

Um Sistema Integrado para Monitoramento Automático do Uso de EPIs na Indústria Alimentícia com Detecção Visual e Atuação Embarcada em Tempo Real

Glauber Giordano De Moraes Lima¹, Fabrício Moura Guimarães¹,
Caique Nascimento dos Santos¹, Warlles Carlos Costa Machado¹,
José Soares da Silva Neto¹, Melina da Conceição Macêdo da Silva¹,
Arlino Henrique Magalhães de Araújo²

¹Instituto Federal de Educação, Ciência e Tecnologia do Piauí (IFPI)
Campus Angical do Piauí – Angical do Piauí – PI – Brasil

²Universidade Federal do Piauí (UFPI)
Campus Universitário Ministro Petrônio Portela – Teresina – PI – Brasil

caang.2024119tads0012@aluno.ifpi.edu.br, fbguimaraes.ads@gmail.com,
caiquesantos4705@gmail.com, warllescarlos@ifpi.edu.br,
jose.neto@ifpi.edu.br, melinacms@ifpi.edu.br, arlinoh@ufpi.edu.br

Abstract. *Ensuring compliance with Personal Protective Equipment (PPE) usage is essential in food processing environments to prevent contamination and ensure occupational safety. This work presents an integrated real-time monitoring system that combines object detection models with embedded devices to automatically identify PPE non-compliance and trigger physical responses. The solution was experimentally evaluated in a controlled laboratory environment designed to reproduce operational characteristics of a mineral water bottling facility. Results demonstrate the feasibility of integrating visual detection, asynchronous communication, and embedded actuation with an average end-to-end response time of 140 ms and mAP@50 of approximately 90%, indicating its potential as a scalable low-cost monitoring approach.*

Resumo. *A verificação do uso de Equipamentos de Proteção Individual (EPIs) é fundamental em ambientes do setor alimentício. Este trabalho apresenta um sistema integrado de monitoramento em tempo real que combina detecção automática de EPIs com comunicação assíncrona e atuação embarcada. A solução foi avaliada experimentalmente em ambiente laboratorial adaptado, com características operacionais semelhantes a linhas de envase. O sistema alcançou mAP@50 de aproximadamente 90% e tempo médio de resposta de 140 ms, demonstrando viabilidade técnica para aplicações de monitoramento contínuo.*

1. Contexto

A contaminação microbiológica em ambientes industriais do setor alimentício representa risco à saúde pública e à conformidade sanitária. Em linhas de envase de água mineral, aplicação inicial deste trabalho, o uso adequado de Equipamentos de Proteção Individual (EPIs), como toucas e máscaras, integra as boas práticas de higiene e contribui para a mitigação de contaminação cruzada [Lopes et al. 2022].

Contudo, a verificação do uso de EPIs é predominantemente manual, baseada em inspeção visual, o que implica cobertura limitada e suscetibilidade a falhas humanas [Zorzenon et al. 2022]. Nesse cenário, técnicas de visão computacional tornaram-se alternativas viáveis para reconhecimento automático de EPIs. A família YOLO (*You Only Look Once*) [Redmon et al. 2016] consiste em detectores do tipo *one-stage*, nos quais classes e coordenadas são previstas em uma única etapa de regressão, favorecendo aplicações em tempo quase real. Entre suas variantes, o YOLOv5 adota abordagem baseada em *anchors*, enquanto o YOLOv8 introduz refinamentos estruturais e estratégia *anchor-free*, motivando a comparação experimental realizada neste trabalho.

Entretanto, parte significativa das abordagens reportadas limita-se à detecção visual, sem integração efetiva com mecanismos físicos de mitigação de risco [Zhou et al. 2025]. A articulação entre visão computacional, sistemas embarcados e Internet das Coisas (IoT) [Ashton 2009, Bavaresco et al. 2021] possibilita converter detecções de não conformidade em respostas físicas automatizadas. Ainda assim, permanece pouco explorada a integração simultânea de detecção automática de EPIs, comunicação embarcada e atuação física validada experimentalmente no setor alimentício, lacuna que este trabalho busca endereçar.

