

Artículo de investigación

<https://doi.org/10.47460/athenea.v7i24.145>

Modelado predictivo basado en inteligencia artificial y sensores inteligentes para la prevención dinámica de accidentes laborales en entornos industriales de alto riesgo

Benjamín Roldan Polo-Escobar
<https://orcid.org/0000-0001-5056-9957>
benjamin.polo@untrm.edu.pe
Universidad Nacional Toribio Rodríguez de
Mendoza
Chachapoyas, Perú

Renzo Enrique Polo-Moreano
<https://orcid.org/0009-0009-8747-8974>
20193257@aloe.ulima.edu.pe
Universidad de Lima, Facultad de Ciencias
Empresariales y Económicas
Lima, Perú

Larissa Galia Yampasi Surco
<https://orcid.org/0009-0008-8777-3423>
lyampasi@unsa.edu.pe
Universidad Nacional San Agustín de Arequipa
Arequipa, Perú

Eduardo Andre Zuñiga Flores
<https://orcid.org/0009-0002-8810-4754>
ezunigaf@unsa.edu.pe
Universidad Nacional San Agustín de Arequipa
Arequipa, Perú

*Autor de correspondencia: benjamin.polo@untrm.edu.pe

Recibido: (03/03/2026), Aceptado: (30/05/2026)

Resumen. La prevención de accidentes laborales en entornos industriales de alto riesgo requiere soluciones capaces de anticipar condiciones inseguras en tiempo real. El objetivo de esta investigación fue desarrollar un modelo predictivo basado en inteligencia artificial y sensores inteligentes para la prevención dinámica de accidentes laborales. La metodología integró tecnologías del Internet de las Cosas Industrial (IIoT), algoritmos de aprendizaje automático, simulación Monte Carlo e inteligencia artificial explicable para analizar variables ambientales, operacionales y humanas. Los resultados mostraron que el modelo XGBoost alcanzó una exactitud del 94% y un AUC de 0,97, mientras que el análisis SHAP identificó la fatiga operacional, las vibraciones anormales y la temperatura ambiental como los principales factores asociados al riesgo. Se concluye que la integración de sensores inteligentes, inteligencia artificial y simulación avanzada fortalece la seguridad industrial mediante sistemas predictivos orientados a la detección temprana de riesgos y la toma de decisiones preventivas.

Palabras clave: inteligencia artificial, seguridad industrial, sensores inteligentes, prevención de accidentes, IIoT.

Predictive Modeling Based on Artificial Intelligence and Smart Sensors for the Dynamic Prevention of Occupational Accidents in High-Risk Industrial Environments

Abstract. The prevention of occupational accidents in high-risk industrial environments requires solutions capable of anticipating unsafe conditions in real time. The objective of this research was to develop a predictive model based on artificial intelligence and smart sensors for the dynamic prevention of occupational accidents. The methodology integrated Industrial Internet of Things (IIoT) technologies, machine learning algorithms, Monte Carlo simulation, and explainable artificial intelligence to analyze environmental, operational, and human variables. The results showed that the XGBoost model achieved an accuracy of 94% and an AUC of 0.97, while the SHAP analysis identified operational fatigue, abnormal vibrations, and ambient temperature as the main risk-related factors. It is concluded that the integration of smart sensors, artificial intelligence, and advanced simulation strengthens industrial safety through predictive systems aimed at early risk detection and preventive decision-making.

Keywords: artificial intelligence, industrial safety, smart sensors, accident prevention, IIoT.

I. INTRODUCCIÓN

La seguridad laboral continúa siendo uno de los principales desafíos en los entornos industriales de alto riesgo debido a la complejidad de los procesos productivos y a la interacción constante entre factores humanos, ambientales y operacionales. Aunque los avances normativos y tecnológicos han contribuido a mejorar las condiciones de trabajo, los accidentes laborales siguen generando importantes consecuencias humanas y económicas, evidenciando la necesidad de fortalecer los mecanismos de prevención [1]. Los enfoques tradicionales basados en inspecciones periódicas y análisis retrospectivos presentan limitaciones para identificar condiciones de riesgo emergentes en tiempo real, especialmente en escenarios industriales dinámicos [2].

En este contexto, la inteligencia artificial (IA) y el aprendizaje automático han impulsado el desarrollo de sistemas predictivos capaces de analizar grandes volúmenes de datos, detectar patrones complejos y estimar probabilidades de riesgo con mayor precisión que los métodos convencionales [1], [3], [4]. Paralelamente, los sensores inteligentes y las tecnologías asociadas al Internet de las Cosas (IoT) han ampliado las capacidades de monitoreo continuo mediante la captura de información relacionada con variables fisiológicas, ambientales y operacionales [5], [6].

