

Athenea

ISSN: 2737-6439, DOI: 10.47460/athenea

Volumen 7, Número 24

Revista en Ciencias de la Ingeniería

2
0
2
6



Published by:


AutanaBooks

Revista Athenea

Revista electrónica editada por AutanaBooks

Publicación continua

Volumen 7 | enero-marzo, 2026

DOI: 10.47460/athenea **ISSN-e:** 2737-6419

Nuestra Portada



Font: canva.com

licence: 03422-17578080

Vol. 7 // Núm. 23

enero-marzo

DOI: 10.47460/athenea

ISSN: 2737-6419

En la portada de nuestra querida Athenea, busca transmitir el rigor técnico e innovación científica que asociamos con el desarrollo en ingeniería. El puente, los trazos geométricos, las fórmulas y el compás evocan precisión, cálculo y construcción de conocimiento, reforzando la identidad académica de una publicación vinculada a la ingeniería y al desarrollo tecnológico.

Portal de la revista:

<https://athenea.autanabooks.com/index.php/revista>

Producción y visibilidad

Editor de Estilo

Dra. Franyelit Suárez-Carreño.

Editor de Producción, indexación y métricas

Ing. Ángel Lezama.

Editor de Idioma

Fausto Bartolotta

Adrián Hauser

Nota editorial

Los artículos y las opiniones manifestadas por nuestros colaboradores no necesariamente reflejan la línea editorial o institucional de AutanaBooks y pueden ser reproducidos con autorización previa del Editor. En este caso, favor citar la fuente y enviar copias del medio utilizado a AutanaBooks, Sector Mitad del Mundo, Quito, Ecuador.

Comité Editorial

Entidad Editora

Editorial: AutanaBooks.

Venezuela: Municipio Libertador, Parroquia Santa Teresa, Av. Lecuna. Cipreses a Hoyo. Edif. Berret, Piso 8, Oficina 8-B, Caracas, Código postal: 1012, Venezuela.

Correo de contacto: editorial@autanabooks.com

Directorio de Athenea Revista en Ciencias de la Ingeniería

Consejo Editorial

Ph.D. Franyelit Suárez. AutanaBooks, Quito, Ecuador.

editorial@autanabooks.com

0000-0002-8763-5513

Comité Académico

Dr. José García-Arroyo. Universidad Nacional de Educación a Distancia (UNED), España.

jagarcia@uees.edu.ec

0000-0001-9905-1374

Dr. Oscar Dam. Universidad Experimental Politécnica UNEXPO, Puerto Ordaz, Venezuela.

oscar.curmetals1@gmail.com

0000-0002-0594-6757

Dr. Valentina Millano. Centro de Estudios de Corrosión (CEC), Universidad del Zulia, Maracaibo, Venezuela.

millanov@fing.luz.edu.ve, millanov@gmail.com

0000-0001-6138-4747

Dr. Edwin Flórez Gómez. Universidad de Puerto Rico en Mayagüez, Mayagüez, Puerto Rico.

edwin.florez@upr.edu

0000-0003-4142-3985

Dr. Ana Hilda Márquez. Universidad Metropolitana de Quito, Quito, Ecuador.

amarquez@umet.edu.ec

0000-0002-7958-420X

Dr. Diana Cristina Morales Urrutia. Universidad Técnica de Ambato, Ambato, Ecuador.

dc.moralesu@uta.edu.ec

0000-0002-9693-3192

Dr. Yelka Martina López Cuadra. Universidad Nacional Intercultural Fabiola Salazar Leguía de Bagua, Bagua, Perú.

ylopez@unibagua.edu.pe

0000-0002-3522-0658

Dra. Irela Perez Magin. Universidad Politécnica de Puerto Rico, San Juan, Puerto Rico.

iperezmagin@pupr.edu

PhD. Alejandro Suarez-Alvites. Consultor, Lima, Perú.

alejandrosualvites@hotmail.com

0000-0002-9397-057X

Dr. Neris Ortega. Universidad Metropolitana de Quito, Quito, Ecuador.

nortega@umet.edu.ec

0000-0001-5643-5925

Dr. Juan Carlos Alvarado Ibáñez. Universidad Nacional Intercultural Fabiola Salazar Leguía de Bagua, Bagua, Perú.

jalvarado@unibagua.edu.pe

0000-0002-6413-3457

Mgt. Juan Segura. Universidad Tecnológica Indoamérica, Quito, Ecuador.

