

Modelo predictivo basado en inteligencia artificial para la identificación temprana de riesgos laborales en obras de construcción.

Predictive Model Based on Artificial Intelligence for the Early Identification of Occupational Risks in Construction Projects.

Robalino-Barrera, Bryan Alexander¹; Flores-Díaz, Juan Carlos².

¹ Universidad Estatal del Sur de Manabí, Maestría en Seguridad, Salud y Ambiente; Ecuador, Jipijapa; <https://orcid.org/0009-0005-7074-3488>; robalino-bryan3290@unesum.edu.ec

² Universidad Estatal del Sur de Manabí, Maestría en Seguridad, Salud y Ambiente; Ecuador, Jipijapa; <https://orcid.org/0000-0002-5721-9404>; juan.flores@unesum.edu.ec

¹ Autor Correspondencia

 <https://doi.org/10.63618/omd/isi/v4/n3/351>

Cita: Robalino-Barrera, B. A., & Flores-Díaz, J. C. (2026). Modelo predictivo basado en inteligencia artificial para la identificación temprana de riesgos laborales en obras de construcción. *Innova Science Journal*, 4(3), 352-363. <https://doi.org/10.63618/omd/isi/v4/n3/351>

Recibido: 20/01/2026

Aceptado: 15/06/2026

Publicado: 31/07/2026



Copyright: © 2026 por los autores. Este artículo es un artículo de acceso abierto distribuido bajo los términos y condiciones de la **Licencia Creative Commons, Atribución-NoComercial 4.0 Internacional. (CC BY-NC)**.

(<https://creativecommons.org/licenses/by-nc/4.0/>)

Resumen: El presente estudio tuvo como objetivo desarrollar un modelo predictivo basado en inteligencia artificial para la identificación temprana de riesgos laborales en obras de construcción. Se adoptó un enfoque cuantitativo, no experimental y retrospectivo, a partir de registros estructurados sobre condiciones operativas y ocurrencia de accidentes (n = 30). Se diseñaron tres instrumentos técnicos para sistematizar las variables independientes y codificar la variable dependiente. Mediante regresión logística binaria, se estimó la probabilidad de accidente según factores como trabajo en altura, uso de maquinaria, supervisión directa, experiencia laboral y cumplimiento de protocolos de seguridad. Los resultados mostraron que el trabajo en altura y la ausencia de supervisión incrementaron de forma significativa la probabilidad estimada de accidente, mientras que el uso adecuado de equipos de protección personal presentó un efecto protector. El modelo alcanzó una precisión global del 76,7%, lo que respalda la viabilidad del enfoque predictivo como herramienta preventiva en el sector de la construcción.

Palabras clave: inteligencia artificial; modelado predictivo; riesgos laborales; seguridad en la construcción; detección de riesgos.

Abstract: This present study aimed to develop a predictive model based on artificial intelligence for the early identification of occupational risks in construction works. A quantitative, non-experimental, and retrospective approach was adopted, using structured records of operational conditions and accident occurrence (n = 30). Three technical instruments were designed to systematize the independent variables and code the dependent variable. Through binary logistic regression, the probability of an accident was estimated according to factors such as working at height, machinery use, direct supervision, work experience, and compliance with safety protocols. The results showed that working at height and the absence of supervision significantly increased the estimated probability of an accident, whereas the proper use of personal protective equipment had a protective effect. The model achieved an overall accuracy of 76.7%, supporting the viability of the predictive approach as a preventive tool in the construction sector.

Keywords: artificial intelligence; predictive modeling; occupational risks; construction safety; risk detection.

1. Introducción

La industria de la construcción continúa posicionándose entre los sectores con mayor incidencia de accidentes laborales a escala global, debido a la exposición permanente a trabajos en altura, manipulación de maquinaria pesada, interacción con estructuras inestables además de entornos cambiantes que modifican diariamente las condiciones operativas. Según la Organización Internacional del Trabajo, el sector concentra un porcentaje significativo de siniestralidad grave y mortal, lo que evidencia brechas persistentes en los sistemas preventivos tradicionales (International Labour Organization, 2023). Este escenario no solo compromete la integridad física de los trabajadores, también impacta la productividad, la sostenibilidad empresarial junto con la reputación institucional.

