

## T6 – Segurança do Trabalho

### CLASSIFICAÇÃO DO RISCO POSTURAL DE ATIVIDADES LABORAIS POR INTELIGÊNCIA ARTIFICIAL

Felipe Marlon da Silva <sup>1</sup>, Jonhatan Magno Norte da Silva <sup>2</sup>

**RESUMO:** *Este artigo apresenta uma inteligência artificial (IA) desenvolvida para identificar e classificar a postura corporal no local de trabalho. O sistema utiliza tecnologias de visão por computador e aprendizado de máquina para monitorar a postura dos trabalhadores e fornecer feedback sobre a posição adotada pelo corpo. Além disso, a IA também pode ser configurada para identificar posturas perigosas e alertar os trabalhadores sobre possíveis riscos posturais para a saúde. A finalidade é ajudar a prevenir lesões relacionadas a manutenção de más posturas, contribuindo para melhorar a saúde e o bem-estar dos trabalhadores. A IA proposta foi testada em três vídeos selecionados do Youtube filmados na vista lateral. Os resultados mostram que a IA foi capaz de captar, em tempo real, as boas e más posturas adotadas pelos trabalhadores. Além de quantificar o tempo em cada postura, a IA ainda pode fornecer um feedback sonoro, por exemplo, avisando ao trabalhador que este está mantendo uma má postura por um tempo excessivo. Conclui-se que a IA proposta tem capacidade de monitorar a postura corporal em ambientes de trabalho, fornecendo um feedback importante para o trabalhador e para os gestores em ergonomia.*

**PALAVRAS-CHAVE:** IA, Visão computacional, Monitoramento de saúde no trabalho.

#### 1. INTRODUÇÃO

A saúde e o bem-estar dos trabalhadores são aspectos importantes para qualquer organização. Por isso devem ser buscados para assegurar a melhor eficiência global dos sistemas produtivos. Um elemento que tem impacto na saúde é postura corporal adotada durante o trabalho. Quando inapropriada, a postura repercute em um aumento na chance de doenças, especialmente para os trabalhadores que passam longos períodos sentados ou em pé em seus postos de trabalho (BISPO et al., 2022).

No entanto, é difícil para os trabalhadores manter a postura correta durante todo o dia de trabalho. A adoção de múltiplas posturas durante é a condição mais comum vivenciada por trabalhadores. Contudo, os métodos de avaliação ergonômica, a exemplo do *Rapid Entire Body Assessment* (REBA) (HIGNETT & MCATAMNEY, 2000), *Rapid Upper Limb Assessment* (RULA) (MCATAMNEY & CORLETT, 1993) e *Ovako Working Posture Analysis System* (OWAS) (KARHU et al., 1977), fazem apenas uma avaliação estática das posturas por meio de fotografias. Desse modo, apenas uma amostra das posturas de trabalho é avaliada na prática.

Compreendendo essa importante limitação dos métodos baseados em fotografias, alguns pesquisadores tem utilizado sensores para fornecer um feedback de posturas em tempo real (LIND et al., 2020). Porém, o uso de tecnologias dessa natureza demanda elevado investimento em sensores eletrônicos e sistemas robustos capazes de processar as informações geradas, repercutindo em um custo significativo para as empresas em geral.

<sup>1</sup> Afiliação: Universidade Federal de Alagoas – Campus do Sertão  
Email: felipe.marlon@delmiro.ufal.br

<sup>2</sup> Afiliação: Universidade Federal de Alagoas – Campus do Sertão  
Email: jonhatan.silva@delmiro.ufal.br

Por outro lado, é cada vez mais comum o uso de imagens captadas em tempo real e processadas por algoritmos de inteligência artificial (IA). Exemplo disso, é o trabalho de Assunção et al. (2022) que fez o uso de imagens para detecção e classificação dos frutos, sendo, portanto, uma ferramenta útil para elevar a produtividade em atividades agrícolas de precisão. E, sem dúvidas, foi o aumento na capacidade computacional e o recente desenvolvimento de algoritmos de aprendizagem profunda (LAMAS et al., 2022) que fizeram com que a detecção de objetos e pessoas possa trazer mudanças e beneficiar os mais diferentes setores da economia e da sociedade como um todo (ZENG et al., 2022).

