

Automating Ergonomic Evaluation in Harsh Environments: A Real-Time Computer Vision Framework for Underground Mining

Cesar Ciriaco-Martinez, M. Sc¹; Nelson Chambi Quiroz M. Sc²

^{1,2}Universidad Privada del Norte, Perú, cesar.ciriaco@upn.edu.pe, nelson.chambi@upn.pe

Abstract– Musculoskeletal disorders (MSDs) represent a critical problem in underground mining due to biomechanical demands and adverse environmental conditions. Traditional observational methods, such as RULA, are subjective and do not allow for continuous monitoring. This article proposes a real-time machine vision framework for automated ergonomic assessment in harsh mining environments. The methodology comprises: (i) a video acquisition protocol adapted to dusty conditions, poor lighting, and PPE occlusions; (ii) frame preprocessing and filtering using MediaPipe Pose; (iii) construction of a dataset labeled with RULA risk levels (Low, Medium, High) based on joint angles; and (iv) a custom convolutional neural network (CNN) for postural classification. The model was trained and validated with data from real mining operations, employing cross-validation and metrics for accuracy, completeness, and F1 score. The results demonstrate the system's viability in providing objective, continuous, and real-time assessments, overcoming the limitations of traditional methods and offering a scalable tool for the proactive prevention of musculoskeletal disorders in underground mining.

Keywords– Artificial Intelligence; Underground Mining; Ergonomic Assessment; Deep Learning; Musculoskeletal Disorders; Occupational Health and Safety.

Automatización de la evaluación ergonómica en entornos hostiles: un marco de visión artificial en tiempo real para la minería subterránea

Cesar Ciriaco-Martinez, M. Sc¹; Nelson Chambi Quiroz M. Sc²

^{1,2}Universidad Privada del Norte, Perú, cesar.ciriaco@upn.edu.pe, nelson.chambi@upn.pe

Resumen— Los trastornos musculoesqueléticos (TME) representan un problema crítico en minería subterránea debido a las exigencias biomecánicas y condiciones ambientales adversas. Los métodos observacionales tradicionales, como RULA, son subjetivos y no permiten una monitorización continua. Este artículo propone un marco de visión artificial en tiempo real para la evaluación ergonómica automatizada en entornos mineros hostiles. El estudio se desarrolló en una operación de minería subterránea ubicada en la región andina de Sudamérica, durante el periodo comprendido entre noviembre y diciembre de 2025, preservando la anonimización de la unidad minera por criterios de confidencialidad industrial. La metodología comprende: (i) un protocolo de adquisición de video adaptado a condiciones de polvo, iluminación deficiente y oclusiones por EPP; (ii) preprocesamiento y filtrado de fotogramas mediante MediaPipe Pose; (iii) construcción de un dataset etiquetado con niveles de riesgo RULA (Bajo, Medio, Alto) a partir de ángulos articulares; y (iv) una red neuronal convolucional (CNN) personalizada para clasificación postural. El modelo se entrenó y validó con datos de operaciones mineras reales, empleando validación cruzada y métricas de precisión, exhaustividad y F1-score. Los resultados demuestran la viabilidad del sistema para proporcionar evaluaciones objetivas, continuas y en tiempo real, superando las limitaciones de los métodos tradicionales y ofreciendo una herramienta escalable para la prevención proactiva de TME en minería subterránea.

Palabras clave— Inteligencia Artificial; Minería Subterránea; Evaluación Ergonómica; Aprendizaje Profundo; Trastornos Musculoesqueléticos; Seguridad y Salud Ocupacional.

I. INTRODUCCIÓN

La industria minera se distingue por imponer una de las mayores demandas biomecánicas a su fuerza laboral. La ejecución de tareas que requieren una aplicación sostenida de fuerza, la adopción de posturas forzadas y la presencia de ciclos de movimiento repetitivo constituyen factores de riesgo ampliamente documentados para el desarrollo de trastornos musculoesqueléticos (TME) de origen laboral. Estas patologías no solo comprometen la salud y la calidad de vida de los trabajadores mineros [1], sino que también generan un impacto económico significativo debido a la pérdida de productividad, el incremento del ausentismo y los costos asociados a la compensación de los trabajadores [2]. En particular, la operación prolongada de maquinaria pesada presenta una correlación significativa con la incidencia de patologías lumbares, un problema de alcance global que sitúa a los TME entre las principales causas de enfermedad profesional. Datos de la Agencia Europea para la Seguridad y

la Salud en el Trabajo corroboran que los trastornos de espalda y extremidades superiores atribuibles al trabajo representan una carga socioeconómica considerable, siendo la manipulación manual de cargas un factor contribuyente clave [3]. Esta evidencia subraya la necesidad crítica de implementar estrategias de evaluación proactivas que permitan cuantificar y mitigar estos riesgos en su origen.

