Anais do Congresso Brasileiro de Iniciação Científica
(https://periodicos.unisanta.br/COB)

ISSN 2317-1316

MONITORAMENTO AUTOMATIZADO DE EPIs E VESTIMENTAS NO INOVFABLAB COM VISÃO COMPUTACIONAL EMBARCADA

AUTOMATED PPE AND WORKWEAR COMPLIANCE MONITORING USING RASPBERRY PI 5 AND HAILO-8L NEURAL ACCELERATOR

Gabriel Rodrigues Marques, Matheus Tetsuji Yamauti Angelotti, Sergio Seda Escudero Filho, Sergio Schina de Andrade

Universidade Santa Cecília, Faculdade de Engenharia, Curso de Engenharia da Computação

E-mail para contato: sf156753@alunos.unisanta.br

RESUMO – Este trabalho propõe um sistema automatizado para monitoramento de EPIs e vestimentas em ambiente controlado, conforme a Norma Regulamentadora n. 6 (NR-06), utilizando Visão Computacional e Aprendizado Profundo. A solução emprega o modelo YOLOv8n em uma arquitetura de Edge AI composta por Raspberry Pi 5 e acelerador neural Hailo-8L. O INOVFABLAB foi utilizado como estudo de caso. O modelo, treinado com 1.092 imagens, alcançou mAP@50 de 96,9%, precisão de 94,2%, recall de 94,8% e F1-Score de 94,5%. Nos testes, o sistema atingiu média de 28 FPS e picos de 30 FPS, indicando viabilidade para monitoramento contínuo e rastreável.

Palavras-chave: YOLOv8n; Inteligência artificial embarcada; Visão computacional; Hailo-8L; Raspberry Pi 5;

ABSTRACT – This work proposes an automated system for monitoring Personal Protective Equipment (PPE) and workwear in a controlled environment, in accordance with Brazilian Regulatory Standard NR-06. The system uses Computer Vision and Deep Learning techniques. The proposed solution employs the YOLOv8n model in an Edge AI architecture composed of a Raspberry Pi 5 and a Hailo-8L neural accelerator. INOVFABLAB was used as a case study. The model, trained with 1,092 images, achieved an mAP@50 of 96.9%, precision of 94.2%, recall of 94.8%, and F1-score of 94.5%. In the tests, the system achieved an average of 28 FPS, with peaks of 30 FPS, indicating its feasibility for continuous and traceable monitoring.

Keywords: YOLOv8n; Embedded artificial intelligence; Computer vision; Hailo-8L; Raspberry Pi 5;

ISSN 2317-1316

1 INTRODUÇÃO

A adoção de tecnologias associadas à Indústria 4.0 tem impulsionado soluções de automação, monitoramento e segurança apoiadas por Visão Computacional e inteligência artificial embarcada. Arquiteturas da família YOLO têm sido amplamente utilizadas em detecção de objetos em tempo real (ALI; ZHANG, 2024), enquanto abordagens de *Edge AI* permitem executar inferência local em dispositivos embarcados, reduzindo dependência de infraestrutura externa (MERENDA; PORCARO; IERO, 2020; SIPOLA et al., 2022)

Em ambientes controlados, a NR-12 estabelece medidas preventivas para máquinas e equipamentos, enquanto a NR-06 regulamenta os Equipamentos de Proteção Individual (EPIs). A supervisão visual pode auxiliar na verificação de conformidade, conforme estudos de detecção automatizada de EPIs (CHENG et al., 2022; DELHI; SANKARLAL; THOMAS, 2020; BRASIL, 2019; BRASIL, 2024).

Nesse cenário, a Visão Computacional possibilita monitoramento em tempo real e registros rastreáveis de não conformidades.

