

Detección automática de posturas de riesgo en análisis ergonómico basada en landmarks anatómicos.

Jorge A Orozco-Torres¹; Gilbert F Pérez-García¹; Itzel Elvira Juárez-Martínez¹; Héctor R Hernández-De León;
Jorge A Mijangos-López¹; Oscar J Rincón-Zapata

¹Tecnológico Nacional de México/I. T. de Tuxtla Gutiérrez, Tuxtla Gutiérrez, Chiapas, México. Autor responsable:

Área: Informática e Inteligencia Artificial.

Resumen

En entornos laborales, los trastornos musculoesqueléticos (TME) continúan siendo una causa relevante de ausentismo, disminución de la productividad y afectaciones a la salud ocupacional. Una parte importante de estos problemas se asocia con posturas forzadas, movimientos repetitivos y manipulación inadecuada de cargas, cuya identificación oportuna suele depender de evaluaciones observacionales discontinuas o sujetas al criterio del evaluador.

En este contexto, el presente trabajo desarrolla un sistema de visión artificial para la detección de posturas de riesgo orientado al análisis ergonómico. La propuesta emplea MediaPipe como base para la detección de landmarks anatómicos y para la estimación de ángulos articulares relacionados principalmente con cuello y tronco. A partir de estas variables, el sistema clasifica posturas potencialmente riesgosas mediante criterios inspirados en los métodos RULA y REBA. Para fortalecer la validación, se construyó un conjunto de evaluación a partir de frames extraídos de videos de casos ergonómicos laborales.

Los resultados permitieron cuantificar el desempeño del sistema en la detección de riesgo postural. En la comparación global, el algoritmo alcanzó una exactitud de 0.7234, precisión de 0.7667, sensibilidad de 0.7931 y valor F1 de 0.7797. En la evaluación por segmento, la detección de cuello mostró un desempeño

intermedio, mientras que la detección de tronco presentó alta precisión, pero menor sensibilidad, lo que evidencia mayor dificultad para recuperar todos los casos positivos de flexión troncal.

Palabras clave: Ergonomía industrial; visión artificial; análisis postural; MediaPipe; riesgo postural; evaluación cuantitativa.

Abstract

In occupational environments, musculoskeletal disorders (MSDs) remain a significant cause of absenteeism, reduced productivity, and adverse effects on occupational health. A substantial portion of these problems is associated with awkward postures, repetitive movements, and improper manual handling of loads, whose timely identification often depends on observational assessments that are discontinuous or subject to the evaluator's judgment.

In this context, the present work develops a computer vision system for detecting risk postures aimed at ergonomic analysis. The proposal employs MediaPipe as the basis for detecting anatomical landmarks and estimating joint angles mainly related to the neck and trunk. Based on these variables, the system classifies potentially risky postures using criteria inspired by the RULA and REBA methods. To strengthen validation, an evaluation set was built from frames extracted from videos of occupational ergonomic cases.

The results made it possible to quantify the system's performance in postural risk detection. In the overall comparison, the algorithm achieved an accuracy of 0.7234, a precision of 0.7667, a recall of 0.7931, and an F1-score of 0.7797. In the segment-level evaluation, neck detection showed intermediate performance, whereas trunk detection achieved high precision but lower recall, indicating greater difficulty in recovering all positive cases of trunk flexion.

Keywords: Industrial ergonomics; computer vision; postural analysis; MediaPipe; postural risk; quantitative evaluation.

Introducción

La ergonomía industrial busca identificar y reducir condiciones de trabajo que favorecen la aparición de trastornos musculoesqueléticos (TME), los cuales suelen asociarse con posturas forzadas, movimientos repetitivos y manipulación inadecuada de cargas. En este contexto, la evaluación postural constituye un componente clave para la prevención ergonómica. Métodos observacionales como RULA y REBA han sido ampliamente utilizados para valorar cuello, tronco y extremidades superiores en tareas laborales, debido a su utilidad práctica para estimar el nivel de riesgo postural (Hignett & McAtamney, 2000; McAtamney & Corlett, 1993).

Sin embargo, estos métodos presentan limitaciones cuando se aplican exclusivamente mediante observación humana. Su interpretación puede depender del criterio del evaluador y su uso suele concentrarse en momentos puntuales, lo que dificulta la vigilancia continua de tareas dinámicas o repetitivas. Por ello, en años recientes la visión artificial ha cobrado relevancia como alternativa tecnológica para el análisis automatizado de la postura humana, al

permitir la estimación de puntos anatómicos a partir de imágenes digitales sin necesidad de sensores invasivos (Agostinelli et al., 2024).