La ergonomía ocupacional proporciona el marco disciplinario para analizar y optimizar la interacción entre el trabajador, su tarea y el entorno. En este contexto, la evaluación ergonómica se define como el procedimiento sistemático para identificar, cuantificar y controlar los factores de riesgo que pueden afectar el bienestar del trabajador y la eficiencia operativa [4]. En entornos industriales, las metodologías predominantes son de carácter observacional. Estas se basan en el análisis visual, directo o mediante grabaciones de video, de la actividad laboral, aplicando taxonomías estandarizadas como el Sistema de Análisis de Posturas de Trabajo de Ovako (Ovako Working Posture Analysing System, OWAS), la Evaluación Rápida de la Extremidad Superior (Rapid Upper Limb Assessment, RULA) o la Evaluación Rápida de Todo el Cuerpo (Rapid Entire Body Assessment, REBA). No obstante, la dependencia de la observación humana introduce limitaciones inherentes, tales como la subjetividad en la codificación postural, la variabilidad entre evaluadores, un consumo intensivo de tiempo y, fundamentalmente, la incapacidad para proporcionar un análisis continuo en tiempo real. Estas restricciones dificultan la identificación inmediata de riesgos y la implementación de correcciones dinámicas durante la jornada laboral.

Investigaciones recientes han explorado la integración de tecnologías digitales para superar estas barreras. Se han desarrollado enfoques híbridos que combinan herramientas clásicas como REBA con simulaciones estocásticas para modelar la exposición acumulativa a TME [5]. Paralelamente, principios de manufactura esbelta y filosofías de mejora continua (Kaizen) han sido adaptados para el rediseño de puestos de trabajo, logrando reducciones mensurables en la carga ergonómica [6, 7]. Asimismo, tecnologías inmersivas como la Realidad Aumentada (RA) han demostrado su utilidad como sistemas de guía y retroalimentación postural en entornos de fabricación [8, 9]. Sin embargo, una revisión crítica del estado del arte revela dos vacíos significativos que

motivan la presente investigación: (i) muchas de estas innovaciones tecnológicas no han sido específicamente adaptadas ni validadas para las condiciones operativas singulares, remotas y hostiles de la industria minera subterránea; y (ii) persiste la carencia de soluciones plenamente automatizadas que eliminen la dependencia del criterio humano experto para el diagnóstico ergonómico, limitando la escalabilidad, la objetividad y la capacidad de implementar sistemas de monitorización continua.

La transición hacia evaluaciones objetivas, automáticas y en tiempo real es actualmente viable gracias a los avances en visión por computadora y aprendizaje profundo. Su aplicación al análisis del movimiento humano, mediante la estimación precisa de la pose 2D/3D a partir de flujos de video, ofrece una vía prometedora para digitalizar y automatizar los protocolos de evaluación ergonómica clásicos. Este enfoque permite transformar evaluaciones puntuales y subjetivas en sistemas de monitorización continua, capaces de proporcionar retroalimentación inmediata y objetivos.

En consecuencia, el objetivo principal de este artículo es el diseño, desarrollo y validación de un sistema de evaluación ergonómica automatizado para el sector de la minería subterránea, basado en un marco de visión artificial en tiempo real. El sistema propuesto procesa secuencias de video para inferir posturas, calcular de manera automática índices de riesgo ergonómico estandarizados (REBA/RULA) y generar alertas o informes para los responsables de seguridad y salud en el trabajo.

Las contribuciones originales de esta investigación se articulan en torno a una validación empírica rigurosa que compara el desempeño del sistema automatizado frente a evaluaciones realizadas por expertos humanos, utilizando métricas de concordancia y precisión, y discutiendo sus implicaciones para la práctica de la seguridad minera. De esta forma, se busca no solo demostrar la viabilidad técnica del enfoque, sino también establecer su validez y fiabilidad en un entorno de alta exigencia.

El manuscrito se organiza de la siguiente manera. La Sección 2 ofrece una revisión sistemática de la literatura, abarcando métodos ergonómicos tradicionales y soluciones tecnológicas emergentes. La Sección 3 describe en detalle la metodología propuesta, incluida la arquitectura del modelo de estimación de pose y el pipeline de procesamiento de datos. La Sección 4 presenta los resultados de la validación experimental, junto con una discusión de sus implicaciones. Finalmente, la Sección 5 concluye el trabajo resumiendo los hallazgos principales, reconociendo las limitaciones del estudio y proponiendo direcciones para futuras investigaciones.