2. Processo adotado

A pesquisa é de natureza aplicada e experimental, estruturada em cinco etapas: (i) revisão de literatura, (ii) definição arquitetural, (iii) construção do conjunto de dados, (iv) treinamento do modelo de detecção e (v) integração com sistemas embarcados. O processo foi conduzido de forma incremental, permitindo refinamento sucessivo do *dataset* e do modelo.

A revisão de literatura analisou abordagens de detecção automática de EPIs, fundamentando a escolha da visão computacional e da família YOLO como base experimental.

Tabela 1. Comparação sintética dos trabalhos relacionados

Trabalho	Ambiente	Paradigma	Modelo
[Barro-Torres et al. 2012]	Construção civil	SF	–
[Yang et al. 2020]	Construção civil	SF	–
[Protik et al. 2021]	Construção civil	VC	YOLOv4
[Lo et al. 2022]	Construção civil	VC	YOLOv8
[Al-Azani et al. 2024]	Construção civil	VC	YOLOv7
[Ali et al. 2022]	Laboratório	VC	YOLOv5

O conjunto de dados foi composto por aproximadamente 1.500 imagens provenientes de repositórios públicos¹ e coletas em ambientes com características operacionais semelhantes ao cenário de aplicação. Foram definidas sete classes relacionadas ao uso de EPIs e presença de pessoas. A rotulagem ocorreu por anotação assistida incremental, e o dataset foi particionado em 70% para treinamento, 20% para validação e 10% para teste.

Por fim, o modelo treinado² foi preparado para integração com sistemas embar-

¹Parte do conjunto de dados utilizado no treinamento e validação do modelo pode ser acessado em: <https://universe.roboflow.com/datasetanyar/med-ppe-bewmr>

²Código-fonte de teste do modelo: <https://github.com/GlaugTbest/YoloV8EPIDetectionV2>

cados, priorizando portabilidade do pipeline de inferência e definição de interfaces para comunicação com dispositivos externos.

3. Solução

A solução proposta implementa um sistema integrado para verificação automática de conformidade no uso de EPIs, combinando detecção visual baseada em aprendizado profundo, comunicação assíncrona via MQTT (*Message Queuing Telemetry Transport*), protocolo leve baseado no modelo publicação/assinatura amplamente empregado em aplicações IoT devido à eficiência em redes com restrições de largura de banda, e atuação física embarcada em tempo quase real. A arquitetura, apresentada na Figura 1, organiza-se em três módulos funcionais: (i) aquisição, (ii) processamento e (iii) atuação, seguindo um modelo de processamento distribuído compatível com o paradigma de *fog computing* [Hu et al. 2017].



Figura 1. Arquitetura da solução proposta.

No módulo de aquisição, câmeras realizam captura contínua do ambiente monitorado. Os quadros são encaminhados ao módulo de processamento, onde é executado o modelo de detecção treinado para identificar sete classes: *com_touca*, *sem_touca*, *com_mascara*, *sem_mascara*, *com_bota*, *sem_bota* e *pessoa*. O modelo foi treinado com aproximadamente 1.500 imagens anotadas, estruturadas em subconjuntos de treinamento, validação e teste (70/20/10), conforme descrito na Seção anterior.

Foram comparadas as variantes nano dos modelos YOLOv5 e YOLOv8, considerando desempenho e custo computacional. O YOLOv5n atingiu mAP@0.5 de 0.785 com latência média de 7.2 ms (GPU), enquanto o YOLOv8n apresentou mAP@0.5 de 0.911 mantendo latência equivalente (8.6 ms). Dada a sensibilidade da aplicação a falsos negativos, o YOLOv8n foi adotado como modelo final.

Embora o conjunto de dados seja moderado em escala, foram aplicadas técnicas de *data augmentation* (rotação, variação de brilho e escala), contribuindo para maior capacidade de generalização.

A Tabela 2 apresenta o desempenho por classe no conjunto de teste. Observa-se desempenho elevado para a maioria das classes, com destaque para as classes relacionadas a botas e pessoa. A classe *sem_mascara* apresentou desempenho relativamente inferior (AP@0.5 = 0.83), indicando maior dificuldade discriminativa sob oclusões parciais e variações de iluminação.

A Figura 2 exemplifica a inferência realizada pelo modelo final, evidenciando a

detecção simultânea das classes por meio de *bounding boxes* e respectivas classificações.