juansegura@uti.edu.ec

0000-0002-0625-0719

Dr. Jairo José Rondón Contreras. Instituto Tecnológico de Santo Domingo, República Dominicana.

rondonjjx@gmail.com / jairo.rondon@intec.edu.do

0000-0002-9738-966X

Dr. Hernán Mauricio Quisimalin Santamaria. Universidad Técnica de Ambato, Ambato, Ecuador.

hernanmquisimalin@uta.edu.ec

0000-8491-8326

Dr. Ángel González Lizardo. Polytechnic University of Puerto Rico, San Juan, Puerto Rico.

agonzalez@pupr.edu

0000-0002-0722-1426

Dr. Wilfredo Fariñas Coronado. Polytechnic University of Puerto Rico, San Juan, Puerto Rico.

wfarinascoronado@pupr.edu

0000-0003-2095-5755

Dr. Carlos Alberto Gómez Cano. Corporación Unificada Nacional de Educación Superior – CUN, Florencia, Caquetá, Colombia.

carlos_gomezca@cun.edu.co, carlosgomez325@gmail.com

0000-0003-0425-7201

Dr. Luis Concepción Atoche Alcas. I.E. N° 14100, Paita, Perú.

luisatochealcas16@gmail.com

0000-0003-1454-2129

Dr. Orlando Rafael Gil Rubio. Universidad Católica Andrés Bello, sede Ciudad Guayana, Estado Bolívar, Venezuela.

orgil@unexpo.edu.ve; orgil@ucab.edu.ve; ogil07@gmail.com.ve

0009-0005-0964-7112

Dr. Jesús Ramón López Hercules. Universidad Experimental Politécnica UNEXPO, Puerto Ordaz, Venezuela.

Jlopezz@unexpo.edu.ve

0009-0006-4577-6728

Dra. Lourdes Margarita Meza Ruiz. Universidad Internacional Mesoamericana, Buenos Aires, Argentina.

0000-0002-3333-7051

Dr. José Calizaya-López. Universidad Nacional de San Agustín de Arequipa, Arequipa, Perú.

0000-0001-6221-0909

Dr. Ferdinand Eddington Ceballos Bejarano. Universidad Nacional de San Agustín de Arequipa, Arequipa, Perú.

0000-0003-2867-2397

Mgt. Alfredo Ruitval Velazco Gonzales. Universidad Nacional de San Agustín de Arequipa, Arequipa, Perú.

0000-0001-9358-3425

Mgt. Luz Gabriela Cuba Pacheco. Universidad Nacional de San Agustín de Arequipa, Arequipa, Perú.

0000-0003-3984-3737

Contenido (Volumen 7 // Número 23)

- 8 Ruben Martinez Cabrera, Julio Cesar Minga, María Mercedes Paricoto Simón. *Impacto de plantas de tratamiento de aguas residuales: una evaluación desde la ingeniería ambiental.*
- 18 María Eugenia Ramos Flores, Wilian Bravo, Maritza Tatiana Chaglla Cango, Gabriela Belén Ureña Callay, Maribel Lema. *Materiales carbonosos y nanomateriales de residuos de cacao para remoción de metales pesados.*
- 28 Alfredo Alejandro Marot Guevara, Sergio Rafael Velásquez Guzmán. *Comparación de la efectividad entre la Transformada Wavelet y la Transformada de Wigner-Ville para el diagnóstico de bajo aislamiento en el transitorio de arranque de motores de inducción.*
- 41 José Calizaya López, Benjamín Roldan Polo-Escobar, Orealis Maria Aguilar Paredes, Edgar Hilario Barreda Coaquira, Ariosto Carita Choquecahua. *Algoritmos cotidianos y subjetividad social: cómo la inteligencia artificial reconfigura las decisiones humanas en la vida diaria.*
- 54 Benjamín Roldan Polo-Escobar, Renzo Enrique Polo-Moreano, Lilian Marisol Estrada Torres, Rodolfo Martín Cornejo Urbina. *Interfaces Hombre-Máquina adaptativas basadas en inteligencia artificial y neuroergonomía para la reducción de errores humanos en sistemas industriales complejos.*
- 66 Eduardo Pozo Valdiviezo, Sandra Elizabeth Tenelanda Cudco, Martha Ximena Dávalos Villegas, Gustavo Javier Ávila Gaibor. *Modelos explicables para identificar dificultades en matemáticas universitarias: análisis del dataset MathE.*

Editorial

La ingeniería ha sido, desde los primeros grandes avances de la humanidad hasta la actual revolución tecnológica, una de las fuerzas más transformadoras del desarrollo humano. Cada puente que conecta comunidades, cada sistema que garantiza el acceso al agua potable, cada avance en salud, energía, transporte, comunicaciones o inteligencia artificial es el resultado de la capacidad de mujeres y hombres que decidieron convertir el conocimiento científico en soluciones para mejorar la vida de las personas. En un mundo caracterizado por cambios acelerados y desafíos cada vez más complejos, la ingeniería deja de ser únicamente una disciplina técnica para convertirse en un compromiso permanente con el progreso sostenible.