II. REVISIÓN

La investigación en evaluación ergonómica automatizada ha experimentado un avance significativo gracias a la integración de técnicas de visión artificial. Un enfoque particularmente prometedor para superar la escasez de datos del mundo real anotados es la generación de entornos

virtuales. En el sector de la construcción, por ejemplo, un estudio demostró que el uso de imágenes sintéticas para entrenar clasificadores de postura permitió alcanzar una precisión del 89%, validando así la utilidad de este método para desarrollar modelos de prevención de lesiones sin depender de extensas bases de datos reales [10]. La traslación de estos algoritmos a plataformas prácticas constituye un paso crucial hacia su adopción. En esta línea, se ha desarrollado un sistema web que, empleando MediaPipe y una Red Neuronal Convolutiva basada en Regiones (Region-based Convolutional Neural Network, R-CNN), genera informes ergonómicos simultáneos bajo los métodos REBA, RULA y OWAS. El sistema, capaz de calcular 17 ángulos articulares con un error cuadrático medio (Root Mean Square Error, RMSE) de 5.8° y una precisión de detección del 92%, facilita un monitoreo no intrusivo y de bajo costo [11].

Más allá del análisis de posturas estáticas, la automatización se ha extendido al estudio del movimiento. Un marco que utiliza MobileNetV2 junto con un clasificador de k-vecinos más cercanos (k-Nearest Neighbors, KNN) logró categorizar movimientos según el estándar de Métodos de Medición de Tiempos (Methods-Time Measurement, MTM-2) con una precisión cercana al 97% y tiempos de inferencia mínimos, ofreciendo una solución escalable para el análisis de procesos productivos [12]. Paralelamente, la adopción de arquitecturas de vanguardia, como los Transformers de Visión (Vision Transformers, ViT), ha mostrado un desempeño excepcional. Un modelo ligero basado en ViT, capaz de clasificar el riesgo ergonómico directamente desde imágenes RGB sin necesidad de reconstrucción esquelética, alcanzó puntuaciones F1 superiores a 0.99 en ocho regiones anatómicas, demostrando una capacidad de generalización superior a la de los enfoques basados en Redes Neuronales Convolucionales (Convolutional Neural Networks, CNN) [13].

La viabilidad de estas tecnologías en entornos industriales reales ha sido objeto de evaluación mediante el benchmarking de sistemas de captura de movimiento (Motion Capture, MoCap) basados en cámaras RGB 2D. Estos estudios confirman su alto potencial como soluciones de bajo costo y no intrusivas, aunque advierten que su precisión puede verse afectada por variables ambientales y la configuración específica del puesto de trabajo [14]. Una revisión sistemática que abarca 30 estudios sintetiza estos avances, identificando un flujo de trabajo común en tres etapas (preparación de datos, estimación de la pose y evaluación de riesgos) y destacando la superioridad de los algoritmos de aprendizaje profundo. Además, la revisión sugiere que los modelos híbridos, capaces de incorporar relaciones espaciales y temporales, podrían conducir a evaluaciones de TME más precisas y contextualizadas [15].

No obstante, la transición de entornos controlados al campo conlleva desafíos específicos. Un estudio de validación comparativa en el sector de la construcción reveló que, si bien un sistema automatizado basado en MediaPipe mostraba una consistencia superior, presentaba discrepancias en las

puntuaciones asignadas al tronco y las piernas en comparación con el criterio experto. Estas diferencias se atribuyeron a factores como oclusiones parciales y la calidad variable de la imagen en el sitio de obra [16]. Para abordar la necesidad de una intervención inmediata, se han propuesto sistemas de monitoreo en tiempo real capaces de clasificar el estado de los segmentos corporales y cuantificar el tiempo de exposición al riesgo mediante representaciones gráficas, permitiendo así una retroalimentación visual proactiva para la prevención de TME en tareas repetitivas [17].

En comparación con aplicaciones de visión artificial reportadas en sectores industriales como construcción, manufactura y logística [10, 17], la minería subterránea en el contexto latinoamericano presenta restricciones operativas más severas, tales como iluminación limitada, presencia de polvo, espacios confinados, uso intensivo de equipos de protección personal y alta variabilidad de tareas. Mientras que en industrias más controladas los sistemas de visión artificial suelen operar con fondos relativamente estables, trayectorias repetitivas y menor interferencia visual, en minería subterránea el modelo debe responder a escenarios dinámicos, parcialmente obstruidos y ambientalmente adversos. No obstante, la literatura revisada evidencia que aún son escasos los estudios que adapten y validen estos sistemas en operaciones mineras subterráneas de la región. Esta brecha refuerza la contribución del presente estudio, al proponer y validar un marco de evaluación ergonómica automatizada en un entorno industrial de alta complejidad, con potencial de transferencia hacia otras operaciones mineras latinoamericanas.

En conjunto, la literatura revisada traza una trayectoria sólida hacia la automatización objetiva de la evaluación ergonómica. Sin embargo, es crucial observar que la aplicación reportada de estas tecnologías se ha concentrado predominantemente en entornos como la manufactura y la construcción. Esta focalización evidencia una brecha de investigación significativa: la falta de adaptación y validación de estos sistemas para las condiciones operativas únicas, aisladas y visualmente complejas que caracterizan a la industria minera subterránea.