Ciente das inúmeras possibilidades do uso da detecção de imagens para análise em tempo real, algum esforço tem sido empregado para analisar posturas de seres humanos durante algumas atividades cotidianas. Para verificar a acurácia dos algoritmos de IA na detecção de posturas humanas, Garg et al., (2022) classificou posições de yoga, que é um estilo de exercício no qual a adoção de posturas corretas é fundamental para um melhor benefício. Nesse mesmo estudo, uma acurácia próxima a 90% foi alcançada pelos diferentes algoritmos testados, chegando a 99,62% em algumas situações.

Diante do exposto, este artigo tem por objetivo idealizar uma IA desenvolvida em *Python* que identifique e classifique a postura corporal de trabalhadores em estações de trabalho. A IA foi construída usando as bibliotecas *MediaPipe* (LUGARESI et al., 2019) e *OpenCV* (BRADSKI, 2000) para monitorar a postura dos trabalhadores e fornecer feedback sobre a posição correta do corpo. Além disso, a IA também pode ser configurada para identificar posturas perigosas e alertar os trabalhadores sobre possíveis riscos posturais para a saúde.

Vale salientar que a introdução da IA proposta nesse artigo em ambientes de trabalhos pode repercutir em um impacto significativo na saúde e no bem-estar dos trabalhadores, ajudando a prevenir lesões relacionadas ao trabalho pela não manutenção de más posturas (LIMA DA SILVA et al., 2022; SOUZA et al., 2021), melhorando a qualidade de vida dos trabalhadores. A prevenção de lesões osteomusculares também reflete em benefícios para a empresas, por exemplo, na redução dos índices de absenteísmo (LEITE et al., 2022) e no aumento no desempenho no trabalho (DE ARAÚJO VIEIRA et al., 2022).

## **2. METODOLOGIA**

Nessa seção é possível conhecer os critérios de seleção dos vídeos. Também são apresentadas informações sobre a construção do algoritmo de IA para análise postural e os procedimentos para o cálculo de distâncias, ângulos, tempos e inserção de sinais de alerta.

### **2.1 Seleção dos Vídeos**

Um total de três vídeos foram selecionados aleatoriamente do *YouTube*. Os critérios de seleção dos vídeos foram: (1) Ter um trabalhador filmado na posição lateral por no mínimo 20 segundos; (2) Vídeo com qualidade e ausência de perda de foco; (3) Vídeos com tamanho máximo de 20 Megabits (MB); e (4) Vídeo com clareza suficiente para mostrar a cabeça e tronco do trabalhador. Foram excluídos os vídeos que não configuraram situação de trabalho e que não atenderam os critérios de inclusão.

## 2.2 Construção do Algoritmo de IA

A construção de uma IA para análise de postura corporal humana é uma tarefa que exige alguma complexidade computacional e a combinação de diferentes tecnologias. No caso desse artigo, foi utilizado a linguagem de programação *Python* e duas de suas bibliotecas, a *MediaPipe* e *OpenCV*.

Em relação ao *MediaPipe* trata-se de uma biblioteca de processamento de mídia (fotos e vídeos, por exemplo), com código aberto e que foi desenvolvida pela *Google*. A mesma fornece ferramentas para a captura, processamento e visualização de vídeos em tempo real. Portanto, ideal para o desenvolvimento de aplicativos de análise postural. Já o *OpenCV* é uma biblioteca de processamento de imagem de código aberto. Fornece então uma ampla gama de recursos de processamento de imagem, incluindo detecção de bordas, rastreamento de objetos e filtragem de imagem.