Diversos estudios han demostrado la utilidad de estas tecnologías para la vigilancia de trabajadores en zonas de alto riesgo, la detección automática de condiciones inseguras y la generación de alertas preventivas [7], [5], [8]. Sin embargo, persisten desafíos asociados a la integración de múltiples fuentes de información, la interpretabilidad de los modelos predictivos y la transformación de los resultados en acciones preventivas efectivas [2], [9], [10]. Asimismo, las investigaciones recientes incorporan enfoques centrados en el factor humano mediante interfaces adaptativas y sistemas de neuroergonomía orientados a reducir errores operacionales y mejorar la toma de decisiones [11].

Bajo este escenario, la presente investigación tiene como objetivo desarrollar un modelo predictivo basado en inteligencia artificial y sensores inteligentes para la prevención dinámica de accidentes laborales en entornos industriales de alto riesgo. La propuesta integra variables humanas, ambientales y operacionales mediante técnicas avanzadas de aprendizaje automático con el fin de fortalecer la detección temprana de riesgos y la toma de decisiones preventivas en tiempo real.

II. MARCO TEÓRICO

A. Seguridad industrial y prevención de accidentes laborales

La seguridad industrial constituye una disciplina orientada a la identificación, evaluación y control de los riesgos asociados a los procesos productivos con el propósito de proteger la integridad física de los trabajadores, garantizar la continuidad operacional y reducir las pérdidas económicas derivadas de incidentes y accidentes laborales. Históricamente, los programas de seguridad se han basado en enfoques preventivos sustentados en inspecciones periódicas, análisis de incidentes y cumplimiento normativo. Sin embargo, la creciente complejidad de los sistemas industriales modernos ha evidenciado las limitaciones de los métodos tradicionales para anticipar situaciones de riesgo dinámicas y altamente variables [1].

Los entornos industriales de alto riesgo presentan una interacción permanente entre factores humanos, ambientales y operacionales que pueden modificar significativamente las condiciones de seguridad en intervalos muy cortos de tiempo. En consecuencia, la prevención efectiva de accidentes requiere mecanismos capaces de monitorear continuamente dichas variables y detectar oportunamente cambios que incrementen la probabilidad de ocurrencia de eventos críticos [2]. Bajo esta perspectiva, la gestión moderna de la seguridad ocupacional ha evolucionado progresivamente hacia modelos basados en información en tiempo real y análisis predictivo. Diversas investigaciones coinciden en que la transformación digital está redefiniendo los paradigmas tradicionales de prevención laboral, favoreciendo el desarrollo de sistemas inteligentes capaces de anticipar riesgos antes de que estos se materialicen en accidentes [7]. Este cambio representa una transición desde enfoques reactivos hacia estrategias proactivas centradas en la predicción y mitigación temprana de peligros.

B. Inteligencia artificial aplicada a la gestión del riesgo ocupacional

La inteligencia artificial ha emergido como una de las tecnologías más prometedoras para fortalecer los sistemas de seguridad industrial mediante el análisis automatizado de grandes volúmenes de datos

y la identificación de patrones complejos de comportamiento. Su aplicación en entornos laborales permite detectar relaciones no lineales entre múltiples variables y generar estimaciones probabilísticas sobre la ocurrencia de eventos adversos [1]. Los algoritmos de aprendizaje automático han demostrado una elevada capacidad para procesar simultáneamente información procedente de sensores, registros históricos, sistemas de mantenimiento y dispositivos de monitoreo humano. De acuerdo con Akash [3], los modelos predictivos basados en inteligencia artificial permiten identificar señales tempranas de riesgo y generar alertas preventivas antes de que se produzcan situaciones críticas.

Por otra parte, las revisiones sistemáticas realizadas por Shekh [4] evidencian que los sistemas predictivos basados en inteligencia artificial han alcanzado niveles de precisión significativamente superiores a los obtenidos mediante métodos convencionales de evaluación de riesgos. Entre las técnicas más utilizadas destacan *Random Forest*, *Support Vector Machine*, *XGBoost*, *LightGBM* y redes neuronales profundas, debido a su capacidad para modelar relaciones complejas entre variables heterogéneas. Adicionalmente, los avances recientes en inteligencia artificial explicable han permitido superar una de las principales limitaciones de los modelos predictivos tradicionales: la falta de interpretabilidad. Herramientas como SHAP (*Shapley Additive Explanations*) facilitan la identificación de las variables que influyen en las predicciones generadas por los algoritmos, proporcionando mayor transparencia y confianza en los procesos de toma de decisiones relacionados con la seguridad ocupacional [9].

C. Sensores inteligentes e Internet de las Cosas Industrial (IIoT)

El desarrollo de sensores inteligentes y tecnologías asociadas al Internet de las Cosas Industrial (*Industrial Internet of Things*, IIoT) ha transformado significativamente las capacidades de monitoreo en los entornos productivos modernos. Estas tecnologías permiten capturar información en tiempo real sobre el estado de los equipos, las condiciones ambientales y las respuestas fisiológicas de los trabajadores, generando flujos continuos de datos para el análisis de riesgos [6]. Los sensores inteligentes incorporan capacidades de procesamiento, comunicación y transmisión de información que facilitan la supervisión permanente de variables críticas tales como temperatura, humedad, vibraciones, ruido, gases contaminantes, frecuencia cardíaca y localización espacial [2]. Gracias a esta capacidad de monitoreo continuo, las organizaciones pueden disponer de información actualizada sobre las condiciones de operación y responder con mayor rapidez ante posibles situaciones de peligro.