Este trabalho propõe o desenvolvimento de um sistema embarcado para monitoramento automatizado de vestimentas em ambientes controlados, baseado em uma arquitetura de *Edge AI*. A solução é composta por câmera HBVCAM IMX586, microcomputador Raspberry Pi 5, acelerador neural Hailo-8L e modelo YOLOv8n treinado para identificar condições de conformidade e não conformidade relacionadas ao uso de vestimentas. (RASPBERRY PI LTD., 2025; HAILO, 2024; ULTRALYTICS, 2025).

Os quadros capturados são processados em tempo real para classificar as vestimentas segundo os critérios de conformidade do ambiente.

Os eventos e as imagens capturadas ficam disponíveis em uma interface web para consulta e rastreamento. A solução foi aplicada como estudo de caso no INOVFABLAB da Universidade Santa Cecília.

Persistem desafios na aplicação da inteligência artificial embarcada a laboratórios acadêmicos, sobretudo na validação, rastreabilidade e segurança (RUSSELL; NORVIG, 2013).

A literatura privilegia detecção genérica ou aplicações industriais, com menor atenção a sistemas embarcados para fiscalização de vestimentas em laboratórios educacionais.

No INOVFABLAB, a verificação predominantemente humana pode gerar inconsistências e dificultar o registro sistemático de não conformidades.

ISSN 2317-1316

Diante dessa lacuna, o presente estudo tem como objetivo geral desenvolver e validar uma solução baseada em Visão Computacional e *Edge AI* para o monitoramento automatizado da conformidade de vestimentas em ambiente laboratorial. Como objetivos específicos, busca-se implementar um sistema embarcado utilizando Raspberry Pi 5 e o acelerador neural Hailo-8L, treinar e validar um modelo YOLOv8n para identificar as classes de vestimenta definidas no estudo, realizar a detecção em tempo real de situações de conformidade e não conformidade, emitir alertas quando forem identificadas condições inadequadas e registrar evidências das detecções para auxiliar na supervisão e na rastreabilidade dos eventos. Parte-se da hipótese de que a integração entre um modelo de detecção de objetos e uma arquitetura de *Edge AI* pode viabilizar o monitoramento automatizado de vestimentas em tempo real, com desempenho adequado para atuar como ferramenta de apoio à supervisão em ambientes laboratoriais controlados.

2 MATERIAIS E MÉTODOS

A pesquisa é de natureza aplicada, com abordagem experimental e estudo de caso no laboratório INOVFABLAB da Universidade Santa Cecília. Conforme Gil (2002), a pesquisa aplicada busca gerar conhecimento direcionado à solução de problemas práticos. Prodanov e Freitas (2013) destacam que o método experimental envolve o controle de variáveis e a observação dos resultados. O procedimento experimental envolveu a montagem de ambiente controlado para coleta de imagens, configuração da infraestrutura de hardware, treinamento e validação do modelo de visão computacional e, posteriormente, testes de campo. O trabalho foi organizado em quatro etapas: planejamento, desenvolvimento, implementação e avaliação do sistema

2.1 MATERIAIS

Raspberry Pi 5 com 16 GB de RAM, sistema operacional Raspberry Pi OS Bookworm 64 bits, fonte oficial de 27 W USB-C, armazenamento em cartão microSD de 128 GB e processador Broadcom BCM2712, Arm Cortex-A76 de quatro núcleos e 64 bits a 2,4 GHz. Acelerador de Inteligência Artificial Hailo-8L em Raspberry Pi AI HAT+, utilizado como unidade de processamento neural para a inferência do modelo. Câmera HBVCAM IMX586 de

ISSN 2317-1316

12 MP, com captura 4K a 30 fps. Nos ensaios, a captura foi configurada em 1920 x 1080 a 30 fps, com campo de visão de aproximadamente 120 graus e distância operacional entre 2 m e 4 m, sob iluminação fluorescente do laboratório. A escolha buscou preservar resolução suficiente para distinguir classes de vestimenta. Parâmetros de altura, ângulo de instalação e calibração fotométrica não foram registrados de forma sistemática; essa ausência é tratada como limitação metodológica, especialmente por sua possível influência em cenários de baixa iluminação.