O algoritmo de IA combina tais tecnologias através de programação. Parte do código é dedicada a capturar imagens de pessoas (oriundas de vídeos, câmeras e webcams, por exemplo). Em seguida, a biblioteca *MediaPipe* é utilizada para rastrear os pontos-chaves do corpo, como cabeça e ombros. Para, por fim, a biblioteca *OpenCV* proceder com a análise da postura da pessoa a partir da posição relativa desses pontos-chaves.

Durante o processo de programação em *Python* também foram definidas relações matemáticas (de natureza trigonométrica) para classificar a postura em boa ou ruim. Nesse artigo, as posturas foram classificadas em função da flexão/extensão da cabeça e tronco (coluna vertebral). A classificação de risco se baseou na adição de pontuação de risco semelhante aos métodos REBA (HIGNETT & MCATAMNEY, 2000) e RULA (MCATAMNEY & CORLETT, 1993).

## 2.3 Distâncias, Ângulos, Cronometragem e Sinais de Alerta

A partir dos pontos-chaves do corpo definidos e capturados pelas bibliotecas *MediaPipe* e *OpenCV*, foram calculadas as distâncias (Equação 01),

$$D_{ab} = \sqrt{(x_b - x_a)^2 + (y_b - y_a)^2} \quad (\text{Equação 01})$$

no qual  $D_{ab}$  representa a distância entre dois pontos-chaves a e b;  $x_a$  e  $x_b$  representam as coordenadas dos pontos a e b, respectivamente, no eixo x no plano cartesiano; e  $y_a$  e  $y_b$  representam as coordenadas dos pontos a e b, respectivamente, no eixo y no plano cartesiano.

A Equação 01 foi calculada em tempo real à medida que o trabalhador se movimentava para realizar a sua atividade laboral. Para tanto, o algoritmo foi configurado a encontrar a distância entre os pontos conforme script, a seguir:

```
def findDistance(x1, y1, x2, y2):  
    dist = m.sqrt((x2-x1)**2+(y2-y1)**2)  
    return dist
```

Também foi definida uma função para calcular o ângulo adotado durante a flexão e extensão da cabeça e tronco (adotado como eixo de interesse ao eixo y). Este é o fator determinístico primário para a postura. Portanto, adotou-se a linha do pescoço conectada ao ombro e a região ocular, sendo o ombro como ponto pivô. Da mesma forma, a linha do tronco conecta-se ao quadril e ao ombro, onde o quadril é considerado o ponto pivô. Em síntese, um desalinhamento entre as linhas do ombro, região ocular e pescoço indicam inclinação da cabeça (flexão ou extensão), do mesmo modo que um desalinhamento entre a linha do ombro, tronco e quadril indicam inclinação de tronco (flexão ou extensão). Desse modo, tomando a linha do pescoço como exemplo, tem-se que os pontos são P1 (x1, y1) para o ombro, P2 (x2, y2) para a região ocular e P3 (x3, y3) um ponto no eixo vertical y e que passa por P1. Portanto, para P3 a coordenada x é a mesma de P1 e, como y3 é válido para todo y, vamos considerar y3 = 0 para simplificar. Então, para encontrar o ângulo interno de três pontos, adotamos uma abordagem de vetores. O ângulo entre dois vetores,  $\vec{P_{12}}$  e  $\vec{P_{13}}$ , é calculado pela Equação 02:

$$\theta = \arccos\left(\frac{\vec{P_{12}} \cdot \vec{P_{13}}}{|\vec{P_{12}}| \cdot |\vec{P_{13}}|}\right) \quad (\text{Equação 02})$$

Resolvendo para  $\theta$  (Equação 3), tem-se que,

$$\theta = \arccos\left(\frac{y_2 - y_1}{\sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}}\right) \quad (\text{Equação 03})$$

no qual  $\theta$  é ângulo entre os dois vetores quaisquer;  $\vec{P_{12}}$  e  $\vec{P_{13}}$  são os dois vetores quaisquer que geram o ângulo  $\theta$ ;

