempenho do modelo YOLOv8n, foram utilizadas as seguintes métricas padrão em detecção de objetos:

- Precisão: mede a razão entre verdadeiros positivos e todas as detecções positivas, indicando quantas das detecções realizadas pelo modelo estavam corretas;
- Revocação: representa a razão entre verdadeiros positivos e todos os objetos realmente presentes, medindo quantos dos EPIs presentes o modelo conseguiu detectar;
- mAP@0.5 (precisão média com IoU de 0,50): calcula a precisão média quando uma detecção é considerada correta se houver pelo menos 50% de sobreposição entre a caixa delimitadora predita pelo modelo e a caixa real do objeto, onde IoU (Interseção sobre União) representa a razão entre a área de interseção e a área de união das duas caixas;
- mAP@0.5:0.95 (precisão média com IoU de 0,50 a 0,95), que representa a precisão média usando múltiplos limiares rigorosos de sobreposição variando de 50% a 95%, avaliando a precisão da localização dos objetos com critérios progressivamente mais exigentes. As métricas foram calculadas em um conjunto de validação com 232 imagens contendo 704 instâncias anotadas das classes pessoa, capacete, óculos e bota.

As imagens eram capturadas continuamente pela câmera e processadas em tempo real. O algoritmo gerava caixas delimitadoras nos objetos detectados e verificava a presença ou ausência dos EPIs obrigatórios. Quando identificada a ausência de um EPI, a ocorrência era registrada no banco de dados Firebase Firestore juntamente com a imagem, a data e o nível de confiança da detecção. Esses dados eram então disponibilizados para uma interface *web*, acessível via navegador em computadores, com autenticação de usuários para acesso seguro.

3 RESULTADOS E DISCUSSÃO

O sistema opera a partir de uma distância de aproximadamente 5 metros do alvo, e 1,5 metros de altura em relação ao solo. O funcionamento do sistema está de acordo com o que foi planejado, ou seja, quando aparece uma pessoa na área onde o sistema foi posicionado e se a mesma está utilizando capacete, óculos e botas, caso um desses equipamentos não for detectado, é gerado uma ocorrência que é enviado ao banco de dados e pode ser vista no site, para o usuário que fica encarregado de checar o sistema analisar se de fato há a falta destes EPIs. Dentro do site aparece a imagem e qual EPI foi registrado a ausência, assim como o horário e data, lá

mesmo você pode alterar a área de captação da câmera tipo uma zona delimitadora caso não queira utilizar toda a resolução da câmera.

A matriz de confusão, figura 4, ilustra o desempenho do algoritmo na detecção dos EPIs, evidenciando taxas de falsos positivos e falsos negativos o que é crucial para avaliar sua confiabilidade em alertar corretamente sobre ausência de capacete, óculos ou botas. A tabela de performance, referenciada como tabela 1, complementa essa análise com métricas como precisão, *recall* e *F1-score*, permitindo verificar se o sistema identifica EPIs com alta sensibilidade ou se foi registrado um alerta indevido.

Figura 4: Matriz de confusão e Curva PR do modelo YOLOv8n desenvolvido.





Tabela 1: Métricas de desempenho na detecção de EPIs (YOLOv8n).

Classe	Imagens	Instâncias	Precisão (P)	Revocação (R)	mAP50	mAP50-95
Todos	232	704	0,947	0,873	0,939	0,599
Bota	63	152	0,897	0,809	0,893	0,582
Capacete	80	138	0,969	0,914	0,959	0,624
Óculos	107	124	0,947	0,862	0,941	0,538
Pessoa	201	290	0,974	0,908	0,963	0,654

A figura 5 apresenta a matriz de confusão e a curva PR do modelo YOLOv5n, conforme descrito por Ali et al. (2022), permitindo comparar diretamente com a figura 4, que mostra os resultados obtidos neste estudo.

Figura 5: Matriz de confusão e curva PR do modelo YOLOv5n (ALI et al., 2022).



O modelo YOLOv8n, treinado por 200 épocas, apresentou desempenho elevado nas métricas avaliadas, conforme demonstrado na tabela 1. O sistema alcançou um mAP@0.5 de 93,9% e mAP@0.5:0.95 de 59,9%, superando resultados reportados em trabalhos similares da literatura. A precisão geral de 94,7% indica que de todas as detecções realizadas pelo modelo, 94,7% estavam corretas, enquanto a revocação de 87,3% demonstra que o modelo detectou 87,3% de todos os EPIs realmente presentes nas imagens.

A classe "pessoa" apresentou a maior precisão (97,4%), indicando a capacidade robusta do modelo em identificar o elemento principal do sistema. Entre os equipamentos de proteção individual (EPIs), o capacete obteve o melhor desempenho, seguido pelos óculos de proteção e botas de segurança. Estes resultados evidenciam que o modelo detecta com maior facilidade EPIs com características visuais mais definidas.