2.2 INTEGRAÇÃO E TESTES

Foram realizados testes de detecção de pessoas utilizando shorts por meio do modelo YOLOv8n executado na Raspberry Pi 5, no laboratório INOVFABLAB da Universidade Santa Cecília. Inicialmente, foi realizado o levantamento dos requisitos do sistema com base nas normas de segurança vigentes no laboratório e nas especificações relacionadas às vestimentas exigidas para acesso ao ambiente. Essa etapa consistiu na análise das diretrizes institucionais e dos procedimentos de segurança adotados no laboratório, permitindo a definição dos critérios de conformidade necessários para o desenvolvimento e validação da solução proposta.

Em seguida, realizou-se o desenvolvimento do protótipo de hardware utilizando a plataforma Raspberry Pi 5 como unidade principal de processamento, integrada ao acelerador de inteligência artificial Hailo-8L, responsável pela otimização computacional da inferência. O sistema foi encapsulado em um invólucro mecânico semelhante a uma câmera de monitoramento. Esse encapsulamento foi projetado considerando a dissipação térmica ativa do conjunto, o gerenciamento seguro da alimentação elétrica via fonte cabeada ininterrupta e a proteção física contra poeira e impactos leves. O posicionamento do dispositivo ocorreu no teto/canto superior da parede, garantindo o campo de visão ideal e facilitando a instalação no ambiente do laboratório.

Posteriormente, foi realizado o treinamento do modelo YOLOv8n utilizando 1.092 imagens próprias, distribuídas em quatro classes: bermuda, calça, sapato fechado e chinelo. As imagens foram rotuladas pela equipe responsável pelo desenvolvimento do projeto, utilizando uma ferramenta de anotação de imagens, com posterior conferencia dos rótulos para verificar sua consistência. O conjunto foi divido em 914 imagens para treinamento, 119 para validação e 59 para teste. A quantidade reduzida de imagens de teste, correspondente a aproximadamente 5,4% do conjunto, constitui uma limitação metodológica, sendo seus resultados complementados por

ISSN 2317-1316

testes em condições reais de operação. Foram aplicadas técnicas de *data augmentation,* como rotação, variação de brilho e zoom. O treinamento utilizou *batch size* 32, *leraning rate* de 0,001 e 50 épocas. Parâmetros como seed, otimizador, *early stopping* e valores de **IoU/NMS** não foram integralmente registrados. Após o treinamento, os componentes foram integrados e avaliados por métricas de detecção e FPS do *pipeline* Hailo/GStreamer, considerando o desempenho completo do sistema.

Para a avaliação do desempenho, foi utilizado o parâmetro **`--show-fps`** do pipeline Hailo/GStreamer, com execução contínua durante 60 segundos. O valor obtido foi tratado como uma medida da taxa de processamento do pipeline completo, envolvendo as etapas de captura da imagem, pré-processamento, inferência na NPU, pós-processamento e exibição dos resultados. A comunicação via MQTT integra o fluxo geral da aplicação, porém sua latência não foi medida separadamente. Da mesma forma, não foram registradas latências individuais para cada etapa nem o desvio-padrão entre execuções. Assim, o FPS apresentado neste trabalho representa o desempenho global do protótipo e não deve ser interpretado como uma medida isolada da velocidade de inferência do Hailo-8L.