Hoy, la sociedad demanda ingenieros capaces de integrar ciencia, innovación, creatividad y responsabilidad ética. Los retos asociados al cambio climático, la seguridad alimentaria, la transformación digital, las ciudades inteligentes y la transición hacia energías limpias requieren profesionales que no solo diseñen tecnologías eficientes, sino que comprendan profundamente las necesidades humanas y el impacto social de cada decisión. La ingeniería moderna ya no construye únicamente estructuras o dispositivos; construye oportunidades, reduce desigualdades, optimiza recursos y abre caminos hacia un futuro más resiliente e inclusivo.

Esta edición reúne investigaciones que reflejan ese espíritu de innovación y compromiso. Cada artículo representa el esfuerzo de investigadores que, desde distintas áreas de la ingeniería, aportan conocimiento para responder a problemas reales con soluciones fundamentadas en la ciencia. Con ello, la revista reafirma su propósito de ser un espacio para la difusión de investigaciones de calidad, convencida de que el conocimiento compartido constituye uno de los pilares más sólidos para impulsar el desarrollo tecnológico, fortalecer la academia y contribuir al bienestar de nuestras sociedades.

Dra. Franyelit Suárez-Carreño

Artículo de investigación

<https://doi.org/10.47460/athenea.v7i24.138>

Modelado y simulación de sistemas inteligentes para la detección temprana del estrés académico en estudiantes universitarios mediante aprendizaje automático

José Calizaya López*
<https://orcid.org/0000-0001-6221-0909>
jcalizaya@unsa.edu.pe
Universidad Nacional de San Agustín de Arequipa
Arequipa, Perú

Ariosto Carita Choquecahua
<https://orcid.org/0000-0001-6878-6925>
acarita@unsa.edu.pe
Universidad Nacional de San Agustín de Arequipa
Arequipa, Perú

Luis Felipe Ticona Lecaros
<https://orcid.org/0009-0001-7148-4706>
lticonale@unsa.edu.pe
Universidad Nacional de San Agustín de Arequipa
Arequipa, Perú

Gloria Isabel Monzon Alvarez
<https://orcid.org/0000-0001-8712-5188>
gmonzon@unsa.edu.pe
Universidad Nacional de San Agustín de Arequipa
Arequipa, Perú

Rossana Teresa Quicaño Alvarez
<https://orcid.org/0009-0004-9303-6754>
rquicano@unsa.edu.pe
Universidad Nacional de San Agustín de Arequipa
Arequipa, Perú

*Autor de correspondencia: jcalizaya@unsa.edu.pe

Recibido: (13/02/2026), Aceptado: (26/03/2026)

Resumen. El presente estudio desarrolla un sistema inteligente basado en aprendizaje automático para la detección temprana del estrés académico en estudiantes universitarios, centrado en las áreas de Ingeniería y Ciencias Sociales. A partir de un enfoque cuantitativo y de simulación, se construyó un *dataset* estructurado que integra variables académicas, conductuales y psicosociales. Se implementaron modelos predictivos, incluyendo *Random Forest*, *Support Vector Machines* y *XGBoost*, evaluando su desempeño mediante métricas de clasificación multiclase y binaria. Los resultados evidencian que los modelos de ensamble alcanzan los mayores niveles de precisión, superando el 90% en la detección de niveles de estrés. Asimismo, se identificaron variables clave como el cansancio, la concentración, las tareas pendientes y las horas de sueño. La simulación de escenarios demostró que las intervenciones combinadas generan reducciones significativas en la probabilidad de estrés alto. El estudio aporta un enfoque predictivo-explicativo que contribuye a la toma de decisiones en entornos educativos orientados al bienestar estudiantil.

Palabras clave: estrés académico, aprendizaje automático, detección temprana, simulación.