Diante do exposto, o código em *Python* foi programado de tal modo a calcular o ângulo em tempo real conforme o script, a seguir:

```
def findAngle(x1, y1, x2, y2):  
    theta = m.acos((y2 - y1) * (-y1) / (m.sqrt((x2 - x1)**2 + (y2 - y1)**2) * y1))  
    degree = int(180/m.pi) * theta  
    return degree
```

Como o pacote *MediaPipe* separa o vídeo em um conjunto de frames (um frame por segundo), foi possível calcular o ângulo de cada par de vetores gerado pelos pontos-chaves do corpo já citados para cada frame. Desse modo, para cada frame a postura foi classificada como “boa/good” ou “má/bad”. Sendo assim, o seguinte script foi desenvolvido,

```
good_time = (1/ fps) * good_frames  
bad_time = (1/ fps) * bad_frames
```

de tal modo que, *fps* (frames por segundo) é a taxa de quadros por segundo da reprodução; *good\_frames* é o número de quadros em “boa postura” da reprodução; e *bad\_frames* é o número de quadros de “má postura” do vídeo. Vale salientar que, a linha do script *good\_time* calculou o tempo de reprodução em “boa postura” dividindo o número total de quadros “boa” pela taxa de quadros por segundo. A linha do script *bad\_time* calculou o mesmo para o tempo de reprodução “má postura”.

Quantificados então o tempo em “má” ou “boa” postura, é possível gerar um feedback em tempo real. Por exemplo, pode-se configurar o script, a seguir, para que, diante de uma situação no qual o trabalhador adote uma má postura por tempo superior a 180 segundos, seja emitido um alerta visual, sonoro ou ambos

```
if bad_time > 180:  
    sendWarning()
```

Devido as limitações de páginas desse evento, não se pode explicitar com maiores detalhes todo o código de programação em *Python*. Contudo, o mesmo pode ser acessado pelo seguinte endereço:<<https://pastebin.com/zdXj2yDs>>.

### 3. RESULTADOS E DISCUSSÕES

Os resultados foram apresentados e discutidos numa única seção. Tal escolha dos autores se deu para atendimento das normas de publicação do evento.

#### 3.1 Avaliação das posturas

Inicialmente, buscou-se fazer a avaliação das posturas. É possível observar que o algoritmo de IA captou bem a posição do ombro (ponto rosa) dos trabalhadores (Figura 1), sendo, portanto, a referência para o cálculo dos demais pontos relacionados a cabeça, coluna vertebral e quadril (pontos em amarelo), além das distâncias (linhas em verde). Os ângulos também foram determinados a partir dos pontos pré-determinados.

Figura 1: Exemplo de aplicação do algoritmo de IA em uma situação real de trabalho



Fonte: AUTORES (2023).

É possível observar que o algoritmo de IA sugere que, em relação a coluna vertebral, a cabeça está inclinada em 19 graus, configurando uma situação sem risco postural. Métodos de análise posturais clássicos em ergonomia, como o REBA (HIGNETT & MCATAMNEY, 2000), adicionam pontuação de risco para inclinações de cabeça/pescoço (flexão) superiores a 20 graus.

A Figura 2, ilustra duas situações de risco postural (2A e 2B) captadas pelo algoritmo de IA. Ficaram evidenciadas inclinações de tronco (coluna vertebral) igual a 39 graus e 71 graus, respectivamente. Métodos como o REBA (HIGNETT & MCATAMNEY, 2000) e RULA (MCATAMNEY & CORLETT, 1993) determinam que flexão de tronco entre 20 e 60 graus configuram situação de risco próximo ao máximo. Também é possível verificar uma inclinação de 57 graus e 115 graus para a cabeça em relação ao tronco. Os mesmos métodos concordam que uma flexão superior a 20 graus configura situação de risco postural grave.

Figura 2: Situação de risco captada pelo algoritmo de IA



Fonte: AUTORES (2023).

Desse modo, ao captar situação de risco algumas informações passam a ser apresentadas em coloração vermelha, inclusive as linhas que formam a esqueletização. Por outro lado, a adoção de uma má postura por um tempo pequeno não configura, necessariamente, situação de risco. Já a manutenção de uma má postura por um tempo elevado (ou repetidamente em diversos momentos da jornada de trabalho) eleva o risco de sintomas osteomusculares (SOUZA et al., 2021; LIMA DA SILVA et al., 2022).