2.3 ANÁLISE DOS RESULTADOS

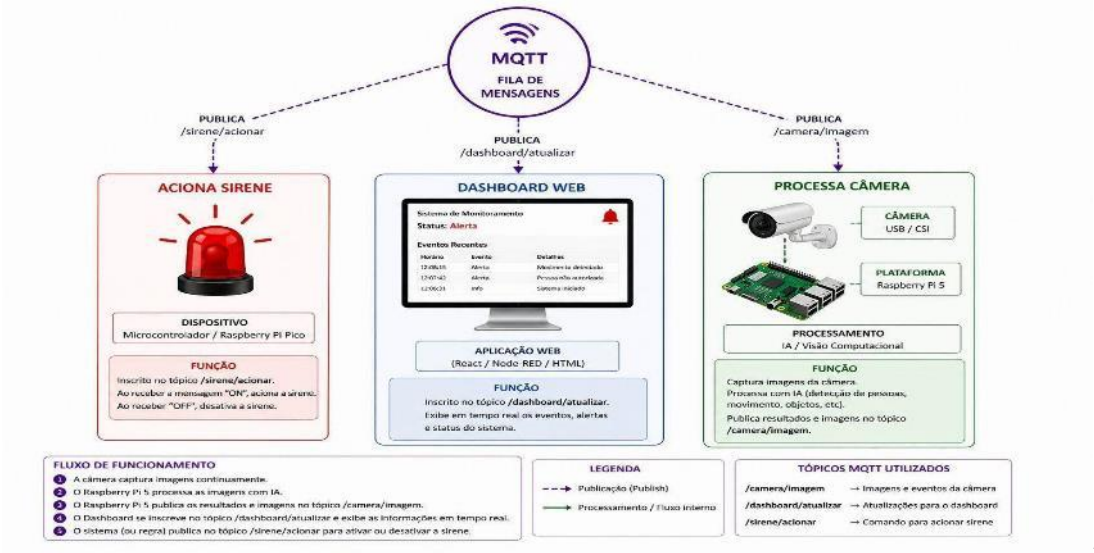
A análise dos resultados considerou as métricas de *precision*, *recall*, *F1-Score* e mAP@50, além da taxa de FPS observada no *pipeline*. O valor de mAP@50 superior a 95% foi estabelecido como meta operacional do projeto, não sendo considerado um limiar universal definido pela literatura. A interpretação do desempenho foi fundamentada em referências relacionadas à detecção de objetos, ao aprendizado profundo e à *Edge AI* (ALI; ZHANG, 2024; GOODFELLOW; BENGIO; COURVILLE, 2016; CORDOVA-CARDENAS; AMOR; GUTIÉRREZ, 2025). As limitações relacionadas à aquisição das imagens, às condições de iluminação e à instrumentação também foram consideradas na análise, uma vez que esses fatores podem influenciar o desempenho do sistema em condições reais de operação.

2.4 ARQUITETURA E FLUXO DE FUNCIONAMENTO DO SISTEMA

A Figura 1 sintetiza a arquitetura: a câmera captura imagens, o Raspberry Pi 5 e o Hailo-8L realizam a detecção, e os módulos conectados registram eventos, atualizam a interface web e acionam alertas de não conformidade.

ISSN 2317-1316

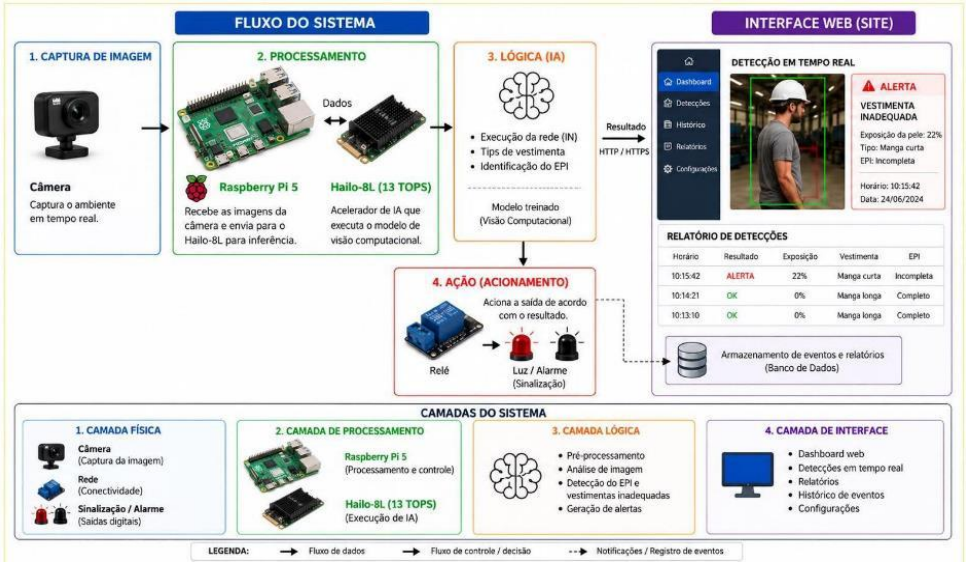
Figura 1: Arquitetura geral e fluxo de funcionamento do sistema de detecção de vestimentas.