Nakka y Dilip [5] destacan que los sistemas basados en aprendizaje profundo y sensores inteligentes han mostrado resultados prometedores para la vigilancia automática de trabajadores en zonas de alto riesgo. De forma similar, Moura *et al.* [8] demostraron la viabilidad de plataformas inteligentes para la prevención de riesgos en espacios confinados mediante la integración de sensores ambientales y modelos analíticos avanzados. La convergencia entre IIoT e inteligencia artificial ha dado origen a ecosistemas de seguridad industrial capaces de recopilar, procesar y analizar información de manera autónoma, fortaleciendo las capacidades predictivas y preventivas de las organizaciones [7].

D. Sistemas predictivos, simulación y toma de decisiones en tiempo real

Los sistemas predictivos representan una evolución natural de los enfoques tradicionales de seguridad industrial al permitir la anticipación de eventos potencialmente peligrosos a partir del análisis continuo de datos operacionales. A diferencia de los modelos reactivos, los sistemas predictivos buscan identificar patrones de riesgo antes de que ocurran incidentes, facilitando la implementación temprana de acciones correctivas [3]. En este contexto, la simulación computacional constituye una herramienta complementaria de gran relevancia para evaluar escenarios futuros y analizar el comportamiento de los sistemas bajo condiciones de incertidumbre. Técnicas como la simulación Monte Carlo permiten generar miles de escenarios posibles mediante la variación controlada de parámetros críticos, proporcionando estimaciones probabilísticas sobre la ocurrencia de eventos adversos y la sensibilidad del sistema frente a diferentes factores de riesgo [1].

Paralelamente, los avances en gemelos digitales han impulsado nuevas formas de gestión de la seguridad industrial. Un gemelo digital puede definirse como una representación virtual dinámica de un sistema físico que replica su comportamiento mediante datos obtenidos en tiempo real. Esta tecnología permite simular condiciones operativas, evaluar estrategias preventivas y analizar escenarios de riesgo sin intervenir directamente sobre los procesos productivos [10]. La integración de inteligencia artificial, sensores inteligentes, simulación probabilística y gemelos digitales configura una nueva generación de

sistemas de seguridad industrial capaces de observar, aprender, predecir y recomendar acciones preventivas de manera continua. Según Ramírez-Peña *et al.* [10] y Rogério Pires *et al.* [9], esta convergencia tecnológica constituye uno de los pilares fundamentales de la Industria 5.0, donde la toma de decisiones se apoya en plataformas inteligentes orientadas a mejorar simultáneamente la seguridad, la eficiencia y el bienestar de los trabajadores.

E. Factor humano, neuroergonomía e interacción inteligente

A pesar del crecimiento de las tecnologías de automatización y monitoreo inteligente, el factor humano continúa desempeñando un papel determinante en la ocurrencia de accidentes laborales. Variables como la fatiga, la carga cognitiva, el estrés, la atención situacional y la percepción del riesgo influyen directamente en el desempeño operativo y en la probabilidad de cometer errores durante la ejecución de tareas críticas [11].

En respuesta a esta problemática, la neuroergonomía propone integrar conocimientos provenientes de las neurociencias, la ergonomía y la inteligencia artificial para comprender mejor la interacción entre las personas y los sistemas tecnológicos. Según Polo-Escobar *et al.* [11], las interfaces hombre-máquinas adaptativas permiten ajustar dinámicamente la presentación de información en función del estado cognitivo del trabajador, reduciendo la probabilidad de errores y mejorando la toma de decisiones en entornos industriales complejos.

La incorporación de variables humanas dentro de los modelos predictivos de seguridad representa una tendencia emergente que busca superar las limitaciones de los enfoques centrados exclusivamente en factores técnicos. Desde esta perspectiva, la prevención efectiva de accidentes requiere comprender el riesgo como un fenómeno multidimensional donde interactúan simultáneamente personas, tecnologías y condiciones ambientales.

III. METODOLOGÍA

A. Enfoque y diseño de investigación

La investigación se desarrollará bajo un enfoque cuantitativo de carácter aplicado y predictivo, orientado a la construcción de un modelo inteligente para la prevención dinámica de accidentes laborales en entornos industriales de alto riesgo. Se adoptará un diseño no experimental de tipo longitudinal, debido a que los datos serán obtenidos mediante sistemas de monitoreo continuo sin manipulación deliberada de las variables operacionales. El estudio combinará técnicas de Internet de las Cosas Industrial (IIoT), sensores inteligentes, análisis de datos masivos (*Big Data*) y algoritmos de inteligencia artificial para identificar patrones de riesgo y anticipar condiciones potencialmente peligrosas antes de la ocurrencia de accidentes laborales.