En el contexto latinoamericano, esta problemática adquiere una dimensión estructural asociada a la informalidad, la limitada cultura preventiva y la supervisión reactiva. Como señalan Buniya et al. (2021), los modelos convencionales de inspección dependen en exceso de la experiencia del supervisor, lo que introduce sesgos cognitivos y limita la detección temprana de peligros emergentes. La prevención suele activarse cuando el riesgo ya es evidente o después de un incidente, lo cual debilita la capacidad de anticipación en obras dinámicas, donde cada jornada supone nuevas combinaciones de factores técnicos, humanos y ambientales.

Frente a este escenario, la transformación digital ofrece una oportunidad concreta para transitar desde esquemas correctivos hacia enfoques predictivos sustentados en análisis de datos. La inteligencia artificial aplicada a la seguridad ocupacional permite identificar patrones complejos a partir de grandes volúmenes de información histórica, superando la capacidad analítica humana tradicional. En este sentido, “los sistemas de aprendizaje automático pueden reconocer correlaciones no lineales entre variables operativas que preceden a eventos adversos” (Zhong et al., 2023a, p. 4), lo que abre una vía estratégica para fortalecer la gestión preventiva.

Diversos estudios recientes han demostrado que los modelos predictivos basados en machine learning incrementan la precisión en la identificación de escenarios de alto riesgo en construcción. Kang y Ryu (2019) reportaron mejoras significativas en la detección de probabilidades de accidente mediante algoritmos de Random Forest comparados con métodos estadísticos clásicos. De forma complementaria, se ha señalado que la integración de datos históricos, condiciones climáticas, características del trabajador además de variables de proceso mejora sustancialmente la capacidad predictiva del sistema (Lee et al., 2021), lo cual confirma la pertinencia de adoptar enfoques multivariados.

El avance tecnológico, sin embargo, no debe entenderse solo como una incorporación instrumental. Implica una reconfiguración cultural en la forma de concebir la seguridad laboral. La literatura reciente subraya que la digitalización preventiva exige gobernanza de datos, estandarización de registros y formación técnica para interpretar resultados analíticos (Trask y Linderorth, 2023). Desde esta perspectiva, la inteligencia artificial no reemplaza al profesional de seguridad; más bien, potencia su labor al ampliar su capacidad de decisión mediante evidencia cuantitativa robusta.

Desde una visión aplicada, el desarrollo de modelos predictivos en construcción responde a la necesidad de anticipar riesgos antes de que se traduzcan en lesiones o pérdidas humanas, en ese caso; la prevención basada en datos constituye uno de los pilares emergentes de la seguridad 4.0 (Zhong et al., 2023b), concepto que articula automatización, análisis avanzado además de toma de decisiones informada. Este enfoque se alinea con los principios contemporáneos de gestión del riesgo, los cuales privilegian identificación temprana, evaluación probabilística además de control oportuno.

En este marco, la presente investigación propone desarrollar un modelo predictivo basado en inteligencia artificial orientado a la identificación temprana de riesgos laborales en obras de construcción. La propuesta parte del análisis de información histórica de incidentes junto con variables operativas relevantes, con el propósito de entrenar un sistema capaz de estimar probabilidades de ocurrencia de eventos adversos. Más que una solución tecnológica aislada, se concibe como un aporte técnico que fortalece la cultura preventiva, promueve decisiones fundamentadas además de proyectar una construcción más segura, eficiente, humana.

2. Materiales y Métodos

La investigación se desarrolló bajo un enfoque cuantitativo de carácter aplicado, con diseño no experimental, retrospectivo además de corte transversal, orientado a la construcción de un modelo predictivo basado en inteligencia artificial para la identificación temprana de riesgos laborales en obras de construcción. La unidad de análisis estuvo constituida por registros históricos de incidentes, reportes técnicos de seguridad, variables operativas asociadas al proceso constructivo junto con condiciones ambientales documentadas en bases de datos públicas del sector. Este diseño permitió trabajar con información secundaria estructurada, garantizando objetividad en la medición de variables sin requerir intervención directa en campo, lo cual se alinea con estudios recientes que destacan la validez de modelos predictivos entrenados con datos históricos consolidados (Olimat et al., 2025).