Fonte: Elaborado pelos autores (2026), com auxílio de ferramenta de inteligência artificial generativa.

A Figura 2 detalha o fluxo operacional, da captura e inferência à avaliação da conformidade, emissão de alertas e registro dos eventos para consulta. O diagrama também apresenta decisões e tratamentos de exceção.

Figura 2: Fluxo operacional e máquina de estados do sistema de monitoramento de vestimentas com processamento embarcado em Raspberry Pi 5 e acelerador Hailo-8L.



Fonte: Elaborado pelos autores (2026), com auxílio de ferramenta de inteligência artificial generativa.

ISSN 2317-1316

3 RESULTADOS E DISCUSSÃO

A implementação do sistema embarcado de inteligência artificial demonstrou a viabilidade do monitoramento automatizado de vestimentas e equipamentos de proteção em ambiente laboratorial. A integração entre o Raspberry Pi 5, o acelerador Hailo-8L e o modelo YOLOv8n permitiu realizar a detecção dos elementos de interesse em tempo real, mantendo desempenho compatível com a proposta do sistema. Os resultados obtidos indicaram que a utilização de processamento dedicado por NPU foi determinante para superar as limitações observadas quando a inferência foi executada exclusivamente pela CPU.

No ensaio contínuo de 60 segundos, o *pipeline* apresentou média de 28 FPS e picos próximos de 30 FPS. Em comparação, a execução somente na CPU apresentou aproximadamente 3 FPS e uso de CPU próximo de 100%, enquanto, com o Hailo-8L, o uso médio observado da CPU foi de aproximadamente 35%. Esses valores descrevem o comportamento do protótipo; temperatura, consumo da NPU e desvio-padrão do FPS não foram instrumentados no protocolo original.

No teste prático, o YOLOv8n utilizou resolução de 640 × 640 pixels e limiar de confiança de 63%. Para avaliar essa configuração, foram definidos três limiares de comparação (50%, 60% e 70%), considerando as métricas de Precision e Recall. O pós-processamento empregou Non-Maximum Suppression (NMS), adotando como referência IoU de 0,70, valor padrão do YOLOv8 na biblioteca Ultralytics. A análise também considera possíveis perdas na detecção de classes menores, como sapatos e chinelos, devido ao redimensionamento das imagens. O ensaio de desempenho foi relatado integralmente no intervalo de 60 segundos, sem exclusão seletiva de resultados para elevar as métricas. A Tabela 1 apresenta apenas os indicadores efetivamente medidos e documentados no protótipo.