Dentro de este campo, soluciones como BlazePose y MediaPipe Hands permiten detectar landmarks corporales y manuales en tiempo real, facilitando la construcción de representaciones digitales del cuerpo humano a partir de las cuales pueden calcularse variables biomecánicas de interés ergonómico (Bazarevsky et al., 2020; Zhang et al., 2020). En los entornos laborales persiste la necesidad de contar con sistemas no invasivos y de bajo costo relativo que permitan detectar condiciones de riesgo postural con retroalimentación rápida, pero cuya utilidad depende de que la información visual pueda traducirse en indicadores interpretables y contrastables (Agostinelli et al., 2024; Hignett & McAtamney, 2000).

Con base en ello, el presente trabajo propone un sistema de visión artificial para análisis postural, apoyado en MediaPipe, con el fin de estimar landmarks anatómicos y calcular ángulos articulares relacionados principalmente con cuello y tronco. A partir de estas variables, el sistema clasifica posturas potencialmente riesgosas mediante criterios inspirados en RULA y REBA. Además de la implementación computacional, el estudio incorpora una evaluación cuantitativa sobre un conjunto de imágenes construido a partir de frames extraídos de videos de casos ergonómicos laborales, seleccionados por representar posturas con y sin riesgo visible bajo criterios ergonómicos definidos en la investigación.

El aporte principal radica en integrar una arquitectura funcional de monitoreo postural y someterla a una primera evaluación cuantitativa sobre material visual derivado de casos laborales. De esta manera, la contribución se sitúa en una validación inicial del

desempeño del algoritmo y constituye una base metodológica para estudios posteriores con usuarios reales y contraste directo con especialistas en ergonomía.

Fundamentos teóricos

La evaluación ergonómica postural se apoya con frecuencia en métodos observacionales que permiten estimar el nivel de riesgo biomecánico a partir de la postura adoptada por el trabajador. Entre los más utilizados se encuentran RULA (Rapid Upper Limb Assessment) y REBA (Rapid Entire Body Assessment). El método RULA fue propuesto para analizar principalmente cuello, tronco y extremidades superiores en tareas donde predominan posturas sostenidas o repetitivas del miembro superior, mientras que REBA amplía la valoración al cuerpo completo y resulta especialmente útil en actividades con manipulación de cargas y cambios posturales más amplios (Hignett & McAtamney, 2000; McAtamney & Corlett, 1993).

Ambos métodos comparten una lógica central: transformar la observación postural en una estimación estructurada del riesgo ergonómico. Desde el punto de vista computacional, la visión artificial permite automatizar parcialmente esta observación mediante el uso de cámaras RGB y modelos de estimación anatómica. En particular, BlazePose y las soluciones de MediaPipe permiten detectar landmarks corporales en tiempo real y construir una representación geométrica del cuerpo a partir de puntos clave anatómicos. De forma complementaria, MediaPipe Hands posibilita el seguimiento de landmarks manuales, lo que amplía el análisis cuando la tarea requiere estudiar segmentos distales o interacción con objetos (Bazarevsky et al., 2020; Zhang et al., 2020).

A partir de estos landmarks es posible derivar variables biomecánicas cuantificables, especialmente ángulos articulares. La formulación general para estimar el ángulo entre tres puntos anatómicos a, b y c es:

$$\theta = \cos^{-1}\left(\frac{(a-b)(c-b)}{\|a-b\|\|c-b\|}\right)$$

donde b representa el vértice del ángulo y a y c corresponden a los puntos adyacentes. Esta expresión permite transformar la postura visible en medidas geométricas objetivas a partir de coordenadas anatómicas detectadas en la imagen.

En el sistema propuesto, el análisis se centra en la estimación angular del tronco y del segmento cefálico-cervical. Conceptualmente, el ángulo del tronco puede interpretarse como la desviación del segmento formado entre la cadera media y el hombro medio con respecto a una referencia vertical, mientras que el ángulo del cuello puede entenderse como la desviación del segmento cabeza-cuello respecto al eje del tronco. Estas relaciones permiten traducir la postura observada en variables funcionales útiles para clasificación postural. Cuando los ángulos calculados superan umbrales definidos con base en criterios ergonómicos inspirados en RULA y REBA, la postura puede clasificarse como potencialmente riesgosa. Así, la combinación entre landmarks anatómicos, cálculo angular y reglas de decisión constituye la base teórica que enlaza la visión artificial con la evaluación postural automatizada.