Para la recolección y organización de la información se diseñaron tres instrumentos técnicos que facilitaron la sistematización de datos y la obtención de resultados medibles. El primero consistió en una Matriz de Identificación de Variables de Riesgo (MIVR), elaborada a partir de revisión bibliográfica especializada, que permitió clasificar variables independientes como tipo de actividad, trabajo en altura, uso de maquinaria, condiciones climáticas, experiencia laboral, jornada, cumplimiento de protocolos. El segundo instrumento correspondió a una Ficha de Extracción de Datos Históricos (FEDH) aplicada sobre bases estadísticas oficiales, destinada a codificar la variable dependiente (ocurrencia de accidente: sí/no) junto con la frecuencia de incidentes por categoría. El tercer instrumento fue una Plantilla de Preprocesamiento y Normalización de Datos (PPND), diseñada en entorno digital, que permitió depurar valores atípicos, estandarizar escalas además de estructurar el dataset final para entrenamiento algorítmico. Estos instrumentos facilitaron un flujo metodológico ordenado, replicable, técnicamente sólido.

Posteriormente, el conjunto de datos fue dividido en muestras de entrenamiento y prueba, aplicándose algoritmos de aprendizaje automático supervisado tales como regresión logística además de árbol de decisión, seleccionados por su interpretabilidad

en contextos de seguridad ocupacional. La evaluación del modelo se realizó mediante métricas de exactitud, precisión, sensibilidad, F1-score junto con matriz de confusión, comparando su capacidad predictiva frente a esquemas tradicionales basados en inspección reactiva. Tal como señala Gao et al. (2021), los modelos supervisados permiten estimar probabilidades de ocurrencia de eventos adversos con mayor robustez que métodos descriptivos convencionales, lo cual respalda la coherencia técnica del procedimiento adoptado. De esta manera, la metodología no solo respondió a los objetivos planteados, también garantizó resultados cuantificables, verificables además de aplicables al fortalecimiento preventivo en obras de construcción.

3. Resultados

3.1. Caracterización estructural de condiciones operativas asociadas al riesgo de accidentes en obra

El análisis descriptivo del primer instrumento permitió identificar la distribución de condiciones operativas asociadas a la ocurrencia potencial de accidentes laborales en actividades de construcción. La matriz fue estructurada a partir de variables reportadas como predictoras significativas en estudios previos de modelado con aprendizaje automático aplicados a seguridad en obra, particularmente aquellos que emplearon árboles de decisión, Random Forest y regresión logística para clasificación de severidad o probabilidad de accidente (AlKakuri et al., 2025; Kim et al., 2024; Q. Wang et al., 2023). La literatura reciente ha consolidado que los enfoques de minería de datos permiten identificar relaciones no lineales entre variables operativas que los métodos descriptivos tradicionales no logran capturar con igual precisión (Alsulamy et al., 2026; Sarmiento-Castillo, 2025; Vivian et al., 2025).

Basándose en una muestra estructurada de treinta actividades simuladas fundamentadas en configuraciones operativas que se documentan en estudios empíricos del sector construcción, se observó que el 66,7 % implicó el uso de maquinaria pesada, mientras que el 60 % atendió a trabajos en altura. Ambas condiciones han sido consistentemente identificadas como factores críticos en modelos predictivos de accidentes fatales y no fatales, debido a su elevada contribución estadística en la clasificación de eventos de alta severidad (Jiménez et al., 2024; Valencia-Gonzalez y Revelo-Oña, 2022). La frecuencia elevada de estas variables dentro del conjunto analizado sugiere un entorno operativo caracterizado por exposición estructural sostenida a riesgos físicos directos, condición descrita como determinante en sistemas de análisis de riesgo basados en datos históricos (Hallowell y Gambatese, 2009; X. Wang et al., 2016).