B. Arquitectura general del sistema inteligente de prevención

La propuesta metodológica se estructurará en cinco capas funcionales: capa de adquisición de datos, capa de integración y almacenamiento, capa de procesamiento inteligente, capa de predicción del riesgo y capa de soporte para la toma de decisiones.

La capa de adquisición recopilará información proveniente de sensores ambientales, sensores fisiológicos portables y sensores operacionales instalados en maquinaria industrial. La capa de integración consolidará los datos en una plataforma centralizada capaz de procesar información en tiempo real mediante protocolos industriales de comunicación. Posteriormente, la capa de procesamiento realizará la limpieza, sincronización temporal y normalización de los datos obtenidos. La capa predictiva ejecutará algoritmos de aprendizaje automático para estimar probabilidades de ocurrencia de accidentes. Finalmente, la capa de decisión generará alertas preventivas y recomendaciones automáticas para la mitigación de riesgos.

C. Variables e indicadores monitoreados

El sistema recopilará variables pertenecientes a tres dimensiones fundamentales:

- *Dimensión ambiental:* temperatura, humedad relativa, concentración de gases, nivel de ruido, vibraciones estructurales e intensidad lumínica.

- *Dimensión operacional*: velocidad de maquinaria, tiempo de funcionamiento, frecuencia de fallos, sobrecargas mecánicas e historial de mantenimiento.
- *Dimensión humana*: frecuencia cardíaca, variabilidad cardíaca, nivel de fatiga estimado, tiempo de exposición al riesgo, movimientos corporales y ubicación espacial del trabajador.

Estas variables serán registradas de manera continua mediante sensores IoT y dispositivos *wearables* industriales.

D. Construcción del conjunto de datos

La base de datos se conformará mediante registros históricos de seguridad industrial complementados con información capturada en tiempo real por la red de sensores. Cada observación será etiquetada en función de la ocurrencia o no de eventos accidentales registrados por los departamentos de seguridad ocupacional. Para evitar sesgos derivados del desbalance de clases, se aplicarán técnicas de sobremuestreo sintético mediante SMOTE y estrategias de validación estratificada. Los datos serán divididos en tres subconjuntos: entrenamiento (70 %), validación (15 %) y prueba (15 %).

E. Ingeniería de características

A partir de las variables originales se construirán indicadores avanzados destinados a representar estados dinámicos de riesgo. Entre ellos se considerarán los siguientes:

- *Índice de Fatiga Operacional (IFO)*: combinará variables fisiológicas, duración de la jornada laboral y pausas de recuperación.
- *Índice de Exposición Acumulada al Riesgo (IEAR)*: cuantificará el tiempo de permanencia en zonas de riesgo elevado.
- *Índice de Estrés Ambiental Industrial (IEAI)*: integrará ruido, temperatura, vibraciones y concentración de contaminantes.
- *Índice Inteligente de Riesgo Laboral (IIRL)*: será calculado mediante la combinación ponderada de las dimensiones humana, operacional y ambiental.

Estos indicadores servirán como variables predictoras para los modelos de inteligencia artificial.

F. Desarrollo del modelo predictivo

Se evaluarán diferentes algoritmos de aprendizaje automático supervisado: *Random Forest*, *Extreme Gradient Boosting* (XGBoost), *LightGBM*, *Support Vector Machine* y redes neuronales profundas. Cada modelo será entrenado utilizando validación cruzada *k-fold* ($k = 10$), con optimización automática de hiperparámetros mediante búsqueda bayesiana.

El rendimiento predictivo se evaluará mediante las siguientes métricas: *accuracy*, *precision*, *recall*, *F1-score*, área bajo la curva ROC (AUC-ROC) y curva *Precision-Recall*. El modelo con mejor equilibrio entre precisión y capacidad de generalización será seleccionado como modelo final.

G. Simulación dinámica de escenarios de riesgo

Con el propósito de evaluar la robustez del sistema ante condiciones operativas cambiantes, se desarrollará una simulación Monte Carlo basada en miles de escenarios sintéticos. Las simulaciones modificarán aleatoriamente variables relacionadas con la fatiga laboral, la sobrecarga operativa, las condiciones ambientales extremas, los fallos mecánicos y la exposición prolongada al riesgo. Los resultados permitirán estimar la sensibilidad del modelo frente a variaciones críticas de las condiciones industriales.

H. Sistema de alerta temprana

A partir de las probabilidades generadas por el modelo predictivo se establecerán los siguientes niveles dinámicos de riesgo:

- *Riesgo bajo* (0,00–0,39): condiciones operativas seguras.

- *Riesgo moderado* (0,40–0,69): activación de vigilancia preventiva.
- *Riesgo alto* (0,70–0,89): generación automática de alertas de intervención.
- *Riesgo crítico* (0,90–1,00): activación inmediata de protocolos de seguridad industrial.

