

Construindo Indicadores Estratégicos para a Saúde e Segurança no Trabalho a Partir de uma Metodologia de Visão Computacional de EPIs

Jonathan Kuspil^{1,2}, Karina Kimura^{1,2}, Luiz de Lima²,
Caio Flexa², Renan Ceratto², Gislaine Leal^{1,2}, Edwin Galdamez^{1,2}

¹Universidade Estadual de Maringá – Maringá – PR – Brasil

²OnSafety – Maringá, PR – Brasil

{jonathankuspil, kimurakarina23, luiz.m.franca1}@gmail.com,

caio.rodriques@icen.ufpa.br, ceratto@onsafety.com.br,

{gclleal, evcgaldamez}@uem.br

Abstract. *This work proposes a methodology for converting computer vision detections into strategic Occupational Health and Safety indicators, instantiated through the OnSafety Vision AI (OnVI) system. Using a model to detect PPE use and non-compliance events, this proposal integrates climatic, spatial, and severity variables to overcome conventional reactive management. The approach enables proactive, data-driven decision-making, identifying ergonomic and structural flaws through transparent and contextual metrics.*

Resumo. *Este trabalho propõe uma metodologia para converter detecções de visão computacional em indicadores estratégicos de Segurança e Saúde do Trabalho, materializada no sistema OnSafety Vision AI (OnVI). Utilizando um modelo de detecção de EPIs e não conformidades, esta proposta integra variáveis climáticas, espaciais e de severidade para superar a gestão reativa convencional. A abordagem viabiliza decisões proativas e data-driven, identificando falhas ergonômicas e estruturais via métricas transparentes e contextuais.*

1. Contexto

Apesar dos avanços da Indústria 4.0, o cenário de Segurança e Saúde do Trabalho (SST) no Brasil permanece crítico, com mais de 8,8 milhões de acidentes entre 2012 e 2024 [Smartlab 2026, Ferrari et al. 2023a]. A conformidade com a Norma Regulamentadora 06 (NR-06) esbarra na supervisão humana limitada em ambientes dinâmicos [Brasil 2022, Daniel et al. 2025] e na dependência de indicadores reativos, que registram falhas apenas após o ocorrido [Saxena 2024]. Atualmente, a conformidade – definida como a aderência rigorosa ao uso dos EPIs previstos, em contraste com a não conformidade, caracterizada pela ausência ou uso inadequado do equipamento frente aos riscos identificados – é afetada por inspeções manuais onerosas e sujeitas a erros, gerando dados estáticos.

Para uma prevenção efetiva, a indústria demanda Indicadores *Leading* (preditivos) em tempo real [Chandu et al. 2024]. Embora o *deep learning* possua alta acurácia na detecção de EPIs [Pereira et al. 2024], persiste uma lacuna entre os dados brutos e a inteligência estratégica. Diante desse cenário e sob a ótica de Sistemas de Informação (SI),

este trabalho propõe uma metodologia para traduzir detecções de visão computacional em indicadores gerenciais de SST. A abordagem é materializada por meio do **Onsafety Vision AI (OnVI)**¹, que converte imagens em métricas de aderência e risco por ambiente, permitindo uma gestão *data-driven* e maior consciência situacional no monitoramento normativo e na prevenção de riscos.

2. Processo Adotado

A fundamentação técnica da abordagem proposta baseia-se no ecossistema OnVI, um SI orientado por visão computacional para o monitoramento de EPIs e não conformidades. A extração de dados brutos a partir de imagens de câmera de segurança utiliza modelos de aprendizagem profunda de estágio único baseados no algoritmo YOLOv11. Conforme apontado por [Pereira et al. 2024], essa classe de modelos consolidou-se como um padrão de mercado para a detecção de múltiplas classes em contextos de SST, permitindo identificar simultaneamente trabalhadores e diversos tipos de equipamentos com alta performance.

Contudo, a saída primária do algoritmo, composta por coordenadas de *bounding boxes* e classes com confiança de detecção associada (e.g., com *capacete*: 78%), constitui um dado bruto que carece de contexto semântico para a gestão estratégica. Soma-se a isso o desafio da magnitude do processamento: a gravação contínua aliada a altas taxas de quadros por segundo (QPS) gera uma quantidade massiva de dados brutos, tornando a análise humana direta impraticável e reforçando a necessidade de mecanismos automáticos de síntese em indicadores inteligentes e integráveis [AlMarri et al. 2025].