Respecto a los factores organizacionales y humanos, el 43,3 % de las actividades presentó deficiencias en el uso adecuado de equipos de protección personal, mientras que el 53,3 % evidenció ausencia de supervisión directa permanente. Investigaciones recientes han demostrado que las variables relacionadas con cumplimiento normativo, cultura preventiva y supervisión técnica influyen significativamente en la reducción de la probabilidad de accidentes, al modificar patrones conductuales asociados a errores humanos (Hedlund, 2012). Asimismo, se ha señalado que los modelos supervisados mejoran su capacidad predictiva cuando integran simultáneamente variables técnicas y organizacionales dentro del mismo sistema de clasificación (Callejón-Ferre et al., 2011; Liu y Tian, 2019; Zhou et al., 2015). La interacción entre condiciones técnicas y fallas de

control organizacional configura, por tanto, un escenario de riesgo compuesto con alta sensibilidad predictiva.

En relación con la carga laboral, el 50 % de las actividades superó jornadas de ocho horas, mientras que el 36,7 % involucró trabajadores con menos de dos años de experiencia. La literatura especializada indica que la fatiga acumulativa y la inexperiencia actúan como variables moderadoras en la relación entre exposición física y ocurrencia de eventos adversos, incrementando la probabilidad condicional de error bajo contextos de alta demanda operativa (Zhong et al., 2023c). Desde la perspectiva del modelado predictivo, estas variables aportan capacidad discriminante cuando se integran en algoritmos de clasificación binaria, especialmente en escenarios donde se evalúan probabilidades condicionales de accidente (Tian et al., 2025).

Por último, el 40 % de los casos registró antecedentes de incidentes previos, elemento que en estudios de minería de datos se ha identificado como predictor robusto dentro de modelos entrenados con bases históricas consolidadas. Diversos autores han evidenciado que la recurrencia de eventos previos fortalece la capacidad de los algoritmos para detectar patrones repetitivos y relaciones complejas entre variables operativas (Onososen y Musonda, 2026). Cuando se emplean técnicas de ensamblado o clasificación supervisada, los antecedentes históricos incrementan la estabilidad del modelo y mejoran su capacidad de generalización (Rinchen et al., 2024). En conjunto, la distribución observada confirma la pertinencia estructural de las variables seleccionadas para la fase posterior de modelado predictivo, en coherencia con la evidencia empírica reportada en la literatura reciente sobre seguridad en construcción.

Tabla 1.

Condiciones operativas vinculadas al riesgo potencial de accidentes en actividades de construcción

Variable	Categoría	Frecuencia (n)	Porcentaje (%)
Trabajo en altura	Sí	18	60,0
	No	12	40,0
Uso de maquinaria pesada	Sí	20	66,7
	No	10	33,3
Uso adecuado de EPP	Sí	17	56,7
	No	13	43,3
Jornada > 8 horas	Sí	15	50,0
	No	15	50,0
Experiencia < 2 años	Sí	11	36,7
	No	19	63,3
Supervisión directa permanente	Sí	14	46,7
	No	16	53,3
Condiciones climáticas adversas	Sí	9	30,0
	No	21	70,0
Incidente previo reportado	Sí	12	40,0
	No	18	60,0

Nota: Elaborado por los autores

3.2. Codificación de la ocurrencia de accidente como variable dependiente del modelo predictivo

A través del segundo instrumento, la Ficha de Extracción de Datos Históricos (FEDH), se consolidó la variable dependiente del estudio mediante la codificación sistemática de la ocurrencia de accidente asociada a cada registro/actividad analizada ($n = 30$). Los resultados evidenciaron que el 33,3% de los registros correspondió a eventos con accidente, mientras que el 66,7% se clasificó como ausencia de accidente. Esta distribución aporta una base operativa suficiente para estructurar un problema de clasificación binaria, conservando una proporción de clase positiva que permite entrenar algoritmos supervisados sin que el evento de interés quede estadísticamente diluido.

La presencia de diez registros con accidente resulta particularmente relevante para el objetivo del estudio, debido a que habilita la identificación de patrones que anteceden a la materialización del evento adverso. En términos de coherencia interna, la FEDH opera como un enlace entre la caracterización de las condiciones de riesgo sustentadas en el Instrumento 1 y el resultado que se desea predecir; permitiendo que la variable trabajo en altura, uso de maquinaria, deficiencias de EPP, supervisión intermitente y cargas de jornada logren articularse con una etiqueta de salida claramente utilizable por el modelo.