La Tabla 1 sintetiza una selección de estudios representativos sobre evaluación ergonómica, contrastando el enfoque tradicional en minería con las innovaciones en industrias afines.

Tabla 1. Métodos de evaluación ergonómica utilizados en minería e industrias relacionadas.

Autor	Tipo de mina	Método de evaluación
Adeyemi et al. (2020)	Mina Cielo abierto (arena)	Cuestionario NORDIC
Dobson et al. (2018)	Mina Socavón (Carbón)	Cuestionario NORDIC
Komljenovic et al. (2017)	Mina Socavón (Carbón)	RULA-OWAS
Custodio et al. (2016)	Mina Socavón (Oro)	Cuestionario NORDIC

Weston et al. (2016)	Mina Socavón	Cuestionario NORDIC
Sharma et al. (2016)	Mina Socavón	OWAS - REBA
Varga et al. (2016)	Mina Socavón	REBA
Norhidayah et al. (2016)	Mina Socavón	REBA
Aghilinejad et al. (2016)	Mina Socavón	Cuestionario NORDIC
Pari & Dari (2015)	Mina Cielo Abierto	OWAS
Chaudhary et al. (2019)	Mina cielo abierto (hierro)	REBA-RULA
El-mir e Ivarsson (2020)	Industria	Cálculo de Angulo vectorial y cámara en vivo
Santos et al. (2019)	Logística	RULA
Oyekan et al. (2021)	Manufactura	REBA
Sancho et al. (2021)	Salud	REBA

Se observa una marcada predominancia del uso de métodos observacionales subjetivos (como cuestionarios NORDIC, RULA, REBA, OWAS) en operaciones mineras subterráneas y de cielo abierto. En contraste, en otros sectores industriales comienzan a explorarse métodos instrumentados, incluyendo el uso de cámaras para el cálculo vectorial de posturas, lo que subraya el potencial de transferencia tecnológica y la oportunidad de innovación en el sector minero.

En síntesis, la literatura revela una brecha crítica: la ausencia de sistemas de evaluación ergonómica automatizada específicamente diseñados y validados para el entorno minero. Los escenarios de trabajo subterráneo presentan desafíos perceptuales únicos —como presencia de polvo, iluminación deficiente y variable, oclusiones complejas derivadas del equipo de protección personal (EPP) y la maquinaria, así como tareas eminentemente no repetitivas— que no son adecuadamente abordados por las soluciones tecnológicas desarrolladas para sectores más controlados como la manufactura o la construcción. Esta carencia justifica plenamente la presente investigación, cuyo objetivo es desarrollar un marco de visión artificial en tiempo real, adaptado a estas condiciones adversas, para la evaluación ergonómica automatizada. Al hacerlo, se busca no solo llenar un vacío tecnológico, sino también ofrecer una solución práctica y escalable para la prevención proactiva de trastornos musculoesqueléticos en la industria minera.

III. METODOLOGÍA.

La investigación adoptó un enfoque cuantitativo, de tipo aplicado, con diseño tecnológico-experimental y corte transversal. El estudio se desarrolló en una operación de minería subterránea ubicada en una región andina en Sudamérica, durante el periodo de noviembre y diciembre de 2025. La unidad de análisis estuvo constituida por secuencias de video de trabajadores durante actividades de sostenimiento

con shotcrete, capturadas bajo condiciones reales de operación.

El marco metodológico se fundamentó en técnicas de visión artificial y aprendizaje profundo para la evaluación ergonómica automatizada de trabajadores en entornos de minería subterránea. El objetivo fue determinar el nivel de riesgo ergonómico (Bajo, Medio o Alto) a partir del análisis de secuencias de video capturadas durante actividades extractivas desarrolladas en condiciones ambientales adversas.

El procedimiento se organizó en cuatro: (1) adquisición de video bajo un protocolo adaptado a entornos hostiles; (2) preprocesamiento de imágenes; (3) construcción de un dataset etiquetado mediante estimación de pose y métricas RULA; y (4) diseño, entrenamiento y validación del modelo de aprendizaje profundo.

La Figura 1 muestra el flujo metodológico propuesto para la adquisición, procesamiento, etiquetado y clasificación del riesgo ergonómico.




Figura 1. Metodología de trabajo

1) Adquisición de Video

La fase inicial consistió en la captura de material videográfico de trabajadores durante operaciones reales en una mina subterránea, un entorno caracterizado por iluminación deficiente, presencia de partículas de polvo en suspensión y espacios confinados. Para garantizar la calidad, consistencia y viabilidad del análisis computacional posterior en este entorno desafiante, se diseñó un protocolo de adquisición específico.

La Tabla 2 detalla las especificaciones del protocolo de captura de video aplicado en condiciones de minería subterránea.