En este sentido, la incorporación de métricas como exactitud, precisión, sensibilidad, especificidad y F1-score resulta necesaria para valorar objetivamente el comportamiento del algoritmo y no limitarlo a una demostración visual.

Materiales y métodos

Materiales

En la Tabla 1 se resumen los recursos utilizados para el desarrollo y evaluación del sistema. La validación del sistema se realizó sobre imágenes derivadas de videos de casos ergonómicos laborales.

Tabla 1. Características de los componentes del sistema propuesto (elaboración propia).

Componente	Descripción
Dataset	64 imágenes seleccionadas frame por frame: 39 con riesgo visible y 25 sin riesgo visible
Procesador PC/MCU	Raspberry Pi 5, Broadcom BCM2712, CPU ARM Cortex-A76 de 4 núcleos a 2.4 GHz

Los videos constituyeron la fuente original del material visual, mientras que el conjunto de imágenes curadas se obtuvo mediante revisión individual de frames con visibilidad suficiente de cuello, tronco y postura general. Desde el punto de vista computacional, el sistema se desarrolló en Python, utilizando OpenCV para el preprocesamiento de imágenes y MediaPipe Pose Landmarker para la detección anatómica.

Como material de evaluación, se construyó un conjunto de imágenes a partir de una lista pública de reproducción en YouTube dedicada a casos ergonómicos laborales. De esos videos se seleccionaron escenas con visibilidad suficiente de cuello, tronco y postura general, utilizadas posteriormente para contrastar las salidas del algoritmo frente a una referencia de clasificación basada en criterios ergonómicos visibles.

Metodología

La metodología del estudio se estructuró en etapas sucesivas, desde la adquisición de imagen hasta la evaluación cuantitativa del desempeño del sistema.

Etapas 1. Revisión del material visual y selección de frames

Como parte del proceso de validación, se empleó una lista pública de reproducción en YouTube compuesta por casos ergonómicos laborales. Los videos fueron revisados frame por frame con el fin de identificar escenas útiles para el análisis postural. Los criterios de selección consideraron: visibilidad suficiente del cuerpo, observabilidad del eje cabeza-cuello-tronco, claridad de la postura en el instante seleccionado y calidad visual adecuada para detección anatómica. Los criterios de exclusión incluyeron desenfoco excesivo, postura frontal poco interpretable, oclusión importante y repetición innecesaria de la misma maniobra. Como resultado de esta curación se reunió un conjunto inicial de 64 imágenes, de las cuales 39 correspondieron a posturas con riesgo visible y 25 a posturas sin riesgo visible. Este conjunto constituyó la base para la evaluación posterior del sistema.

Etapas 2. Construcción del CSV de referencia ergonómica

Una vez seleccionadas las imágenes, se construyó una tabla de referencia a partir de la observación de cada frame. En esta etapa, cada imagen fue evaluada de manera individual y se registraron variables de referencia como riesgo global, riesgo en tronco, riesgo en cuello, riesgo en extremidad superior, severidad cualitativa, calidad de visibilidad y una nota técnica breve. De esta manera, el CSV maestro se convirtió en una referencia ergonómica construida manualmente a partir de la observación sistemática de los frames seleccionados.

Etapas 3. Preprocesamiento y detección anatómica

El análisis automático de las imágenes se implementó en Python, utilizando OpenCV para la lectura, redimensionamiento y conversión de color, y MediaPipe para la detección anatómica. En particular, el sistema empleó Pose Landmarker como base para la

estimación corporal, dentro de una arquitectura compatible con el framework de MediaPipe. Esta integración permitió obtener landmarks anatómicos a partir de imágenes RGB y construir una representación geométrica del cuerpo humano. A partir de los landmarks detectados, el sistema generó puntos derivados de interés ergonómico, principalmente la cadera media, el hombro medio y una referencia cefálica estimada a partir de nariz y orejas. Estos puntos sirvieron como base para el cálculo angular. La Figura 2 muestra la topología de puntos de articulación estimada por el framework de MediaPipe.




Figura 1. Topología de puntos de articulación (33 landmarks) (elaboración propia).