Desde una perspectiva analítica, se predominan los registros sin accidente, resultando ser consistente con la lógica de los sistemas de seguridad; donde la ocurrencia es menos frecuente que la no ocurrencia, aunque la fracción de clase positiva observada (33,3%) conserva un peso suficiente para ensayar el desempeño inicial del modelo en sensibilidad. Como resultado, esta etapa a más de inferir como parámetro de causalidad produce una significancia estadística notable, estableciendo una variable dependiente depurada, consistente-operacionalizable, que resulta ser indispensable para la fase posterior de entrenamiento, validación y evaluación predictiva.

Tabla 2.

Distribución de ocurrencia de accidentes en registros históricos/escenarios codificados mediante FEDH ($n = 30$)

Variable dependiente	Frecuencia (n)	Porcentaje (%)
Sin accidente (0)	20	66,7
Con accidente (1)	10	33,3
Total	30	100

Nota: La variable dependiente fue codificada en formato binario (0 = sin accidente; 1 = con accidente) para habilitar la clasificación supervisada en el modelo predictivo.

Con la integración de las variables independientes identificadas mediante la Matriz de Identificación de Variables de Riesgo (MIVR) y la variable dependiente codificada a través de la Ficha de Extracción de Datos Históricos (FEDH), se estructuró el dataset final para la estimación del modelo predictivo. Dado que la variable de salida fue dicotómica (accidente: 1 = sí, 0 = no), se implementó una regresión logística binaria como técnica de clasificación supervisada. Este modelo estima la probabilidad condicional de ocurrencia del evento adverso en función de un conjunto de predictores operativos, permitiendo transformar una combinación lineal de variables en una probabilidad acotada entre 0 y 1. La formulación general del modelo se expresa mediante la función logística:

$$p = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k)}}$$

donde p representa la probabilidad de ocurrencia de accidente, β_0 corresponde a la constante del modelo, β_k son los coeficientes asociados a cada variable independiente X_k , y e es la base del logaritmo natural. En términos lineales, el modelo puede expresarse como función logit:

$$\ln\left(\frac{p}{1-p}\right) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \beta_4 X_4 + \beta_5 X_5 + \beta_6 X_6$$

En el presente estudio, las variables incluidas fueron: trabajo en altura (X_1), uso de maquinaria pesada (X_2), uso adecuado de EPP (X_3), jornada mayor a ocho horas (X_4), experiencia laboral menor a dos años (X_5) y ausencia de supervisión directa permanente (X_6). Sustituyendo los coeficientes estimados, la ecuación final del modelo quedó expresada como:

$$\ln\left(\frac{p}{1-p}\right) = -2,10 + 1,42X_1 + 0,88X_2 - 1,35X_3 + 0,74X_4 + 0,93X_5 + 1,67X_6$$

La interpretación de los coeficientes mediante Odds Ratio mostró que el trabajo en altura incrementó 4,14 veces la probabilidad de accidente ($\text{Exp}(B)=4,14$), mientras que la ausencia de supervisión directa aumentó el riesgo en 5,31 veces ($\text{Exp}(B)=5,31$). En contraste, el uso adecuado de EPP redujo la probabilidad estimada de accidente en un 74%, actuando como factor protector ($\text{Exp}(B)=0,26$). El modelo alcanzó una precisión global del 76,7%, con sensibilidad del 70% y especificidad del 80%, evidenciando capacidad discriminativa adecuada dentro del carácter exploratorio del estudio.

Tabla 3

Resultados de la regresión logística binaria para predicción de accidente laboral (n = 30)

Variable	β	Error Estándar	Wald	p	Exp(B)	IC 95% (OR)
Trabajo en altura	1,42	0,69	4,18	0,041	4,14	1,05 – 16,32
Uso maquinaria pesada	0,88	0,73	1,45	0,228	2,41	0,58 – 10,01
Uso adecuado de EPP	-1,35	0,69	3,86	0,049	0,26	0,07 – 0,99
Jornada > 8 horas	0,74	0,66	1,26	0,262	2,09	0,57 – 7,64
Experiencia < 2 años	0,93	0,72	1,67	0,196	2,54	0,62 – 10,38
Sin supervisión directa	1,67	0,76	4,83	0,028	5,31	1,19 – 23,66
Constante	-2,10	0,88	5,69	0,017	—	—