Desse modo, faz-se necessário compreender também o processo de cronometragem ou contagem de tempo em determinada postura, assim como os sinais de alerta que podem ser gerados como feedback para os trabalhadores.

### 3.2 Da Cronometragem e Sinais de Alerta

Ao manter uma correta postura (status igual a ‘Good Posture Time’) as linhas se mantem em verde, e o cronometro passa a medir a quantidade de tempo na condição de boa postura (Figura 3A). Como descrito, anteriormente, a adoção de má postura repercute em uma mudança na esqueletização, trazendo elementos na cor em vermelho. Em paralelo, existe a mudança de status ‘Good Posture Time’ para o status ‘Bad Posture Time’ (Figura 3B).

Figura 3: Exemplificação da cronometragem das condições de má e boa postura



Fonte: AUTORES (2023).

As Figuras 3A e 3B, apresentam os *status* de ‘Good Posture Time’ e ‘Bad Posture Time’ como tempo igual a 0,4 segundos e 2,9 segundos, respectivamente. Diante do exposto, o algoritmo ainda fornecesse a possibilidade de gerar um alerta sonoro (qualquer áudio em formato .mp3) ou sinal luminoso (impulso elétrico sob um led ou Kanban) para um tempo pré-programado. O tempo em cada postura é calculado, armazenado e tabulado, inclusive com seu *status*. Sendo algo relevante para a adoção de planos de correção postural, treinamentos e análises de tempos em determinadas posturas.

### 3.3 Avaliação das Posturas em Situação de Trabalho

A Tabela 1, resume os resultados encontrados através do uso do algoritmo de IA utilizado para três atividades analisadas. Desse modo, é possível verificar que, em média, os vídeos analisados tinham 12 minutos e 35 segundos de duração. As atividades laborais de aplicação de argamassa sobre andaime e de pianista foram as que apresentaram maior e menor tempo total de manutenção em uma má postura (83,29% e 34,21%, respectivamente). Também é possível observar que a atividade laboral de aplicação de argamassa no solo foi a que exigiu o maior tempo mantendo em uma má postura, com valores de 4 minutos e 17 segundos. Em média, as atividades laborais exigiram a manutenção de uma má postura por 6 minutos e 77 segundos. Isso implica que, em média, 61,09% do tempo dos vídeos os trabalhadores adotaram uma postura de risco osteomuscular.

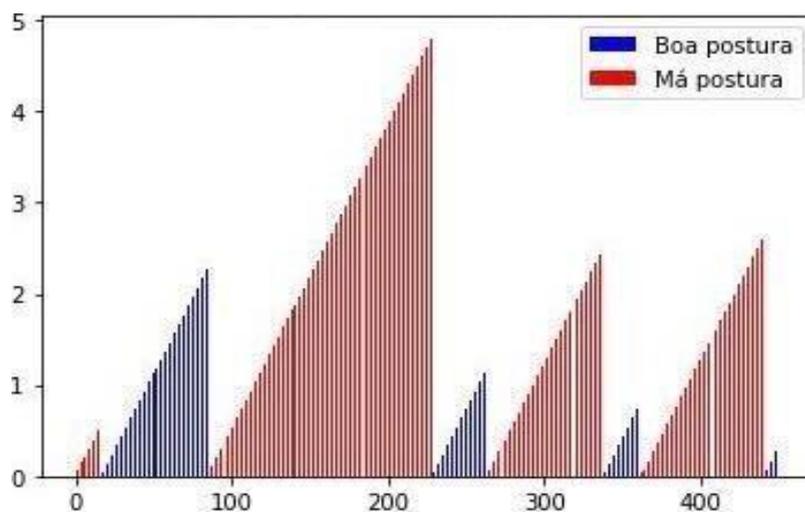
Tabela 1: Síntese dos valores gerados pelo algoritmo de IA.