Tabela 1. Desempenho Computacional

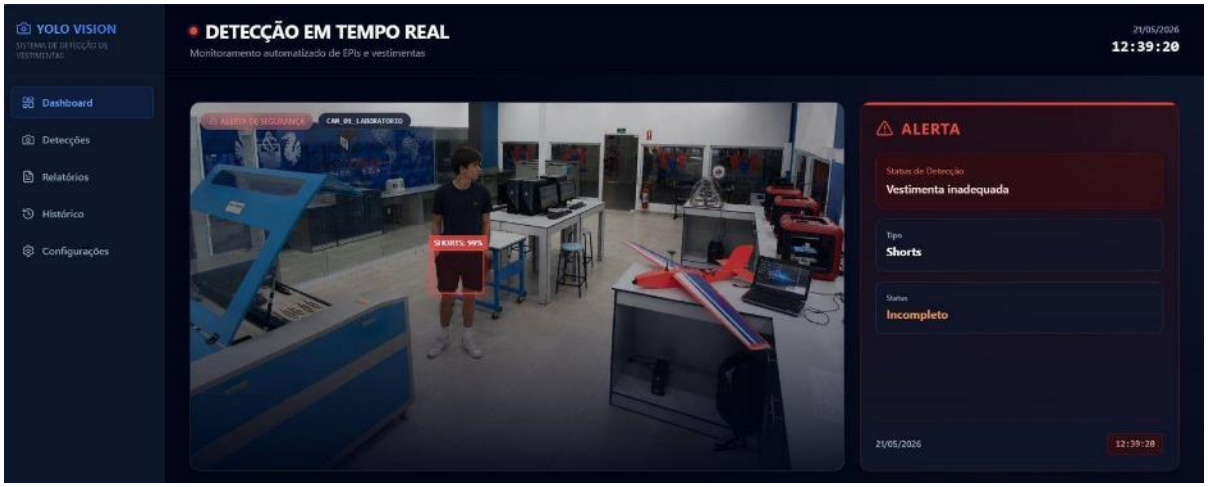
Modelo / Arquitetura	Resolução de Entrada	FPS Médio Obtido	Uso Médio de CPU (%)
YOLOv8n (Nano)	640 x 640	28 FPS	35%

Além da detecção, o sistema foi estruturado para registrar e rastrear os resultados obtidos. A arquitetura inclui um *backend* desenvolvido em Python/*FastAPI*, banco de dados *SQLite*,

ISSN 2317-1316

comunicação via *MQTT* e uma interface em *React* atualizada por *WebSocket*. Esses componentes atuam de forma integrada no protótipo. Durante os testes, a atualização da interface apresentou latência aproximada de 1000 ms, correspondente a um atraso de cerca de 1 segundo na visualização das informações. A Figura 3 apresenta a interface web desenvolvida para o acompanhamento das detecções, exibindo o fluxo de vídeo processado e as informações relacionadas aos eventos identificados pelo sistema.

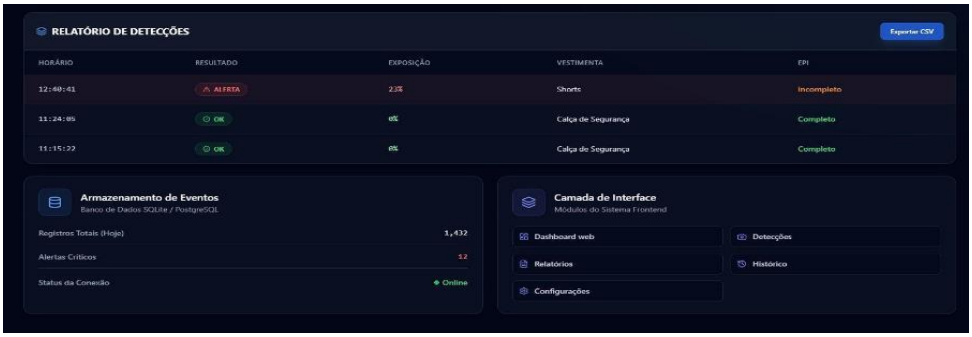
Figura 3: Interface web desenvolvida para exibição das detecções e monitoramento do sistema.



Fonte: Elaborado pelos autores (2026), com auxílio de ferramenta de inteligência artificial para aprimoramento da qualidade da imagem.

O sistema também conta com uma camada de armazenamento local estruturada em banco de dados *SQLite* para auditoria de eventos não conformes. O modelo de dados adotado registra os seguintes campos obrigatórios para cada evento: data, hora da ocorrência, classe detectada, nível de confiança, recorte da imagem contendo a evidência e status final gerado pela lógica de decisão, compondo o relatório ilustrado na Figura 4.