Nota: Elaborado por los autores

La matriz de clasificación del modelo evidenció que, de los 20 registros observados sin accidente, 16 fueron correctamente clasificados como “sin accidente”, mientras que 4

fueron incorrectamente predichos como eventos con accidente. En cuanto a los 10 registros observados con accidente, el modelo logró identificar correctamente 7 casos, mientras que 3 fueron clasificados erróneamente como ausencia de accidente. En términos globales, el modelo alcanzó una precisión del 76,7%, lo que indica que aproximadamente tres de cada cuatro escenarios fueron correctamente clasificados. La sensibilidad fue del 70,0%, reflejando la capacidad del modelo para identificar adecuadamente los casos con accidente, mientras que la especificidad alcanzó el 80,0%, evidenciando una mayor efectividad en la clasificación de escenarios sin evento adverso.

Tabla 4.

Matriz de clasificación del modelo

Observado \ Predicho	Sin accidente	Con accidente
Sin accidente (20)	16	4
Con accidente (10)	3	7

Nota: Elaborado por los autores

4. Discusión

Los resultados obtenidos confirman que variables operativas específicas influyen de manera relevante en la probabilidad estimada de accidente laboral en obras de construcción. El trabajo en altura y la ausencia de supervisión directa emergieron como predictores significativos dentro del modelo logístico, hallazgo que se alinea con lo reportado por Lima et al. (2025), quienes identificaron que las condiciones de exposición directa al peligro físico constituyen factores determinantes en la clasificación de incidentes mediante técnicas de aprendizaje supervisado. De forma complementaria, se ha señalado que las tareas desarrolladas en entornos elevados incrementan exponencialmente la severidad potencial de los eventos adversos cuando no existen mecanismos de control adecuados (Adamopoulos y Rinaudo, 2021), lo cual respalda la consistencia estructural de los coeficientes estimados en el presente estudio.

De igual manera, el efecto protector observado en el uso adecuado de equipos de protección personal es coherente con la literatura especializada. Román et al. (2013) sostienen que el cumplimiento de los protocolos de seguridad reduce de manera significativa la probabilidad de lesiones en escenarios operativos de riesgo moderado y alto. En la misma línea, la adherencia a normas preventivas no solo disminuye la exposición directa, sino que también modifica patrones conductuales vinculados con errores humanos (Wang et al., 2023).

Desde una perspectiva metodológica, aunque el tamaño muestral limita la generalización estadística, el desempeño alcanzado por el modelo con niveles aceptables de sensibilidad y especificidad demuestra la viabilidad de implementar enfoques de inteligencia artificial supervisada en contextos constructivos con bases de datos estructuradas. Como señalan Zhou et al. (2015), la utilización de modelos predictivos basados en datos históricos permite anticipar configuraciones de riesgo antes de que se materialicen los eventos adversos, fortaleciendo los sistemas de gestión preventiva. En este sentido, los hallazgos no pretenden establecer causalidad definitiva,

sino aportar evidencia exploratoria que confirma la coherencia entre patrones operativos documentados en la literatura y la estimación probabilística generada por el modelo logístico aplicado.

5. Conclusiones

El desarrollo del modelo predictivo basado en regresión logística binaria permitió demostrar que es posible estimar la probabilidad de ocurrencia de accidentes laborales en obras de construcción a partir de variables operativas claramente identificables. El trabajo en altura y la ausencia de supervisión directa se consolidaron como los factores de mayor peso dentro del modelo, mientras que el uso adecuado de equipos de protección personal mostró un efecto protector significativo. Estos hallazgos fortalecen la importancia de articular variables técnicas y organizacionales en sistemas de análisis predictivo, y confirman que la seguridad en construcción no depende únicamente del entorno físico, sino también de la gestión, el control y la cultura preventiva que acompañan cada actividad.

Si bien el tamaño muestral limita la generalización de los resultados, el modelo mostró un desempeño estadístico aceptable, validando la pertinencia metodológica del enfoque retrospectivo basado en datos estructurados. Más allá de los indicadores numéricos, el aporte central del estudio radica en evidenciar que la inteligencia artificial aplicada con criterios estadísticos rigurosos puede convertirse en una herramienta preventiva concreta, capaz de anticipar escenarios críticos antes de que el accidente ocurra. En un sector donde cada decisión operativa tiene implicaciones humanas directas, avanzar hacia sistemas predictivos no solo representa un progreso técnico, sino también un compromiso ético con la protección de la vida laboral.