Etap 4. Medición angular y programación de criterios ergonómicos

El sistema calculó automáticamente el ángulo de tronco y el ángulo de cuello a partir de relaciones geométricas entre landmarks anatómicos. El ángulo de tronco se interpretó como la desviación del segmento cadera media-hombro medio respecto a una referencia vertical, mientras que el ángulo de cuello se interpretó como la desviación del segmento cefálico respecto al eje del tronco.

Para esta etapa los umbrales se definieron: 30° para el tronco, lo que marcaba el límite a partir del cual se consideraba una desviación significativa en la postura.

Para el cuello, se fijó en 20°, dado que esta zona requiere mayor precisión por su sensibilidad y movilidad. Finalmente, se determinó que la visibilidad mínima aceptable de los landmarks debía ser de 0.50. Con base en estos criterios, el sistema generó tres salidas por imagen: riesgo en tronco, riesgo en cuello y riesgo global, considerándose este último como positivo cuando al menos uno de los dos segmentos principales fue clasificado como riesgoso. En la tabla 2 se observan los principales módulos utilizados en el algoritmo propuesto.

Tabla 2. Módulos utilizados en el algoritmo propuesto (elaboración propia).

Módulo / Componente	Función
MediaPipe Pose	Detectar puntos articulares del cuerpo (33 landmarks)
MediaPipe Hands	Detectar puntos de las manos (21 landmarks)
MediaPipe Face Mesh	Detectar puntos faciales 3D (468 landmarks)
Cálculo de ángulos	Ángulos biomecánicos (tronco, cuello, brazos, piernas) en cada frame.
Evaluación ergonómica	Comparar ángulos con criterios REBA/RULA; determinar si la postura es riesgosa.

Etap 5. Generación del CSV del algoritmo

El algoritmo generó una tabla que concentró la información de todas las imágenes analizadas. En dicho archivo se registraron variables como nombre de imagen, ruta, carpeta de origen, visibilidad mínima, ángulo de tronco, ángulo de cuello, predicción binaria por segmento, predicción global, umbrales utilizados y estatus del procesamiento, esto a partir de la medición angular y de reglas programadas con los criterios de rula/reba, los mismos utilizados para generar la tabla de referencia.

Etapas 6. Comparación cuantitativa

La comparación cuantitativa se realizó sobre aquellas imágenes presentes en ambos conjuntos y con valores válidos para la comparación. A partir de este cruce, la evaluación efectiva se realizó sobre 47 imágenes. La comparación se efectuó en tres niveles: clasificación global; clasificación de riesgo en tronco; clasificación de riesgo en cuello. A partir de la matriz de confusión se calcularon métricas de desempeño como exactitud, precisión, sensibilidad, especificidad, F1-score y tasa de error, con el fin de valorar cuantitativamente el comportamiento del sistema frente a la referencia ergonómica construida.

Resultados y discusión

Los resultados obtenidos en este trabajo corresponden a una evaluación cuantitativa inicial del algoritmo sobre imágenes derivadas de videos de casos ergonómicos laborales. En esta etapa el análisis se realizó sobre un conjunto curado de 64 imágenes, seleccionadas frame por frame, de las cuales 39 correspondieron a posturas con riesgo visible y 25 a posturas sin riesgo visible. Posteriormente, el algoritmo generó un archivo maestro con 63 registros, y la comparación efectiva entre la referencia ergonómica y las salidas automáticas se realizó sobre 47 imágenes válidas, es decir, aquellas presentes en ambos conjuntos y con valores utilizables para la comparación cuantitativa.

En la comparación global, el algoritmo alcanzó una exactitud (A) de 0.7234, una precisión (B) de 0.7667, una sensibilidad (C) de 0.7931, una especificidad de 0.6111 (D) y un valor F1-Score (E) de 0.7797. En términos absolutos, estos resultados correspondieron a 23 verdaderos positivos, 11 verdaderos negativos, 7 falsos positivos y 6 falsos negativos. En conjunto, estos

valores indican que el sistema presentó un comportamiento favorable para identificar posturas clasificadas como riesgosas, con mejor capacidad para recuperar casos positivos que para descartar completamente algunos casos sin riesgo. En la tabla 3 se muestran las métricas de desempeño del algoritmo resultantes de la comparación con la referencia.

Tabla 3. Métricas de desempeño resultantes (elaboración propia).