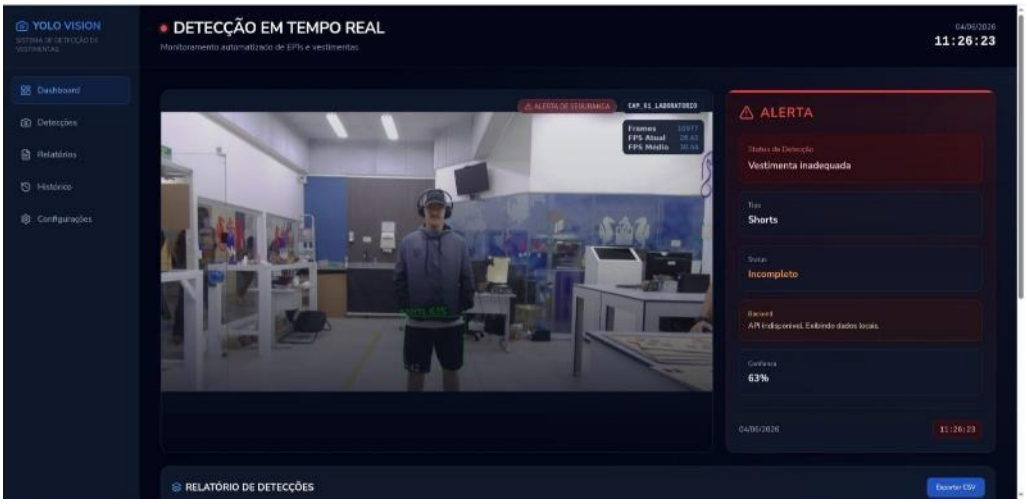
Figura 4: Relatório de detecções com histórico de eventos e detalhamento da camada de armazenamento da interface web.



ISSN 2317-1316

Os ensaios foram conduzidos no INOVFABLAB. O protocolo estabeleceu como critério mínimo de sucesso o reconhecimento correto da conformidade em 80% dos quadros avaliados. A taxa de acerto foi calculada pela razão entre os quadros corretamente classificados e o total de quadros processados, multiplicada por 100. As limitações relacionadas a iluminação, ao posicionamento e as oclusões foram consideradas na análise, sem exclusão dos resultados.

Figura 5: Teste prático de detecção em tempo real utilizando Raspberry Pi 5 e Hailo-8L.



Com Edge AI, o processamento permanece no dispositivo, reduzindo o envio de vídeo a serviços externos. Como há tratamento de imagens pessoais, a implantação deve atender à LGPD (BRASIL, 2018), definindo finalidade, base legal, informação aos participantes, consentimento quando aplicável, controle de acesso e prazo de retenção. Sempre que possível, devem ser adotadas medidas de anonimização, como desfoque facial. O protótipo não deve ser considerado, por si só, certificado em conformidade com a LGPD.

Apesar dos resultados favoráveis, o estudo apresenta limitações. Os testes foram realizados em ambiente controlado, com quatro classes e condições específicas de aquisição das imagens. A avaliação de não conformidade concentrou-se principalmente na presença de bermuda, não contemplando todas as possíveis situações relacionadas ao uso inadequado de EPIs. O protocolo também não registrou o desvio-padrão do FPS, a temperatura, o consumo da NPU ou a latência individual das etapas do pipeline. Além disso, foram observadas possíveis falhas em condições de baixa iluminação, porém sem quantificação suficiente para determinar uma taxa de falsos positivos. Como trabalhos futuros, recomenda-se ampliar o conjunto de dados e as classes

ISSN 2317-1316

analisadas, realizar testes sob diferentes condições de iluminação e aprimorar a instrumentação das métricas de desempenho e das medidas de proteção de dados.

4 CONCLUSÃO

O estudo desenvolveu e avaliou no INOVFABLAB um sistema embarcado de monitoramento de vestimentas, integrando câmera, Raspberry Pi 5, Hailo-8L e YOLOv8n. Os ensaios demonstraram viabilidade técnica para detecção contínua, com alertas, registro local e interface web. A generalização exige novas condições de teste, mais classes, melhor instrumentação e salvaguardas de privacidade. Agradece-se à Universidade Santa Cecília pela disponibilização do INOVFABLAB

.