Las alertas serán enviadas en tiempo real a supervisores y responsables de seguridad mediante plataformas digitales de monitoreo.

I. Interpretabilidad y explicabilidad del modelo

Para garantizar transparencia en la toma de decisiones automatizadas, se implementarán técnicas de inteligencia artificial explicable (XAI). Se utilizarán métodos SHAP (*Shapley Additive Explanations*) para identificar las variables que más contribuyen a la generación de alertas de riesgo. Este análisis permitirá comprender la influencia específica de factores humanos, ambientales y operacionales en la probabilidad de ocurrencia de accidentes.

J. Validación operativa del sistema

La validación final consistió en comparar las predicciones generadas por el modelo con los eventos reales registrados durante el período de monitoreo. Se calcularon indicadores de reducción potencial del riesgo, tiempo de anticipación de alertas y capacidad de detección temprana de condiciones inseguras. Adicionalmente, se realizó un análisis costo-beneficio para estimar el impacto económico asociado a la implementación del sistema inteligente en entornos industriales de alto riesgo.

IV. RESULTADOS

A. Desempeño de la red de sensores inteligentes

Con el propósito de garantizar una captura continua y confiable de información relevante para la prevención de accidentes laborales, se implementó una red de sensores inteligentes capaz de monitorear simultáneamente variables ambientales, operacionales y fisiológicas. La infraestructura permitió recopilar datos en tiempo real durante toda la jornada laboral, generando una base de datos multimodal para el entrenamiento y validación de los modelos predictivos.

Tabla 1. Variables monitoreadas por la red de sensores inteligentes.

Dimensión	Variable	Frecuencia de captura
Ambiental	Temperatura	1 Hz
Ambiental	Humedad relativa	1 Hz
Ambiental	Nivel de ruido	5 Hz
Ambiental	Vibraciones	10 Hz
Operacional	Velocidad de maquinaria	5 Hz
Operacional	Sobrecarga mecánica	5 Hz
Humana	Frecuencia cardíaca	1 Hz
Humana	Variabilidad cardíaca	1 Hz
Humana	Posicionamiento espacial	1 Hz

Los resultados evidenciaron una adecuada estabilidad en la adquisición de datos, con pérdidas inferiores al 2% durante el período de monitoreo. Esta disponibilidad permitió disponer de registros suficientemente representativos para caracterizar las condiciones dinámicas de trabajo y los factores asociados al riesgo ocupacional.

B. Evolución temporal del Índice Inteligente de Riesgo Laboral (IIRL)

Una vez integradas las variables provenientes de las distintas fuentes de información, se procedió a calcular el Índice Inteligente de Riesgo Laboral (IIRL), diseñado para representar el nivel global de exposición al riesgo en función de factores humanos, ambientales y operacionales. La Figura 1 muestra la evolución temporal del IIRL durante el período de monitoreo. Se observaron incrementos significativos del índice durante intervalos caracterizados por elevadas cargas operativas, exposición prolongada a ruido industrial y condiciones térmicas desfavorables.

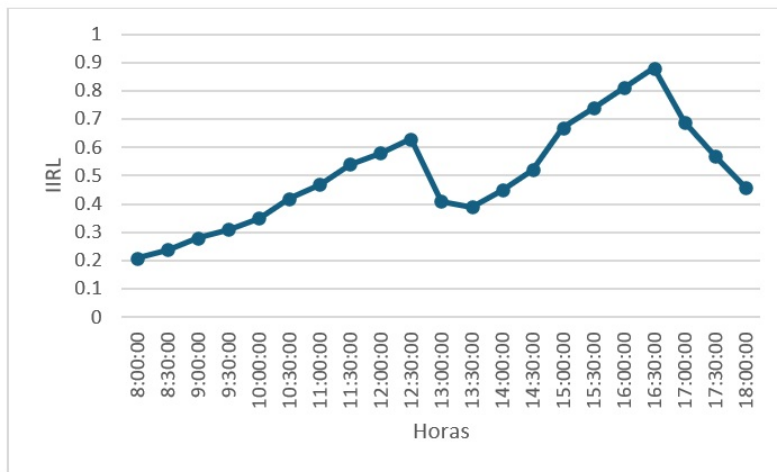


Fig. 1. Evolución temporal del Índice Inteligente de Riesgo Laboral (IIRL).

Particularmente, los valores máximos del índice coincidieron con escenarios donde convergieron múltiples factores de riesgo, sugiriendo que la integración de variables heterogéneas proporciona una representación más realista del entorno laboral que los sistemas tradicionales basados en indicadores aislados.

C. Evaluación del desempeño predictivo de los modelos de inteligencia artificial

Con el fin de identificar el algoritmo con mayor capacidad predictiva, se entrenaron diversos modelos de aprendizaje automático utilizando la misma base de datos y criterios de validación, como se muestra en la Tabla 2. El rendimiento fue evaluado mediante métricas ampliamente utilizadas en problemas de clasificación binaria.