Tabla 2. Especificaciones del protocolo de captura de video adaptado a condiciones mineras subterráneas

Item	Paso
01	La cámara debe contar con una resolución de 1280×720 píxeles
02	Verificar si cámara de video tiene flash, prender flash
03	Considerar el área de grabación que se encuentre sin obstáculos

04	Prender las luces del equipo de trabajo
05	Considerar un zoom adecuado para la actividad
06	Ubicarse a 6 metros del trabajador
07	Enfocar la actividad que realiza el trabajador de preferencia cuerpo entero
08	No enfocar reflejos del trabajador por uso de lampara minera
09	Realizar la toma del trabajador en ángulos frontal y lateral

Este protocolo especifica parámetros críticos adaptados a las condiciones adversas del entorno. Se estableció una distancia óptima de 6 metros, combinando ángulos frontal y lateral para minimizar oclusiones provocadas por maquinaria y Equipos de Protección Personal (EPP). Se requirió el uso de iluminación complementaria (flash y luces del equipo) para compensar la baja luminosidad ambiental. La resolución mínima se fija en 1280×720 píxeles con una tasa de 30 fotogramas por segundo (fps) para capturar detalles posturales sin desenfoque de movimiento, incorporando además directrices específicas para mitigar los reflejos generados por las lámparas mineras. Cada grabación, con una duración de 2 minutos, se enfocó en ciclos completos de tareas representativas, priorizando áreas despejadas que faciliten una visión no obstruida del trabajador.

2) Preprocesamiento

El flujo de video adquirido se sometió a un proceso de preprocesamiento para obtener un conjunto de imágenes aptas para el modelo de aprendizaje profundo, aplicando técnicas que compensan las perturbaciones inherentes al entorno minero. Utilizando la biblioteca OpenCV, cada video se segmenta en fotogramas individuales. Posteriormente, se empleó MediaPipe Pose para verificar la presencia y visibilidad del trabajador en cada fotograma; aquellos donde no se detectan suficientes puntos de referencia corporales (landmarks) son automáticamente excluidos del dataset. Este filtrado garantiza que solo las imágenes con posturas evaluables sean consideradas para las fases subsiguientes de etiquetado y entrenamiento.

3) Construcción del Dataset

El núcleo del enfoque propuesto es un modelo de aprendizaje profundo entrenado de manera supervisada. Para ello, se construyó un dataset de imágenes preprocesadas, etiquetadas con su correspondiente nivel de riesgo ergonómico, siguiendo un proceso sistemático de tres etapas diseñado específicamente para entornos mineros.

3.1 Extracción y Aumento de Datos Robusto

A partir de las imágenes filtradas, se aplicaron técnicas de aumento de datos (data augmentation) orientadas a simular las variaciones propias de la minería subterránea: rotaciones

aleatorias (hasta $\pm 15^\circ$) para emular diferentes ángulos de captura, desplazamientos horizontales y verticales para simular encuadres imperfectos, ajustes de brillo y contraste ($\pm 20\%$) para replicar fluctuaciones lumínicas, y adición controlada de ruido gaussiano para modelar la presencia de polvo. Este proceso incrementa la variabilidad del dataset, mejorando la robustez y capacidad de generalización del modelo frente a condiciones adversas no vistas.

3.2 Estimación de Postura y Cálculo de Ángulos Articulares

Para cada imagen, se utilizó la biblioteca MediaPipe Pose, un framework de alta precisión y eficiencia optimizado para inferencia en tiempo real, que detecta 33 puntos de referencia corporales en 2D y 3D. A pesar de las oclusiones parciales provocadas por el EPP (casco, lámpara, arnés) y la maquinaria, MediaPipe mantiene una estimación robusta gracias a su arquitectura basada en BlazePose. A partir de estas coordenadas, se calculan los ángulos de las extremidades que son clave para la evaluación ergonómica: tronco (ángulo entre hombro-cadera-rodilla), cuello (ángulo entre hombro-cadera), brazo (ángulo hombro-codo-muñeca), antebrazo (ángulo codo-muñeca), muñeca (ángulo de flexión/extensión) y piernas (ángulo cadera-rodilla-tobillo). Estos ángulos se almacenan sistemáticamente en una base de datos estructurada, junto con los metadatos de la captura.

3.3 Evaluación Ergonómica

Se implementó el método RULA (Rapid Upper Limb Assessment) como criterio objetivo para etiquetar las imágenes. La elección de RULA se justifica por su amplia validación y su idoneidad para evaluar posturas de las extremidades superiores y el cuello, que son prevalentes en tareas mineras como la perforación, el sostenimiento y la manipulación de cargas. Un algoritmo automatizado calcula la puntuación RULA final (en una escala de 1 a 7) para cada fotograma, basándose en los ángulos articulares previamente calculados y en supuestos estandarizados de carga y actividad muscular, contextualizados para las tareas mineras. Esta puntuación numérica se discretiza en una de las tres clases objetivo para la clasificación: Bajo (puntuación 1-2, riesgo aceptable), Medio (3-4, riesgo moderado que requiere investigación) y Alto (5-7, riesgo muy alto que requiere acción inmediata).