5 DECLARAÇÃO DE USO DE IA

Na elaboração deste trabalho, ChatGPT-4o (OpenAI) e Claude 3.5 Sonnet (Anthropic), como recursos auxiliares a revisão gramatical, ao aprimoramento da redação cientifica e a organização textual. Todo conteúdo foi analisado, revisado e validado pelos autores, que assumem integral responsabilidade pelas informações apresentadas. Na preparação da versão final, também foram observadas as exigências acadêmicas de submissão, incluindo o limite de 2 MB para o arquivo, a remoção de hiperlinks, a inclusão da Norma Regulamentadora (NR-06) e da Lei Geral de Proteção de Dado Pessoais (LGPD) nas referências bibliográficas.

6 REFERÊNCIAS

ALI, Momina Liaqat; ZHANG, Zhou. The YOLO framework: a comprehensive review of evolution, applications, and benchmarks in object detection. Computers, v. 13, n. 12, p. 336, 2024.

BRASIL. Ministério do Trabalho e Emprego. Norma Regulamentadora n. 6 (NR-06): equipamentos de proteção individual (EPI). Brasília, DF: Ministério do Trabalho e Emprego, 2024.

BRASIL. Lei n. 13.709, de 14 de agosto de 2018. Lei Geral de Proteção de Dados Pessoais (LGPD). Diário Oficial da União: seção 1, Brasília, DF, 2018.

ISSN 2317-1316

BRASIL. Ministério do Trabalho e Emprego. Norma Regulamentadora nº 12 (NR-12): segurança no trabalho em máquinas e equipamentos. Brasília, DF: Ministério do Trabalho e Emprego, 2019.

CHENG, Jack C. P.; WONG, Peter Kok-Yiu; LUO, Haoze; WANG, Mingzhu; LEUNG, Pak Him. Vision-based monitoring of site safety compliance based on worker re-identification and personal protective equipment classification. Automation in Construction, v. 139, p. 104312, 2022.

CORDOVA-CARDENAS, Ruth; AMOR, Daniel; GUTIÉRREZ, Álvaro. *Edge AI* in practice: a survey and deployment framework for neural networks on embedded systems. Electronics, v. 14, n. 24, p. 4877, 2025.

DELHI, Venkata Santosh Kumar; SANKARLAL, R.; THOMAS, Albert. Detection of personal protective equipment (PPE) compliance on construction site using computer vision based deep learning techniques. Frontiers in Built Environment, v. 6, p. 136, 2020.

GIL, Antonio Carlos. Como elaborar projetos de pesquisa. 4. ed. São Paulo: Atlas, 2002.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. Deep learning. Cambridge: MIT Press, 2016.

HAILO. Hailo-8L AI accelerator: datasheet and architecture. Tel Aviv: Hailo Technologies, 2024.

MERENDA, Massimo; PORCARO, Carlo; IERO, Demetrio. Edge machine learning for AI-enabled IoT devices: a review. Sensors, v. 20, n. 9, p. 2533, 2020.

RASPBERRY PI LTD. Raspberry Pi 5 documentation. Cambridge: Raspberry Pi Ltd., 2025.
RUSSELL, Stuart; NORVIG, Peter. Inteligência artificial: uma abordagem moderna. 3. ed. Rio de Janeiro: Elsevier, 2013.

SIPOLA, Tuomo; ALATALO, Janne; KOKKONEN, Tero; RANTONEN, Mika. Artificial intelligence in the IoT era: a review of Edge AI hardware and software. In: CONFERENCE OF OPEN INNOVATIONS ASSOCIATION (FRUCT), 31., 2022. Proceedings [...]. [S. l.]: IEEE, 2022. p. 320-331.

ULTRALYTICS. Explore Ultralytics YOLOv8. [S. l.]: Ultralytics, 2025.