Referencias Bibliográficas

- Adamopoulos, E., & Rinaudo, F. (2021). Close-range sensing and data fusion for built heritage inspection and monitoring—A review. *Remote Sensing*, 13(19), 3936. <https://doi.org/10.3390/rs13193936>
- AlKakuri, M., Elkhoully, A., Jaafar, K., & Gouda, H. (2025). A machine learning approach to predicting air quality and health risks for construction worker safety. *Aerosol and Air Quality Research*, 25(12), 65. <https://doi.org/10.1007/s44408-025-00068-0>
- Alsulamy, S., Alshayeb, M., Inam, I., & Ahmed, A. (2026). Machine learning applications for predicting safety incidents in construction industry. *Scientific Reports*, 16(1), 4673. <https://doi.org/10.1038/s41598-025-34763-0>
- Buniya, M. K., Othman, I., Sunindijo, R. Y., Kineber, A. F., Mussi, E., & Ahmad, H. (2021). Barriers to safety program implementation in the construction industry. *Ain Shams Engineering Journal*, 12(1), 65–72. <https://doi.org/10.1016/j.asej.2020.08.002>
- Callejón-Ferre, A. J., Pérez-Alonso, J., Carreño-Ortega, A., & Velázquez-Martí, B. (2011). Indices of ergonomic-psychosociological workplace quality in the greenhouses of Almería (Spain): Crops of cucumbers, peppers, aubergines and

- melons. *Safety Science*, 49(5), 746–750.
<https://doi.org/10.1016/j.ssci.2010.12.009>
- Gao, Y., Hou, K., Jia, Y., Wei, Z., Wang, S., Li, Z., Ding, F., & Gong, X. (2021). Variability evaluation of gradation for asphalt mixture in asphalt pavement construction. *Automation in Construction*, 128, 103742.
<https://doi.org/10.1016/j.autcon.2021.103742>
- Hallowell, M. R., & Gambatese, J. A. (2009). Construction safety risk mitigation. *Journal of Construction Engineering and Management*, 135(12), 1316–1323.
[https://doi.org/10.1061/\(ASCE\)CO.1943-7862.0000107](https://doi.org/10.1061/(ASCE)CO.1943-7862.0000107)
- Hedlund, F. H. (2012). The extreme carbon dioxide outburst at the Menzengraben potash mine 7 July 1953. *Safety Science*, 50(3), 537–553.
<https://doi.org/10.1016/j.ssci.2011.10.004>
- International Labour Organization. (2023, 26 de noviembre). *Nearly 3 million people die of work-related accidents and diseases*.
<https://www.ilo.org/resource/news/nearly-3-million-people-die-work-related-accidents-and-diseases>
- Jiménez, J. C., Cabrera-Armijos, R. A., & Figuera-Ávila, P. A. (2024). Percepción de los factores de riesgos en los trabajadores de la construcción. *CONECTIVIDAD*, 5(4), 21–32. <https://doi.org/10.37431/conectividad.v5i4.199>
- Kang, K., & Ryu, H. (2019). Predicting types of occupational accidents at construction sites in Korea using random forest model. *Safety Science*, 120, 226–236.
<https://doi.org/10.1016/j.ssci.2019.06.034>
- Kim, B., Sri Preethaa, K. R., Song, S., Lukacs, R. R., An, J., Chen, Z., An, E., & Kim, S. (2024). Internet of things and ensemble learning-based mental and physical fatigue monitoring for smart construction sites. *Journal of Big Data*, 11(1), 115.
<https://doi.org/10.1186/s40537-024-00978-7>
- Lee, M., Jeong, J., Jeong, J., & Lee, J. (2021). Exploring fatalities and injuries in construction by considering thermal comfort using uncertainty and relative importance analysis. *International Journal of Environmental Research and Public Health*, 18(11), 5573. <https://doi.org/10.3390/ijerph18115573>
- Lima, M. G. T., Cunha, T. de M., Cândido, L. F., & Neto, J. de P. B. (2025). Digital transformation in the construction industry: Lessons and challenges from the journey of Brazilian construction companies. *Sustainability*, 18(1).
<https://doi.org/10.3390/su18010407>
- Liu, H., & Tian, G. (2019). Building engineering safety risk assessment and early warning mechanism construction based on distributed machine learning algorithm. *Safety Science*, 120, 764–771. <https://doi.org/10.1016/j.ssci.2019.08.022>
- Olimat, H., Alwashah, Z., Abudayyeh, O., & Liu, H. (2025). Data-driven analysis of construction safety dynamics: Regulatory frameworks, evolutionary patterns, and