O processo adotado fundamentou-se, portanto, na identificação de lacunas entre essas detecções automatizadas por IA e as necessidades de tomada de decisão em SST. Na concepção do sistema, a construção dos indicadores prioriza a transparência e a contextualização, suavizando a característica de “caixa-preta” inerente aos modelos de IA [Park and Kang 2024]. A interpretabilidade gerencial complementa a explicabilidade técnica [Xu et al. 2025]; logo, métricas de sistema como confiança e taxa de quadros (QPS) são expostas para permitir que o gestor audite a eficácia do modelo em tempo real.

A estruturação dos dados seguiu uma lógica de correlação multidimensional. Primeiramente, integrou-se variáveis climáticas (temperatura e umidade) e temporais às taxas de conformidade, dado que o desconforto térmico durante picos de calor e o desconforto temporal são fatores determinantes para a não conformidade no uso de EPIs [Ferrari et al. 2023b]. Essa correlação viabiliza a transição de uma fiscalização punitiva da NR-06 para uma gestão ergonômica e preventiva.

Para elevar a precisão geográfica e anatômica, adotou-se a técnica de mapas de calor (*heatmaps*) que, ao contrário dos dados de conformidade sumarizados (que ocultam nuances setoriais), permitem identificar padrões de risco em setores específicos da planta ou falhas em grupos anatômicos de proteção (ex: membros superiores vs. proteção auditiva). Esta granularidade é essencial para diagnosticar se a não conformidade decorre do comportamento do colaborador ou de inadequações do equipamento às características estruturais e/ou operacionais do ambiente [Wong et al. 2020].

¹OnSafety: Empresa de software para SST. Informações em: <https://onsafety.com.br/a-inteligencia-artificial-ia-na-sst/>. Acessado em: 5 fev. 2026

A severidade foi incorporada ao modelo por meio de uma lógica de ponderação de riscos. O processo definiu que o cálculo da conformidade (i.e., número de detecções conforme sobre o número total – conforme e não conforme) deve ser sensível ao potencial de dano: a ausência de um EPI de proteção contra quedas em altura possui um peso superior a um desvio em área de baixo risco. Essa hierarquização assegura que os indicadores de *leading* reflitam a real exposição ao perigo. Adicionalmente, o sistema processa métricas gerais como o tempo de resposta à identificação do risco, permitindo avaliar a maturidade da resiliência operacional da empresa.

Considerando as implicações éticas e a mitigação da carga psíquica da vigilância contínua [Adler et al. 2022], os indicadores focam em dados agregados por setor, evitando métricas de punição individual. Tal escolha promove uma cultura de segurança baseada na melhoria de processos, respeitando a privacidade e o bem-estar laboral.

3. Solução

Baseando-se nos requisitos técnicos e operacionais da aplicação de modelos como o OnVI, projetaram-se indicadores divididos em quatro visões complementares do risco ocupacional, conforme exemplo de *dashboard* gerencial apresentado na Figura 1.