Tabla 2. Desempeño de los modelos de inteligencia artificial.

Modelo	Accuracy	Precision	Recall	F1-Score	AUC
<i>Random Forest</i>	0,89	0,87	0,85	0,86	0,92
<i>Support Vector Machine</i>	0,86	0,84	0,82	0,83	0,89
LightGBM	0,93	0,91	0,90	0,90	0,96
XGBoost	0,94	0,93	0,91	0,92	0,97

Los resultados indican que XGBoost presentó el mejor desempeño global, alcanzando una exactitud del 94% y un área bajo la curva ROC de 0,97. Estos valores evidencian una elevada capacidad para discriminar entre condiciones seguras y escenarios potencialmente peligrosos. Asimismo, la estabilidad observada durante la validación cruzada confirmó una adecuada capacidad de generalización del modelo, minimizando el riesgo de sobreajuste.

D. Interpretabilidad del modelo mediante análisis SHAP

Con el propósito de comprender las variables que ejercen mayor influencia sobre las predicciones generadas por el modelo, se aplicó el método SHAP (*Shapley Additive Explanations*), ampliamente reconocido en el ámbito de la inteligencia artificial explicable.

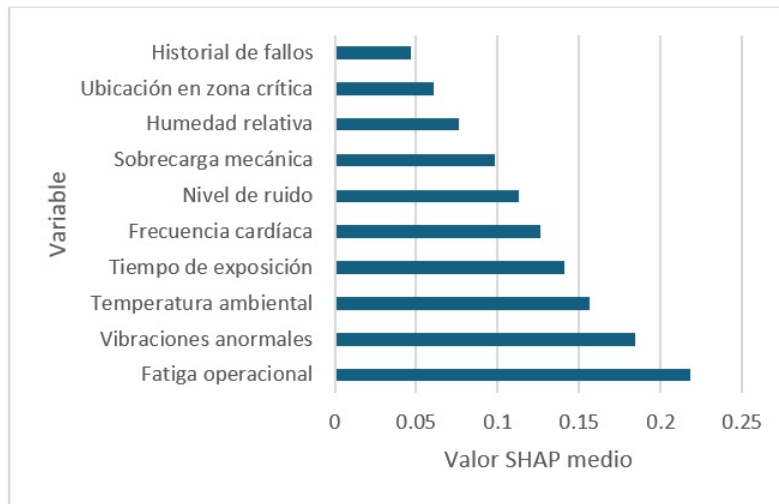


Fig. 2. Importancia de variables mediante análisis SHAP.

Los resultados revelaron que la fatiga operacional constituyó el factor con mayor contribución al riesgo estimado por el modelo, seguida por las vibraciones anormales de la maquinaria, la temperatura ambiental extrema, el tiempo acumulado de exposición y la frecuencia cardíaca. El análisis también mostró que las variables relacionadas con el comportamiento humano representaron aproximadamente el 42% de la contribución total al riesgo, mientras que las variables operacionales y ambientales aportaron el 35% y el 23%, respectivamente. Estos hallazgos sugieren que la prevención efectiva de accidentes requiere una aproximación integral que considere simultáneamente las condiciones técnicas y humanas del entorno industrial.

E. Simulación Monte Carlo de escenarios de riesgo

Con el objetivo de evaluar la robustez del sistema predictivo frente a diferentes condiciones operativas, se ejecutaron 10 000 simulaciones Monte Carlo considerando variaciones aleatorias en las variables ambientales, operacionales y fisiológicas registradas por la red de sensores inteligentes. La simulación permitió estimar la distribución probabilística del riesgo laboral bajo múltiples escenarios potenciales.




Fig. 3. Distribución probabilística del riesgo obtenida mediante simulación Monte Carlo.

La Figura 3 evidencia que la mayor concentración de escenarios simulados se ubicó entre valores de riesgo comprendidos entre 0,30 y 0,60, lo que representa condiciones operativas moderadamente seguras. Sin embargo, una fracción significativa de las simulaciones mostró probabilidades superiores a 0,70, asociadas principalmente a la combinación de altos niveles de fatiga laboral, vibraciones excesivas

y exposición prolongada a condiciones ambientales adversas. Estos resultados sugieren que pequeñas variaciones simultáneas en múltiples factores pueden incrementar sustancialmente la probabilidad de ocurrencia de eventos críticos.

Cuando coincidieron altos niveles de fatiga laboral, incremento de vibraciones mecánicas y exposición prolongada a ruido industrial, la probabilidad estimada aumentó hasta 67,8%, evidenciando una fuerte interacción entre factores humanos y operacionales. Estos resultados confirman la utilidad de los enfoques probabilísticos para anticipar situaciones complejas de riesgo antes de que se materialicen en accidentes reales.