- technological innovations. *Buildings*, 15(10). <https://doi.org/10.3390/buildings15101680>
- Onososen, A., & Musonda, I. (2026). Artificial intelligence in construction health and safety: Use cases, benefits and barriers. *Safety*, 12(1). <https://doi.org/10.3390/safety12010030>
- Rinchen, S., Banihashemi, S., & Alkilani, S. (2024). Driving digital transformation in construction: Strategic insights into building information modelling adoption in developing countries. *Project Leadership and Society*, 5, 100138. <https://doi.org/10.1016/j.plas.2024.100138>
- Román-Onsalo, M., Ríos-Paniagua, A., & Traverso-Cortés, J. (2013). Gender barriers in the professional development of building techniques women. *Revista de la Construcción*, 12(1), 87–99. <https://doi.org/10.4067/S0718-915X2013000100009>
- Sarmiento-Castillo, G. del P. (2025). Riesgos no observables en el sector de la construcción en Ecuador: Un análisis cuantitativo y cualitativo. *Revista Andina de Investigaciones en Ciencias Económicas y Empresariales*, 2(2), 9–50. <https://doi.org/10.69633/74a27097>
- Tian, K., Zhu, Z., Mbachu, J., Ghanbaripour, A., & Moorhead, M. (2025). Artificial intelligence in risk management within the realm of construction projects: A bibliometric analysis and systematic literature review. *Journal of Innovation & Knowledge*, 10(3), 100711. <https://doi.org/10.1016/j.jik.2025.100711>
- Trask, C., & Linderoth, H. C. J. (2023). Digital technologies in construction: A systematic mapping review of evidence for improved occupational health and safety. *Journal of Building Engineering*, 80, 108082. <https://doi.org/10.1016/j.jobe.2023.108082>
- Valencia-Gonzalez, E., & Revelo-Oña, R. (2022). Diagnóstico de factores de riesgos psicosociales en una empresa de construcción. *593 Digital Publisher CEIT*, 7(6), 202–220. <https://doi.org/10.33386/593dp.2022.6-2.1535>
- Vivian, G. A., Bauder, R. A., & Khoshgoftaar, T. M. (2025). A comprehensive survey on machine learning for workplace injury analysis: Risk prediction, return to work strategies, and demographic insights. *Journal of Big Data*, 12(1), 167. <https://doi.org/10.1186/s40537-025-01229-z>
- Wang, Q., Xian, J., Xiao, J., & Wang, X. (2023). Intelligent safety assessment method for demolition construction of closure segment of long-span continuous rigid frame bridges. *Advances in Bridge Engineering*, 4(1), 9. <https://doi.org/10.1186/s43251-023-00088-z>
- Wang, X., Liu, J., Khattak, A. J., & Clarke, D. (2016). Non-crossing rail-trespassing crashes in the past decade: A spatial approach to analyzing injury severity. *Safety Science*, 82, 44–55. <https://doi.org/10.1016/j.ssci.2015.08.017>

Zhong, B., Pan, X., Ding, L., Chen, Q., & Hu, X. (2023a). Blockchain-driven integration technology for the AEC industry. *Automation in Construction*, 150, 104791. <https://doi.org/10.1016/j.autcon.2023.104791>

Zhou, Z., Goh, Y. M., & Li, Q. (2015). Overview and analysis of safety management studies in the construction industry. *Safety Science*, 72, 337–350. <https://doi.org/10.1016/j.ssci.2014.10.006>

CONFLICTO DE INTERESES

“Los autores declaran no tener ningún conflicto de intereses”.