CONDIÇÃO ANALISADA	DURAÇÃO DO VÍDEO (em minutos)	TEMPOS EM BOA POTURA (em minutos)			TEMPO EM MÁ POSTURA (em minutos)		
	VALOR	VALOR	%	MÁXIMO	VALOR	%	MÁXIMO
Argamassa sobre andaime	11,07	1,85	16,71	0,60	9,22	83,29	3,17
Argamassa no solo	6,95	2,38	34,24	0,58	4,57	65,76	4,17
Pianista	19,03	12,52	65,79	0,53	6,51	34,21	0,48
<b>MÉDIA</b>	12,35	5,58	38,91	0,57	6,77	61,09	2,61

Fonte: AUTORES (2023).

A partir dos tempos calculados pelo algoritmo de IA é possível analisar graficamente o comportamento postural do trabalhador (Figura 4). Essa figura apresenta a alternância de boa e má postura adotadas pelo trabalhador durante o trabalho de aplicação de argamassa sobre um andaime, de tal modo que existe um maior número de frames em má postura próximo a 100 e após 200 segundos do vídeo.

Figura 4: Gráfico dos tempos em boa e má postura na atividade de aplicação de argamassa sobre andaime



Fonte: AUTORES (2023).

#### 4. CONCLUSÕES

Conclui-se que o algoritmo de IA idealizado identificou e classificou a postura corporal de trabalhadores das três diferentes estações de trabalho analisadas. O algoritmo de IA mensurou de forma satisfatória os tempos que os trabalhadores permaneceram em más e boas posturas. Ao medir os tempos de forma correta é possível gerar um feedback em tempo real aos trabalhadores, evitando a manutenção de posturas desconfortáveis, reduzindo o risco de distúrbios osteomusculares relacionados ao trabalho.

Contudo, algumas limitações podem ser apresentadas. A primeira delas foi o uso de vídeos curtos e extraídos da internet. Situações reais de trabalho em tempo real podem apresentar posturas complexas que podem ser avaliadas pelo algoritmo de IA com maior dificuldade e menor precisão. A segunda limitação está associada a análise da postura apenas ocorrer de forma lateral. Condições de trabalho que demandem rotação de tronco, por exemplo, que é uma situação de risco ocupacional grave, não podem ser captadas pelo algoritmo proposto, dado que seria necessário uma análise na vista frontal ou traseira do trabalhador, demandando uma maior quantidade de pontos-chaves e operações trigonométricas. A terceira limitação está no não atendimento de todas as regras propostas por métodos como REBA, RULA e OWAS, por exemplo.

Desse modo, estudos futuros podem avaliar a postura do trabalhador de forma frontal e lateral em situações reais de trabalho. Também podem proceder com a uma avaliação mais completa e simultânea com base nos diferentes métodos de avaliação postural, a exemplo do REBA, RULA e OWAS. Ao fazer a avaliação do risco por esses métodos ergonômicos é natural encontrar condições de risco conflitantes. Desse modo, um método pode indicar risco e outro ausência de risco. Nesse cenário a pior situação de risco ergonômico é aquela considerada nas avaliações ocupacionais, algo que poderia ser avaliado de forma simultânea pelo algoritmo de IA.

#### REFERÊNCIAS BIBLIOGRÁFICAS

ASSUNÇÃO, E.; GASPAR, P.D.; ALIBABAEI, K.; SIMÕES, M.P.; PROENÇA, H.; SOARES, V.N.G.J.; CALDEIRA, J.M.L.P. “*Real-Time Image Detection for Edge Devices: A Peach Fruit Detection Application*”. *Future Internet*, v. 14, n. 11, p. 323, 8 nov. 2022.

BISPO, L. G. M.; MORENO, C. F.; SILVA, G. H. DE O.; ALBUQUERQUE, N. L. B. DE; SILVA, J. M. N. DA. “*Risk factors for work-related musculoskeletal disorders: A study in the inner regions of Alagoas and Bahia*”. *Safety Science*, v. 153, p. 105804, set. 2022.