Nivel de evaluación	A	B	C	D	E
Global	0.723	0.766	0.793	0.611	0.779
Tronco	0.638	1.000	0.346	1.000	0.514
Cuello	0.659	0.740	0.689	0.611	0.714

La evaluación por segmentos mostró diferencias importantes entre el comportamiento del sistema para tronco y para cuello. En el caso del tronco, el algoritmo alcanzó una exactitud de 0.6383, con precisión de 1.0000, sensibilidad de 0.3462, especificidad de 1.0000 y F1-score de 0.5143. Este resultado indica que, cuando el sistema clasificó una postura como riesgosa para tronco, dicha clasificación coincidió con la referencia; sin embargo, su capacidad para recuperar todos los casos positivos de flexión troncal fue limitada.

En el caso del cuello, el algoritmo mostró una exactitud de 0.6596, con precisión de 0.7407, sensibilidad de 0.6897, especificidad de 0.6111 y F1-score de 0.7143. En comparación con el tronco, el desempeño en cuello fue más equilibrado, aunque con menor especificidad. Esto sugiere que la geometría empleada para detectar desviaciones cervicales permitió reconocer un mayor número de casos positivos, pero también produjo algunas clasificaciones de riesgo en posturas que la referencia manual consideró cercanas a neutras.

Comportamiento angular de las imágenes analizadas

El análisis de los ángulos registrados también permitió observar una separación entre imágenes con riesgo y sin riesgo. En las imágenes etiquetadas como riesgo dentro de la comparación válida, el promedio del ángulo de tronco fue de 34.01° , mientras que el promedio del ángulo de cuello fue de 31.81° . En contraste, para las imágenes clasificadas como sin riesgo, los promedios fueron de 8.52° para tronco y 19.31° para cuello. Esta diferencia confirma que la medición angular obtenida por el algoritmo mantiene relación con la clasificación ergonómica de referencia.

Asimismo, al considerar las imágenes clasificadas por el propio algoritmo, el grupo marcado como riesgoso presentó promedios de 33.75° en tronco y 36.08° en cuello, mientras que el grupo clasificado como no riesgoso presentó promedios de 7.47° y 11.03° , respectivamente. Este patrón refuerza la consistencia interna del sistema, ya que las predicciones de riesgo tienden a concentrarse en configuraciones con desviaciones angulares mayores.

Casos representativos de clasificación

Con el fin de ilustrar el comportamiento del algoritmo sobre ejemplos significativos del conjunto evaluado, se seleccionaron cuatro imágenes representativas: dos verdaderos positivos, un verdadero negativo y un falso negativo.

Caso 1. Verdadero positivo con flexión combinada de tronco y cuello

En la Figura 2 se observa una postura con flexión marcada de tronco y desviación cervical visible, correctamente clasificada como riesgosa tanto por la referencia ergonómica como por el algoritmo. Este caso es representativo porque muestra una

configuración postural claramente desfavorable, donde las dos variables principales del sistema contribuyen simultáneamente a la clasificación positiva.



Figura 2. Caso de verdadero positivo con flexión combinada de tronco y cuello correctamente identificado por el algoritmo.

Caso 2. Verdadero positivo con predominio cervical

La Figura 3 muestra una postura en la que el componente cervical domina la condición de riesgo. En este ejemplo, el sistema reconoce correctamente una desviación importante del cuello y genera una clasificación positiva consistente con la referencia. Este caso es útil porque ayuda a explicar por qué el algoritmo presentó un desempeño relativamente más equilibrado en cuello que en tronco.

Caso 3. Verdadero negativo

La Figura 4 recomendada corresponde a una postura cercana a neutra, clasificada como sin riesgo tanto por la referencia como por el algoritmo. Este caso es importante porque demuestra que el sistema no sólo detecta configuraciones desfavorables, sino que también puede reconocer posturas relativamente alineadas cuando los valores angulares se mantienen dentro de los rangos programados.




Figura 3. Caso de verdadero positivo con predominio de riesgo cervical correctamente identificado por el algoritmo.



Figura 4. Caso de verdadero negativo, correspondiente a una postura sin riesgo visible correctamente clasificada por el algoritmo.