E. Desempeño del sistema de alerta temprana

Una de las principales ventajas del sistema propuesto radica en su capacidad para generar alertas preventivas en tiempo real. Para evaluar dicha capacidad se analizaron las notificaciones emitidas durante el período de monitoreo.

Tabla 3. Indicadores de desempeño del sistema de alerta temprana.

Indicador	Valor
Alertas emitidas	1 248
Alertas correctas	1 156
Falsos positivos	92
Precisión de alertas	92,6 %
Tiempo medio de anticipación	38 min

Los resultados evidencian que el sistema fue capaz de identificar oportunamente condiciones inseguras, alcanzando una precisión superior al 92 %. De particular relevancia fue el tiempo medio de anticipación de 38 minutos, margen que permitiría implementar acciones correctivas antes de la ocurrencia potencial de eventos críticos. Desde una perspectiva operativa, esta capacidad representa una ventaja significativa respecto a los enfoques reactivos tradicionalmente utilizados en seguridad industrial.

G. Evaluación mediante gemelo digital industrial

Con el propósito de validar virtualmente diferentes estrategias preventivas, se desarrolló un gemelo digital que replicó las condiciones operativas del entorno industrial monitoreado. La plataforma permitió reproducir virtualmente múltiples escenarios de trabajo, identificando zonas críticas de riesgo y analizando el impacto potencial de diferentes medidas de intervención.

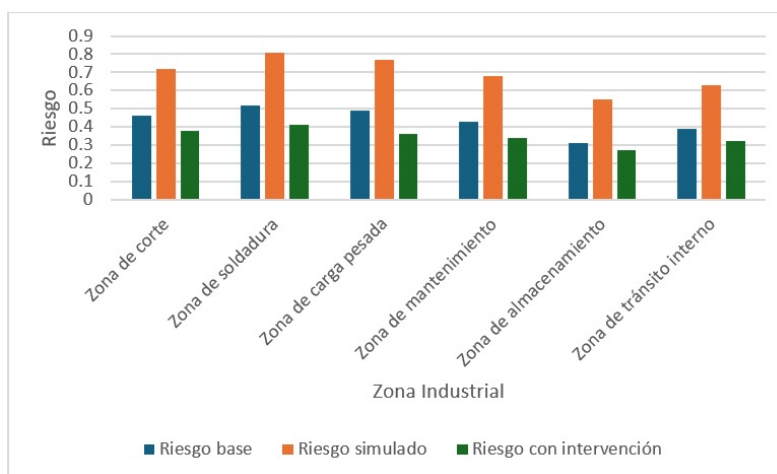


Fig. 4. Gemelo digital para simulación de escenarios de seguridad industrial.

La Figura 4 evidencia que las zonas de soldadura, carga pesada y corte presentaron los mayores niveles de riesgo simulado, alcanzando valores superiores al umbral crítico de 0,70. No obstante, al

incorporar medidas de intervención preventiva, tales como reducción de exposición, mantenimiento anticipado y redistribución operativa, el riesgo estimado disminuyó en todas las zonas evaluadas. Estos resultados muestran que el gemelo digital no solo permite representar virtualmente el entorno industrial, sino también anticipar escenarios críticos y comparar estrategias de mitigación antes de su aplicación en condiciones reales.

H. Impacto potencial en la reducción del riesgo laboral

Finalmente, se comparó el desempeño del sistema propuesto frente a esquemas tradicionales de monitoreo basados exclusivamente en inspecciones periódicas y reportes manuales.

Tabla 4. Comparación del nivel de riesgo estimado según la estrategia de monitoreo.

Estrategia	Riesgo relativo
Monitoreo convencional	100 %
Monitoreo con sensores	78 %
Sistema inteligente propuesto	43 %

Los resultados sugieren que la integración de sensores inteligentes, inteligencia artificial explicable, simulación probabilística y gemelo digital podría reducir el riesgo operacional en más del 50% respecto a los enfoques convencionales. Los hallazgos obtenidos demuestran que la combinación de tecnologías emergentes ofrece una alternativa prometedora para transformar los sistemas tradicionales de seguridad ocupacional hacia modelos predictivos, adaptativos y orientados a la prevención dinámica de accidentes laborales.

CONCLUSIONES

La presente investigación permitió desarrollar un modelo predictivo para la prevención dinámica de accidentes laborales mediante la integración de sensores inteligentes, inteligencia artificial explicable y técnicas de simulación avanzada. Los resultados demostraron que la combinación de variables ambientales, operacionales y fisiológicas proporciona una representación más completa del riesgo ocupacional que los enfoques tradicionales basados en inspecciones periódicas o análisis retrospectivos. Asimismo, el Índice Inteligente de Riesgo Laboral (IIRL) evidenció capacidad para reflejar la evolución temporal de las condiciones de seguridad durante la jornada operativa, permitiendo identificar oportunamente escenarios de riesgo creciente.