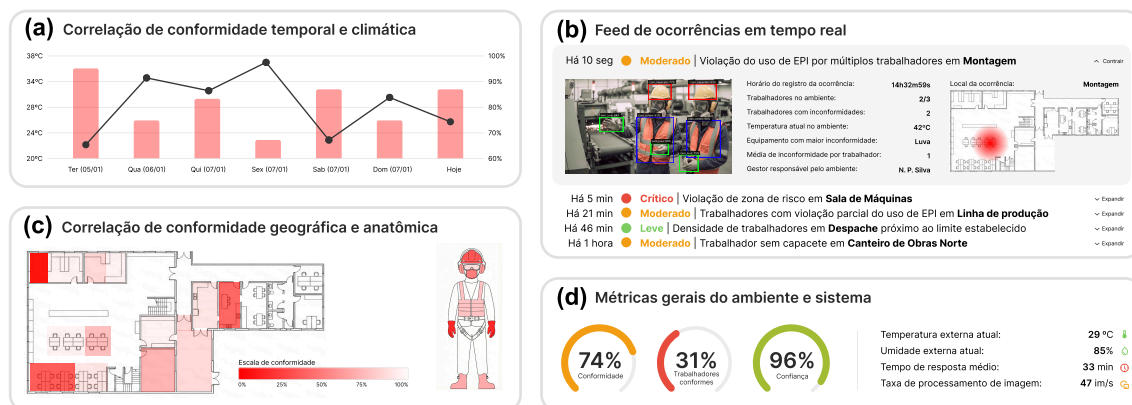


Figura 1. Modelo de dashboard para gerenciamento em tempo real

O indicador multi-eixo na Figura 1(a), **Correlação de Conformidade Temporal-Climática**, cruza a taxa de conformidade (linha preta) com o contexto climático (temperatura em vermelho ou umidade em um modo de exibição alternativo) e temporal semanal. Para fins de gerenciamento, ele pode assumir diferentes granularidades (eixo horizontal).

Para um monitoramento proativo, o **Feed de Ocorrências em Tempo Real**, Figura 1(b), detalha condições que geram alertas classificados por severidade (crítico, moderado, leve). Cada alerta é acompanhado do *snapshot* da detecção e detalhes do local. Neste cenário, a ausência de EPIs em um setor crítico gera um alerta de maior severidade, combatendo a fadiga de alarmes e direcionando a atenção para intervenções imediatas.

Na Figura 1(c), a **Correlação de Conformidade Geográfica-Anatômica** utiliza mapas de calor sobre a planta baixa para identificar se os riscos são dispersos (comportamentais) ou concentrados em postos específicos (falhas estruturais). Complementarmente, o diagrama anatômico destaca regiões do corpo com maior índice de desvio, orientando o reforço em grupos de proteção específicos (e.g., auricular, visual ou de membros) através de treinamentos ou substituição de equipamentos.

As **Métricas Gerais do Ambiente e Sistema**, Figura 1(d), consolidam o desempenho agregado e o contexto instantâneo da operação em um recorte temporal selecionado. O painel exibe a conformidade global e a proporção de trabalhadores protegidos, oferecendo uma visão macroscópica da segurança. O módulo diferencia-se ao expor o nível de confiança das detecções e a taxa de QPS, garantindo transparência técnica. A integração de dados ambientais (temperatura e umidade) permite validar a confiabilidade do monitoramento sob diferentes condições operacionais.

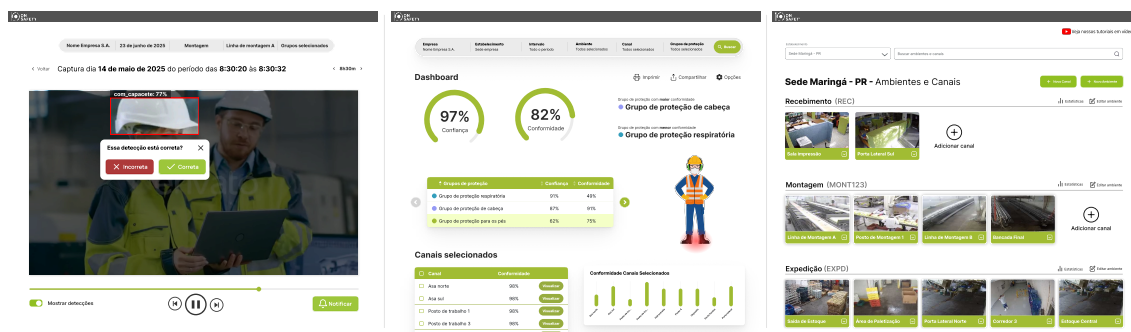


Figura 2. Interfaces atualmente implementadas do OnSafety Vision AI

O estágio atual de desenvolvimento do OnVI compreende uma arquitetura robusta já operacional, com um protótipo sendo seguido como modelo (conforme apresentado na Figura 2) para plataforma web e um *backend* consolidado. A infraestrutura baseia-se em máquinas dedicadas *on-premises* na organização para o processamento local de modelos YOLOv11.