4) Entrenamiento

Arquitectura del Modelo

Se propuso una Red Neuronal Convolucional (CNN) personalizada, diseñada para extraer características jerárquicas de las posturas en entornos adversos. La arquitectura recibe como entrada imágenes en escala de grises. La composición detallada de las capas se presenta en la Tabla 3.

Tabla 3. Arquitectura del modelo

Bloque convolucional 1	Capa Conv2D con 32 filtros (kernel 3×3), activación ReLU, seguida de Batch Normalization para estabilizar el entrenamiento y MaxPooling2D (2×2) para reducción dimensional
Bloque convolucional 2.	Capa Conv2D con 64 filtros (kernel 3×3), activación ReLU, Batch Normalization y MaxPooling2D
Bloque convolucional 3	Capa Conv2D con 128 filtros (kernel 3×3), activación ReLU, Batch Normalization y MaxPooling2D.
Clasificador	La salida se aplanar y se conecta a dos capas densas completamente conectadas con 512 y 128 neuronas, respectivamente, ambas con activación ReLU y Dropout (tasa 0.5) para mitigar sobreajuste. Culmina en una capa de salida densa con 3 neuronas y activación softmax para la clasificación multiclase (Bajo/Medio/Alto).

Partición y Estrategia de Entrenamiento

El dataset se divide de manera estratificada en tres subconjuntos: 80% para entrenamiento, 10% para validación y 10% para prueba, asegurando que la distribución de las clases (Bajo, Medio, Alto) sea representativa en cada uno de ellos. El modelo se compila utilizando el optimizador Adam (con una tasa de aprendizaje inicial de 0.001), la función de pérdida de entropía cruzada categórica (categorical cross-entropy) y la exactitud (accuracy) como métrica de seguimiento. El entrenamiento se realizó durante un máximo de 100 épocas con un tamaño de batch de 32, implementando una parada temprana (early stopping) con una paciencia de 20 épocas basada en la pérdida de validación, y una reducción dinámica de la tasa de aprendizaje (factor de 0.5 si la pérdida de validación no mejora en 10 épocas) para mitigar el sobreajuste. La optimización de hiperparámetros (tasa de aprendizaje, tasa de dropout, número de filtros) se realiza mediante búsqueda aleatoria (random search) con validación cruzada de 3 iteraciones.

IV. RESULTADOS

La evaluación del sistema de visión artificial propuesto se realizó en operaciones de sostenimiento con shotcrete en minería subterránea, analizando dos actividades críticas: calibración en hastiales (paredes laterales) y calibración en corona (techo de la excavación). Estas tareas fueron seleccionadas por su alta demanda biomecánica, que incluye posturas forzadas sostenidas, manipulación de mangueras de alta presión y exposición a rebote de material.

En la Figura 2 se muestra el proceso de calibración de shotcrete en los hastiales de la labor y se evidenciando la capacidad del sistema para cuantificar con precisión los ángulos articulares en condiciones adversas. El sistema detecta una inclinación de tronco de 60° con asimetría postural significativa: brazo izquierdo 10° más elevado que el derecho y pierna izquierda 13° más flexionada, patrones característicos del trabajo en terrenos irregulares.



Figura 2. Calibración de shotcrete en los hastiales de la labor

La Figura 3 presenta la comparación postural durante la calibración de shotcrete en la corona de la labor, destacando las variaciones angulares identificadas por el sistema.

En ambas imágenes se observa una extensión del cuello de 20-30°, necesaria para mantener contacto visual con el punto de aplicación en la corona, generando carga sostenida sobre la musculatura cervical profunda y riesgo elevado. Los hombros presentan flexiones extremas que oscilan entre 130-160°, superando ampliamente el umbral de 45° que activa la máxima puntuación en el método RULA.



Figura 3. Calibración de shotcrete en la corona de la labor

El análisis biomecánico revela una asimetría funcional significativa entre ambos miembros superiores durante la calibración en corona. El brazo derecho presenta una flexión glenohumeral de 155° con el codo prácticamente extendido (165°), mientras que el izquierdo alcanza 140° de flexión con mayor flexión de codo (145°). Esta diferencia de 15-20° evidencia el rol predominante del miembro dominante en el direccionamiento fino del portacalibrador hacia la corona. Las muñecas, por su parte, combinan una extensión moderada (15°) con desviación cubital de 10-12°, configuración que incrementa la tensión y favoreciendo el desarrollo de trastornos como el síndrome del túnel carpiano.

La comparación entre ambas capturas revela una mejoría postural en la imagen derecha, donde el tronco adopta una posición más erguida (7° de extensión frente a 12° hacia atrás) y los miembros superiores presentan mayor simetría angular.