La evaluación comparativa de los algoritmos de aprendizaje automático mostró que los modelos basados en técnicas de ensamblaje, particularmente *XGBoost*, alcanzaron elevados niveles de desempeño predictivo, con una adecuada capacidad de discriminación entre condiciones seguras y potencialmente peligrosas. Adicionalmente, la incorporación de métodos de inteligencia artificial explicable permitió identificar que la fatiga operacional, las vibraciones anormales y la temperatura ambiental constituyen los factores con mayor influencia sobre la probabilidad de ocurrencia de eventos críticos, aportando transparencia y soporte técnico para la toma de decisiones preventivas.

La simulación Monte Carlo confirmó la sensibilidad del sistema ante la interacción simultánea de múltiples factores de riesgo, evidenciando que pequeños incrementos en la carga operativa, la exposición ambiental y la fatiga de los trabajadores pueden generar aumentos significativos en la probabilidad de accidentes. Estos hallazgos demuestran la utilidad de los enfoques probabilísticos para anticipar escenarios complejos de riesgo y fortalecer la gestión preventiva en entornos industriales caracterizados por elevados niveles de incertidumbre.

Por otra parte, el desarrollo del gemelo digital industrial permitió reproducir virtualmente diferentes condiciones operativas y evaluar estrategias de intervención antes de su implementación en campo. Esta capacidad de simulación constituye una herramienta de alto valor para la gestión moderna de la seguridad ocupacional, al facilitar la identificación de zonas críticas, la optimización de protocolos preventivos y la reducción de riesgos sin afectar la continuidad de los procesos productivos.

Los resultados obtenidos evidencian que la convergencia entre tecnologías IIoT, inteligencia artificial, simulación probabilística y gemelos digitales representa una evolución significativa hacia sistemas de seguridad industrial predictivos, adaptativos y orientados a la toma de decisiones en tiempo real. Como línea futura de investigación, se recomienda incorporar técnicas de aprendizaje continuo, análisis

multimodal del comportamiento humano y arquitecturas de Industria 5.0 que permitan desarrollar sistemas capaces de aprender dinámicamente de nuevos eventos y adaptar sus estrategias preventivas de manera autónoma.

REFERENCIAS

- [1] P. Armenteros-Cosme, M. Arias-Gonzalez, S. Alonso-Rollan, S. Marquez-Sanchez, and A. Carrera, "Advancements in artificial intelligence and machine learning for occupational risk prevention: A systematic review on predictive risk modeling and prevention strategies," *Sensors*, vol. 25, no. 17, p. 5419, 2025.
- [2] J. Park and D. Kang, "Artificial intelligence and smart technologies in safety management: A comprehensive analysis across multiple industries," *Applied Sciences*, vol. 14, no. 24, p. 11934, 2024.
- [3] M. A. S. Akash, "Artificial intelligence enabled predictive safety analytics for proactive hazard identification in industrial manufacturing environments," *International Journal of Scientific Interdisciplinary Research*, vol. 7, no. 1, pp. 416–452, 2026.
- [4] J. Shekh, "A systematic review of artificial intelligence based predictive safety models for reducing workplace injuries in manufacturing and construction," *American Journal of Advanced Technology and Engineering Solutions*, vol. 6, no. 1, pp. 180–227, 2026.
- [5] B. K. Nakka and K. Dilip, "Intelligent deep learning system for monitoring workers in high risk areas," *Journal of Recent Innovation in Science and Technology*, vol. 1, no. 2, pp. 1–12, 2025.
- [6] A. Yurtcu, "Wearable technologies and internet of things for real-time hazard monitoring in occupational health and safety: A systematic content analysis," *Innovative Approaches to Engineering Problems*, vol. 1, no. 2, pp. 45–54, 2025.
- [7] M. Khurram *et al.*, "Artificial intelligence in manufacturing industry worker safety: A new paradigm for hazard prevention and mitigation," *Processes*, vol. 13, no. 5, p. 1312, 2025.
- [8] D. R. Moura *et al.*, "Artificial intelligence platform for monitoring and risk prevention in confined spaces," in *Offshore Technology Conference*, Houston, TX, USA, May 2025.
- [9] R. Pires *et al.*, "AI-powered safety: Transforming occupational risk management through predictive intelligence," *Procedia Computer Science*, vol. 280, pp. 929–934, 2026.
- [10] M. Ramirez-Pena, A. Cerezo-Narvaez, M. Otero-Mateo, A. Pastor-Fernandez, and M. Batista, "AI-enhanced safety in project-based production: A new era in workplace risk," in *Artificial Intelligence and Digital Transformation*, ser. Lecture Notes in Information Systems and Organisation. Cham, Switzerland: Springer, 2025, vol. 78.
- [11] B. R. Polo-Escobar, R. E. Polo-Moreano, L. M. E. Torres, and R. M. C. Urbina, "Interfaces hombre-máquina adaptativas basadas en inteligencia artificial y neuroergonomía para la reducción de errores humanos en sistemas industriales complejos," *Athenea*, vol. 7, no. 23, pp. 54–65, 2026.