Tabela 2. Desempenho por classe do modelo YOLOv8n no conjunto de teste.

Classe	Precisão	Recall	AP@0.5
com_touca	0.91	0.88	0.89
sem_touca	0.94	0.92	0.92
com_mascara	0.90	0.87	0.88
sem_mascara	0.84	0.81	0.83
com_bota	0.96	0.94	0.95
sem_bota	0.95	0.93	0.94
peessoa	0.97	0.96	0.96
mAP@50 Global (YOLOv5n)	–	–	0.785
mAP@50 Global (YOLOv8n)	–	–	0.911




Figura 2. Exemplo de detecção utilizando o modelo YOLOv8n.

O treinamento foi conduzido com GPU RTX 3060 Ti, utilizada para validação experimental do pipeline.

A análise de latência *end-to-end* foi realizada a partir de registros temporais inseridos no pipeline de execução, considerando 50 execuções consecutivas em rede local Wi-Fi. O tempo médio observado entre captura do quadro e acionamento físico foi de aproximadamente 140 ms (desvio padrão inferior a 12 ms). Embora a inferência isolada apresente latência média de 8.6 ms em GPU, o tempo total incorpora captura, serialização, transmissão MQTT e processamento embarcado.

A validação funcional utilizou matriz de LEDs 5x5 para sinalizar não conformidades, confirmando a extensibilidade da arquitetura para outros atuadores.

Como contribuição principal, este trabalho apresenta: (i) arquitetura integrada para monitoramento automático de EPIs; (ii) comparação entre YOLOv5n e YOLOv8n sob restrição computacional; e (iii) mensuração da latência *end-to-end* em ambiente embarcado.

Referências

- Al-Azani, S., Luqman, H., Alfarraj, M., Sidig, A. A. I., Khan, A. H., and Al-Hamed, D. (2024). Real-time monitoring of personal protective equipment compliance in surveillance cameras. *IEEE Access*, 12:121882–121895.
- Ali, L., Alnajjar, F., Parambil, M. M. A., Younes, M. I., Abdelhalim, Z. I., and Aljasmi, H. (2022). Development of yolov5-based real-time smart monitoring system for increasing lab safety awareness in educational institutions. *Sensors*, 22(22):8820.
- Ashton, K. (2009). That ‘internet of things’ thing. *RFID Journal*.
- Barro-Torres, S., Fernández-Caramés, T. M., Pérez-Iglesias, H. J., and Escudero, C. J. (2012). Real-time personal protective equipment monitoring system. *Computer Communications*, 36(1):42–50.
- Bavaresco, F. et al. (2021). Internet of things and occupational well-being in industry 4.0: A systematic mapping study and taxonomy. *Computers & Industrial Engineering*, 161:107670.
- Hu, P., Dhelim, S., Ning, H., and Qiu, T. (2017). Survey on fog computing: architecture, key technologies, applications and open issues. *Journal of network and computer applications*, 98:27–42.
- Lo, J.-H., Lin, L.-K., and Hung, C.-C. (2022). Real-time personal protective equipment compliance detection based on deep learning algorithm. *Sustainability*, 15(1):391.
- Lopes, B. R. d. S., Vigoder, H. C., Medeiros, M. d. G. G. d. A., et al. (2022). Use of personal protective equipment and its implications in food hygiene: literature review.
- Protik, A. A., Rafi, A. H., and Siddique, S. (2021). Real-time personal protective equipment (ppe) detection using yolov4 and tensorflow. In *2021 IEEE region 10 symposium (TENSYMP)*, pages 1–6. IEEE.
- Redmon, J. et al. (2016). You only look once: Unified, real-time object detection. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 779–788, Las Vegas. IEEE.
- Yang, X., Yu, Y., Shirowzhan, S., Li, H., et al. (2020). Automated ppe-tool pair check system for construction safety using smart iot. *Journal of Building Engineering*, 32:101721.
- Zhou, H. A., Wolfsschläger, D., Florides, C., et al. (2025). Generative ai in industrial machine vision: A review. *Journal of Intelligent Manufacturing*.
- Zorzenon, R., Lizarelli, F. L., and Braatz, D. (2022). The impact of the internet of things on health and safety performance at work: An empirical study of brazilian companies. *International Journal of Production Economics*, 243:108331.