Comparado a estudos anteriores, como o de ALI et al. (2022), que reportaram mAP@0.5 de 77,4% utilizando YOLOv5n, nosso sistema apresenta ganhos expressivos, com aumentos de 16,5 pontos percentuais no mAP@0.5 e 15,2 pontos na precisão. Isso reflete a eficácia das otimizações realizadas durante o treinamento.

A matriz de confusão normalizada, demonstrada na figura 4, confirma baixas taxas de erro, com valores acima de 85% na diagonal principal.

O sistema foi testado em ambiente real, rodando em Raspberry Pi 4 equipado com Coral Edge TPU, alcançando taxa média de 5 FPS durante as detecções, suficientes para monitoramento contínuo em aplicações industriais. A implementação da máquina de estados, com três fases (Vazio → Analisando → Monitoramento), aumentou a confiabilidade do sistema.

O tempo médio para envio de notificações via Telegram é consideravelmente rápido, enquanto o armazenamento dos dados no Firebase Firestore ocorreu rapidamente garantindo agilidade na comunicação e persistência das informações.

A interface *web* desenvolvida ofereceu funcionalidades que facilitaram o monitoramento remoto, incluindo a configuração intuitiva de zonas de interesse através de uma marcação feita pelo usuário, autenticação personalizada e histórico detalhado de ocorrências.

O uso de *buffers* de estabilidade com histórico de 15 *frames* assegurou consistência nas detecções, mesmo frente a oclusões temporárias.

Entretanto, o sistema apresenta algumas limitações. A detecção de botas, apesar de satisfatória, foi inferior em relação a outras classes, possivelmente pela maior variabilidade visual e oclusões frequentes. Além disso, o sistema está otimizado para operação com uma única câmera, demandando esforços futuros para suportar múltiplas câmeras. Por fim, a dependência de conectividade para notificações e armazenamento pode restringir seu uso em ambientes industriais com limitações de rede.

4 CONCLUSÃO

O presente trabalho desenvolveu um sistema automatizado de detecção de Equipamentos de Proteção Individual utilizando visão computacional em ambiente delimitado, atendendo aos objetivos propostos de monitorar em tempo real o uso de EPIs por trabalhadores e disponibilizar essas informações através de uma interface *web* acessível às empresas. O modelo YOLOv8n treinado alcançou excelente desempenho com mAP@0.5 de 93,9%, mAP@0.5:0.95 de 59,9%, precisão de 94,7% e revocação de 87,3%. O sistema integrado demonstrou robustez operacional através da implementação de máquina de estados tendo processamento em tempo real de 5 FPS em Raspberry Pi 4 com Coral Edge TPU, e capacidade de registrar automaticamente ocorrências com imagem, data, hora e nível de confiança no banco de dados Firebase Firestore, o sistema demonstrou rapidez para notificações via Telegram. A interface *web* desenvolvida proporcionou monitoramento remoto eficaz incluindo configuração intuitiva de zonas de interesse, autenticação de usuários e histórico detalhado de ocorrências, oferecendo às empresas uma ferramenta adicional para fiscalização do cumprimento das normas regulamentadoras de segurança do trabalho. Embora o sistema apresente limitações na detecção de botas (89,3% mAP@0.5) e seja otimizado para câmera única, os resultados evidenciam a viabilidade técnica e prática da solução proposta para implementação em ambientes industriais reais. Como trabalhos futuros, sugere-se a implementação de suporte para múltiplas câmeras, expansão do sistema para detectar outros tipos de EPIs e mudança de *hardware* e sistema, para fazer o

mesmo não depender do processamento da *raspberry* e sim de um servidor dedicado acessível via nuvem.

5 REFERÊNCIAS

ALI, L., ALNAJJAR, F., PARAMBIL, M. M. A., YOUNES, M. I., ABDELHALIM, Z. I., ALJASSMI, H. Development of YOLOv5-Based Real-Time Smart Monitoring System for Increasing Lab Safety Awareness in Educational Institutions. *Sensors*. 2022;22(22):8820.

BRASIL. Ministério do Trabalho. Norma Regulamentadora NR-6: Equipamentos de Proteção Individual – EPI. Portaria GM n.º 3.214, de 08 de junho de 1978. Disponível em: <https://www.gov.br/trabalho-e-emprego/pt-br/assuntos/seguranca-e-saude-no-trabalho/normas-regulamentadoras/nr-6>.

HAYAT, A., MORGADO, D. F. Deep Learning-Based Automatic Safety Helmet Detection System for Construction Safety. *Applied Sciences*. 2022;12(16):8268.

WANG, Z., WU, Y., YANG, L., THIRUNAVUKARASU, A., EVISON, C., ZHAO, Y. Fast Personal Protective Equipment Detection for Real Construction Sites Using Deep Learning Approaches. *Sensors*. 2021;21(10):3478.