Este hallazgo sugiere que ajustes en el posicionamiento del trabajador respecto al frente de trabajo podrían reducir significativamente la carga biomecánica. Los resultados obtenidos demuestran la capacidad del sistema para cuantificar con alta resolución los ángulos articulares durante la calibración en corona, identificando riesgos específicos en segmentos proximales (hombros, cuello) y distales (muñecas), y proporcionando una base objetiva para el diseño de intervenciones ergonómicas focalizadas en operaciones con shotcrete en minería subterránea.

La Figura 4 muestra la evolución de las curvas de pérdida durante el entrenamiento y validación del modelo CNN. Se observa un descenso pronunciado de la pérdida de entrenamiento desde valores iniciales superiores a 1.0, estabilizándose gradualmente por debajo de 0.2 a partir de la época 20. Paralelamente, la pérdida de validación alcanza su valor mínimo en torno a 0.24 y se mantiene estable en las épocas subsiguientes, sin mostrar incrementos significativos que sugieran un deterioro de la capacidad de generalización.

Training curve of the computer vision model




Figura 4. Evolución de las curvas de pérdida durante el entrenamiento del modelo.

La reducida brecha entre ambas curvas y la ausencia de divergencia en las épocas finales confirman que el modelo aprendió los patrones subyacentes a los datos de entrenamiento sin incurrir en sobreajuste (overfitting). Este comportamiento valida la robustez de la arquitectura CNN propuesta y sustenta los altos valores de exactitud (91.55%) y precisión (91.44%) obtenidos en el conjunto de prueba. En conjunto, estos resultados demuestran que el modelo es capaz de mantener un desempeño consistente ante nuevas muestras

no vistas durante el entrenamiento, una condición indispensable para su despliegue fiable en entornos mineros caracterizados por una alta variabilidad operativa.

El desempeño relativamente menor observado en la clase Riesgo Medio (F1-score = 0.88) puede explicarse por la naturaleza limítrofe de esta categoría. A diferencia de los niveles Bajo y Alto, cuyas configuraciones posturales suelen presentar patrones angulares más diferenciados, el Riesgo Medio agrupa posturas de transición con variaciones moderadas de tronco, brazos, muñecas y piernas. En condiciones de minería subterránea, estas diferencias pueden verse afectadas por oclusiones parciales generadas por el equipo de protección personal, presencia de polvo, baja iluminación, reflejos de lámparas mineras y encuadres no completamente frontales o laterales. Por ello, algunos fotogramas cercanos a los umbrales RULA pudieron ser clasificados como Bajo o Alto. Este resultado no invalida el desempeño general del modelo, sino que identifica un punto crítico para futuras mejoras, tales como el incremento de muestras etiquetadas en la clase intermedia, el balanceo del dataset, la incorporación de secuencias temporales y la validación con evaluadores ergonómicos expertos.

IV. CONCLUSIONES

Se desarrolló y validó un sistema basado en aprendizaje profundo para la evaluación ergonómica automatizada en tiempo real de trabajadores mineros durante operaciones de sostenimiento con shotcrete. El modelo alcanzó una exactitud del 91.55%, precisión del 91.44% y AUC de 0.85, demostrando que la visión artificial constituye una alternativa superior a los métodos observacionales tradicionales al eliminar la subjetividad del evaluador y permitir monitoreo continuo y objetivo en entornos mineros caracterizados por condiciones adversas de iluminación y oclusiones por EPP.

La aplicación del sistema en calibración de hastiales reveló inclinación de tronco de 60° con asimetría postural de 10-13° en brazos y piernas. En calibración de corona, se detectaron ángulos de muñeca de 85-98° con desviación cubital de 10-15°, valores que constituyen riesgo extremo para síndrome del túnel carpiano. Estos hallazgos evidencian la capacidad del sistema para identificar riesgos ocultos en segmentos distales y cuantificar asimetrías posturales difíciles de evaluar mediante observación directa.

Desde la perspectiva de sostenibilidad social, el sistema propuesto contribuye a la prevención de trastornos musculoesqueléticos de origen laboral, una problemática que afecta la salud, continuidad laboral y calidad de vida de los trabajadores mineros. La automatización de la evaluación ergonómica no debe entenderse únicamente como una mejora tecnológica, sino como una herramienta de apoyo a la gestión preventiva de seguridad y salud ocupacional. Al permitir el monitoreo objetivo y continuo de posturas de riesgo, el sistema puede facilitar intervenciones tempranas, rediseño de tareas, ajustes en procedimientos operativos y priorización de controles ergonómicos. En consecuencia, la propuesta se

alinea con una minería más segura, responsable y centrada en el bienestar del trabajador.

El sistema proporciona una base objetiva para intervenciones ergonómicas focalizadas, demostrando que pequeños ajustes en el posicionamiento del trabajador reducen significativamente la carga biomecánica. Futuras líneas incluyen la integración de alertas en tiempo real, validación en un espectro más amplio de tareas mineras y estudios longitudinales sobre reducción de trastornos musculoesqueléticos, contribuyendo a la transformación digital de la seguridad ocupacional en el marco de la minería 4.0/5.0.