Atualmente, o sistema disponibiliza a análise de dados históricos para auditoria e planejamento; contudo, o roteiro de evolução tecnológica prevê a integração de alertas críticos, nuances climáticas e monitoramento em tempo real. A utilidade das métricas propostas foi validada preliminarmente junto a especialistas de SST, que destacaram o positivo impacto de tal tecnologia, a qual encontra-se em implementação por *Early adopters*, definindo estratégias para uma avaliação mais completa da solução.

Este trabalho apresentou uma metodologia para converter detecções de visão computacional em indicadores estratégicos de SST via sistema OnVI. A integração de variáveis climáticas, espaciais e de severidade permite que a segurança transcenda a fiscalização relativa para uma gestão *data-driven*. A abordagem mitiga a opacidade técnica e o desafio do *Big Data* do monitoramento contínuo, oferecendo transparência via evidências operacionais e ergonômicas. O OnVI demonstra que o valor da IA reside na decodificação do comportamento humano para uma gestão mais eficaz. Trabalhos futuros focarão na automação de alertas móveis e na correlação entre indicadores *leading* e a redução de custos decorrentes de acidentes e doenças ocupacionais.

Agradecimentos

Agradecemos à SETI - PR pelo financiamento do Projeto de Inovação Tecnológica aprovado no Edital CP 01/2023 - AGEUNI - SETI PR, Termo de Convênio N° 023/2024.

Referências

Adler, D. A., Tseng, E., Moon, K. C., Young, J. Q., Kane, J. M., Moss, E., Mohr, D. C., and Choudhury, T. (2022). Burnout and the quantified workplace: tensions around

- personal sensing interventions for stress in resident physicians. *Proceedings of the ACM on Human-computer Interaction*, 6(CSCW2):1–48.
- AlMarri, M., Al-Ali, M., Alzarooni, M., AlTeneiji, A., Al-Ali, K., and Bahroun, Z. (2025). Enterprise resource planning systems for health, safety, and environment management: Analyzing critical success factors. *Sustainability*, 17(7).
- Brasil (2022). NR 06 - EQUIPAMENTOS DE PROTEÇÃO INDIVIDUAL - EPI. Acesso em: 21 de janeiro de 2026.
- Chandu, K., Raja, K. H., and Kumar, N. N. (2024). From reactive to proactive: The role of wearable technology, ai, and digital training in construction safety management. *Library Progress International*, 44(3):22858–22864.
- Daniel, E. I., Oshodi, O. S., Nwankwo, N. I., Emuze, F. A., and Chinyio, E. (2025). The use of digital technologies in construction safety: A systematic review. *Buildings*, 15(8).
- Ferrari, G. N., Leal, G. C. L., Ossani, P. C., and de Souza, R. C. T. (2023a). Análise exploratória de acidentes de trabalho do brasil registrados no sinan. *Revista Laborativa*, 12(1):172–200.
- Ferrari, G. N., Ossani, P. C., de Souza, R. C. T., Leal, G. C. L., and Galdamez, E. V. C. (2023b). Impact of rising temperatures on occupational accidents in brazil in the period 2006 to 2019: A multiple correspondence analysis. *Safety Science*, 161:106078.
- Park, J. and Kang, D. (2024). Artificial intelligence and smart technologies in safety management: a comprehensive analysis across multiple industries. *Applied Sciences*, 14(24):11934.
- Pereira, F., González García, M. d. I. N., and Poças Martins, J. (2024). An evaluation of the technologies used for the real-time monitoring of the risk of falling from height in construction—systematic review. *Buildings*, 14(9):2879.
- Saxena, V. (2024). Predictive analytics in occupational health and safety. *BARC Newsletter*, (Sep-Oct 2024 Issue):p. 53–57.
- Smartlab (2026). Observatório de segurança e saúde no trabalho. Acesso em: 21 janeiro de 2026.
- Wong, T. K. M., Man, S. S., and Chan, A. H. S. (2020). Critical factors for the use or non-use of personal protective equipment amongst construction workers. *Safety Science*, 126:104663.
- Xu, Y., Wang, L., and Fang, D. (2025). AI-driven safety management for building operation and maintenance: A systematic review. In *International Conference on Construction Engineering and Project Management*, pages 75–82. Korea Institute of Construction Engineering and Management.