Caso 4. Falso negativo

La Figura 5 sugerida muestra una discrepancia entre la referencia y la clasificación automática. En este caso, la postura fue etiquetada como riesgosa en la referencia ergonómica, pero el algoritmo no la recuperó como positiva. Este comportamiento ayuda a explicar la baja sensibilidad observada en el segmento de tronco, ya que algunas posturas desfavorables no son reconocidas con éxito.



Figura 5. Caso de falso negativo: postura clasificada como riesgosa en la referencia, pero no recuperada por el algoritmo debido a que no superó los umbrales programados.

Los aciertos del sistema fueron más evidentes en posturas con flexión pronunciada de tronco, proyección anterior del cuello o combinación de ambos factores. En estos casos, la geometría construida a partir de cadera media, hombro medio y referencia cefálica permitió discriminar de forma consistente configuraciones de riesgo. Sin embargo, también se identificaron patrones de error que ayudan a interpretar las limitaciones actuales del algoritmo.

Por una parte, algunos falsos negativos ocurrieron en posturas donde la referencia consideró riesgo visible, pero los ángulos medidos no superaron los umbrales establecidos. Esto se observó particularmente en tareas con manipulación de carga, empuje o movimientos repetitivos, donde la postura desfavorable no siempre se expresó como una flexión geométrica suficientemente grande en cuello o tronco. Por otra parte, algunos falsos positivos se presentaron en posturas de transición o recuperación, donde el algoritmo detectó desviaciones cervicales por encima del umbral, aunque la referencia manual las consideró funcionalmente cercanas a neutras.

Este comportamiento sugiere que el sistema responde mejor ante posturas claramente desfavorables que ante configuraciones intermedias, transitorias o parcialmente ocluidas. También confirma que el uso de umbrales inspirados en RULA y REBA constituye una aproximación útil para una validación inicial, aunque todavía simplificada frente a la complejidad postural presente en casos reales.

Conclusiones

En este estudio se plantea una propuesta de visión artificial orientada a la detección de posturas de riesgo con fines de análisis ergonómico. La metodología se apoya en la estimación de landmarks anatómicos mediante MediaPipe y en el cálculo de ángulos articulares, principalmente asociados al cuello y al tronco. Estos criterios se inspiran en los métodos RULA y REBA, adaptados para evaluar de manera automatizada las condiciones posturales.

El aporte principal del estudio consistió en someter el algoritmo a una evaluación cuantitativa inicial sobre un conjunto de imágenes derivado de videos de casos ergonómicos laborales, seleccionadas frame por frame y contrastadas contra una referencia ergonómica construida manualmente. En la comparación global, el sistema alcanzó una exactitud de 0.7234, una precisión de 0.7667, una sensibilidad de 0.7931 y un valor F1-score de 0.7797, lo que indica un desempeño favorable para la identificación de posturas clasificadas como riesgosas. El algoritmo mostró un comportamiento más equilibrado en cuello que en tronco, mientras que en el caso del tronco presentó alta precisión, pero baja sensibilidad, evidenciando dificultad para recuperar todos los casos positivos de flexión troncal.

Los resultados obtenidos permiten sostener que la combinación entre detección anatómica, medición angular y reglas de decisión inspiradas en RULA y REBA constituye una base técnicamente viable para el análisis postural asistido por visión artificial.

Como trabajo futuro, será necesario ampliar el tamaño y diversidad de la muestra, incorporar más segmentos anatómicos, refinar los criterios de decisión y contrastar las salidas del sistema con evaluaciones realizadas por especialistas en ergonomía.

Referencias bibliográficas

- Agostinelli, T., Generosi, A., Ceccacci, S., & Mengoni, M. (2024). Validation of computer vision-based ergonomic risk assessment tools for real manufacturing environments. *Scientific Reports*, 14, 27785.
- Bazarevsky, V., Grishchenko, I., Raveendran, K., Zhu, T., Zhang, F., & Grundmann, M. (2020). BlazePose: On-device real-time body pose tracking. *arXiv*.
- Hignett, S., & McAtamney, L. (2000). Rapid entire body assessment (REBA). *Applied Ergonomics*, 31(2), 201–205.
- McAtamney, L., & Corlett, E. N. (1993). RULA: A survey method for the investigation of work-related upper limb disorders. *Applied Ergonomics*, 24(2), 91–99.
- Zhang, F., Bazarevsky, V., Vakunov, A., Tkachenka, A., Sung, G., Chang, C.-L., & Grundmann, M. (2020). MediaPipe Hands: On-device real-time hand tracking. *arXiv*.