BRADSKI, G. “*The OpenCV library*”. *Dr. Dobb’s Journal: Software Tools for the Professional Programmer*, v. 25, p. 120–126, 2000.

DE ARAÚJO VIEIRA, E. M.; DA SILVA, J. M. N.; LEITE, W. K. D. S.; LUCAS, R. E. C.; DA SILVA, L.B. “*Team Workload and Performance of Healthcare Workers with Musculoskeletal Symptoms*”. *International Journal of Environmental Research and Public Health*, v. 20, n. 1, p. 742, 31 dez. 2022.

GARG, S.; SAXENA, A.; GUPTA, R. “Yoga pose classification: a CNN and MediaPipe inspired deep learning approach for real-world application”. *Journal of Ambient Intelligence and Humanized Computing*, 3 jun. 2022.

HIGNETT, S.; MCATAMNEY, L. “Rapid Entire Body Assessment (REBA)”. *Applied Ergonomics*, v. 31, n. 2, p. 201–205, abr. 2000.

KARHU, O.; KANSI, P.; KUORINKA, I. “Correcting working postures in industry: A practical method for analysis”. *Applied Ergonomics*, v. 8, n. 4, p. 199–201, dez. 1977.

LAMAS, A.; TABIK, S.; MONTES, A. C.; PÉREZ-HERNÁNDEZ, F.; GARCÍA, J.; OLMOS, R. “Human pose estimation for mitigating false negatives in weapon detection in video-surveillance”. *Neurocomputing*, v. 489, p. 488–503, jun. 2022.

LEITE, W. K. D. S.; ARAÚJO, A. J. D. S.; DA SILVA, L. B.; DE SOUZA, E. L.; SILVA, J. M. N. D.; BOLIS, I.; SILVA, M. P. O. E.; NEVES, R. D. F.; COLAÇO, G. A. “Sickness absence from work in the footwear industry: A longitudinal study”. *Work*, v. 72, n. 2, p. 431–451, 21 jun. 2022.

LIMA DA SILVA, I.; MACHADO DE SOUZA, E. R.; KARINE DIAS SILVA, L.; CLAUDINO DA SILVA, A. T.; NORTE DA SILVA, J. M. “Effects of multiple risk factors on upper limb musculoskeletal disorders among workers in inner Brazil”. *Work*, v. 72, n. 3, p. 885–900, 15 jul. 2022.

LIND, C. M.; DIAZ-OLIVARES, J. A.; LINDECRANTZ, K.; EKLUND, J. “A Wearable Sensor System for Physical Ergonomics Interventions Using Haptic Feedback”. *Sensors*, v. 20, n. 21, p. 6010, 23 out. 2020.

LUGARESI, C.; TANG, J.; NASH, H.; MCCLANAHAN, C.; UBOWEJA, E.; HAYS, M.; ZHANG, F.; CHANG, C.-L.; YONG, M.G.; LEE, J. *MediaPipe: A Framework for Building Perception Pipelines*. 14 jun. 2019.

MCATAMNEY, L.; NIGEL CORLETT, E. “RULA: a survey method for the investigation of work-related upper limb disorders”. *Applied Ergonomics*, v. 24, n. 2, p. 91–99, abr. 1993.

SOUZA, D. S. F. D.; SILVA, J. M. N. D.; SANTOS, J. V. D. O.; ALCANTARA, M. S. B.; TORRES, M. G. L. “Influence of risk factors associated with musculoskeletal disorders on an inner population of northeastern Brazil”. *International Journal of Industrial Ergonomics*, v. 86, 1 nov. 2021.

ZENG, N.; WU, P.; WANG, Z.; HAN, L.; LIU, W.; LIU, X. “A Small-Sized Object Detection Oriented Multi-Scale Feature Fusion Approach With Application to Defect Detection”. *IEEE Transactions on Instrumentation and Measurement*, v. 71, p. 1–14, 2022.