REFERENCIAS

- [1] T. Ribeiro, F. Serranheira, and H. Loureiro, "Work related musculoskeletal disorders in primary health care nurses," *Applied Nursing Research*, vol. 33, pp. 72–77, Nov. 2017, doi: 10.1016/j.apnr.2016.09.003.
- [2] D. Beales et al., "Work productivity loss in young workers is substantial and is associated with spinal pain and mental ill-health conditions," *Journal of Occupational and Environmental Medicine*, vol. 59, no. 3, pp. 237–245, 2017, doi: 10.1097/JOM.0000000000000990.
- [3] Occupational Safety and Health Administration, OSHA Technical Manual (OTM), Section VII: Chapter 1–Back Disorders and Injuries. 2020. [Online]. Available: https://www.osha.gov/dts/osta/otm/otm_vii/otm_vii_1.html. Accessed: Nov. 17, 2016.
- [4] C. James, A. Bezzina, and M. Rahman, "Task rotation in an underground coal mine: Implications on injury and musculoskeletal discomfort," *Applied Ergonomics*, vol. 93, art. no. 103388, 2021, doi: 10.1016/j.apergo.2021.103388.
- [5] B. Rathore, A. Pundir, R. Iqbal, and R. Gupta, "Development of fuzzy based ergonomic-value stream mapping (E-VSM) tool: a case study in Indian glass artware industry," *Production Planning & Control*, 2022, doi: 10.1080/09537287.2022.2035447.
- [6] W. Mao, Y. Hu, X. Yang, W. Ren, and H. Fang, "ARE-Platform: An augmented reality-based ergonomic evaluation solution for smart manufacturing," *International Journal of Human-Computer Interaction*, 2023, doi: 10.1080/10447318.2023.2173894.
- [7] S. K. Jeripotula, A. Mangalpaday, and G. R. Mandela, "Ergonomic assessment of musculoskeletal disorders among surface mine workers in India," *Mining, Metallurgy & Exploration*, vol. 13, pp. 1–6, 2020, doi: 10.1007/s42461-020-00200-1.
- [8] S. Sardar, C. Lim, S. Yoon, and S. C. Lee, "Ergonomic risk assessment of manufacturing works in virtual reality context," *International Journal of Human-Computer Interaction*, 2023, doi: 10.1080/10447318.2023.2201558.
- [9] L. McAtamney and E. N. Corlett, "RULA: A survey method for the investigation of work-related upper limb disorders," *Applied Ergonomics*, vol. 24, no. 2, pp. 91–99, 1993, doi: 10.1016/0003-6870(93)90080-S.
- [10] J. Seo and S. Lee, "Automated postural ergonomic risk assessment using vision-based posture classification," *Automation in Construction*, vol. 128, art. no. 103725, Aug. 2021.
- [11] A. Kiraz and A. Ö. Geçici, "Ergonomic risk assessment application based on computer vision and machine learning," *Journal of the Faculty of Engineering and Architecture of Gazi University*, vol. 39, no. 4, pp. 2473–2483, 2024.
- [12] A. Mares-Castro, V. Calzada-Ledesma, M. B. Becerra-Rodríguez, R. Santiago-Montero, and A. Estrada-Monje, "Intelligent motion classification via computer vision for smart manufacturing and ergonomic risk prevention in SMEs," *Applied Sciences*, vol. 15, no. 20, p. 10914, Oct. 2025.
- [13] L. Cruciata et al., "Lightweight vision transformer for frame-level ergonomic posture classification in industrial workflows," *Sensors*, vol. 25, no. 15, p. 4750, Aug. 2025.

- [14]T. Agostinelli, A. Generosi, S. Ceccacci, and M. Mengoni, “Validation of computer vision-based ergonomic risk assessment tools for real manufacturing environments,” *Scientific Reports*, vol. 14, no. 27785, 2024.
- [15]Z. Yang, D. Song, J. Ning, and Z. Wu, “A systematic review: Advancing ergonomic posture risk assessment through the integration of computer vision and machine learning techniques,” *IEEE Access*, vol. 12, pp. 180481–180519, 2024.
- [16]Z. Li, Q. He, and J. Li, “A survey of deep learning-driven architecture for predictive maintenance,” *Engineering Applications of Artificial Intelligence*, vol. 133, pt. C, art. no. 108285, Jul. 2024, doi: 10.1016/j.engappai.2024.108285.
- [17]O. Karhu, P. Kansi, and I. Kuorinka, “Correcting working postures in industry: a practical method for analysis,” *Applied Ergonomics*, vol. 8, no. 4, pp. 199–201, 1977, doi: 10.1016/0003-6870(77)90164-8.