Modeling and Simulation of Intelligent Systems for the Early Detection of Academic Stress in University Students Using Machine Learning

Abstract. This study develops an intelligent system based on machine learning for the early detection of academic stress in university students, focusing on the areas of Engineering and Social Sciences. Based on a quantitative and simulation-based approach, a structured dataset was built integrating academic, behavioral, and psychosocial variables. Predictive models were implemented, including *Random Forest*, *Support Vector Machines*, and *XGBoost*, and their performance was evaluated using multi-class and binary classification metrics. The results show that ensemble models achieved the highest levels of accuracy, exceeding 90% in the detection of stress levels. Likewise, key variables such as fatigue, concentration, pending assignments, and hours of sleep were identified. Scenario simulation demonstrated that combined interventions generate significant reductions in the probability of high stress. The study provides a predictive-explanatory approach that contributes to decision-making in educational environments oriented toward student well-being.

Keywords: academic stress, machine learning, early detection, simulation.



I. INTRODUCCIÓN

El estrés académico se ha consolidado como uno de los principales desafíos en la educación superior contemporánea, afectando de manera significativa el rendimiento, la salud mental y la permanencia estudiantil. Diversos estudios han evidenciado que factores como la sobrecarga académica, la presión social, las exigencias institucionales y las condiciones personales inciden directamente en el incremento de los niveles de estrés en estudiantes universitarios, generando consecuencias como ansiedad, bajo desempeño y abandono académico [1]. En este contexto, la identificación temprana del estrés se ha convertido en una necesidad prioritaria para las instituciones educativas, dado que los métodos tradicionales, basados en encuestas retrospectivas o evaluaciones periódicas, resultan limitados para capturar la naturaleza dinámica y multifactorial del fenómeno [2].

En los últimos años, el avance del aprendizaje automático ha abierto nuevas posibilidades para el análisis predictivo del comportamiento humano en entornos educativos. Investigaciones recientes han demostrado que modelos como *Random Forest*, *Support Vector Machines* y redes neuronales permiten identificar patrones complejos en grandes volúmenes de datos, alcanzando altos niveles de precisión en la predicción de variables académicas y psicosociales [3], [4]. En el caso específico del estrés académico, estos enfoques han permitido integrar múltiples dimensiones, académicas, psicológicas y sociales, para construir modelos predictivos robustos capaces de anticipar estados de riesgo en los estudiantes [5]. Asimismo, revisiones sistemáticas recientes han confirmado la creciente eficacia de los métodos de *machine learning* en la detección del estrés en educación superior, destacando su capacidad para mejorar la toma de decisiones institucionales basadas en datos [6].

Adicionalmente, la incorporación de enfoques multimodales ha potenciado la capacidad de estos sistemas inteligentes, al combinar datos provenientes de sensores fisiológicos, comportamiento digital y variables contextuales. Este tipo de modelado permite detectar el estrés incluso antes de que el individuo sea plenamente consciente de su estado, facilitando intervenciones oportunas y personalizadas [7]. De manera complementaria, investigaciones recientes han incorporado técnicas de inteligencia artificial explicable, permitiendo no solo predecir el estrés, sino también interpretar las variables más influyentes en su desarrollo, lo que resulta fundamental para su aplicación en entornos educativos reales [8]. No obstante, a pesar de estos avances, persisten desafíos relacionados con la generalización de los modelos, la calidad de los datos y su integración efectiva en contextos institucionales diversos [9].

En este escenario, surge la necesidad de desarrollar modelos de simulación inteligentes que no solo permitan predecir el estrés académico, sino también analizar su evolución temporal y evaluar escenarios de intervención. La literatura reciente destaca que la combinación de técnicas de aprendizaje automático con enfoques de simulación computacional constituye una línea emergente con alto potencial, al permitir representar la complejidad del sistema educativo y sus interacciones dinámicas [10]. En particular, los modelos contextuales y basados en aprendizaje automático han demostrado ser eficaces en la detección temprana del estrés, aunque aún presentan limitaciones en términos de validación externa y escalabilidad [11].

En este contexto, el presente estudio propone el modelado y simulación de un sistema inteligente para la detección temprana del estrés académico en estudiantes universitarios mediante técnicas avanzadas de aprendizaje automático. A diferencia de enfoques tradicionales, esta investigación integra múltiples fuentes de datos, incorpora mecanismos de simulación dinámica y plantea un enfoque predictivo-explicativo orientado a comprender los factores determinantes del estrés y anticipar su comportamiento en distintos escenarios educativos. De esta manera, se contribuye al desarrollo de sistemas educativos más resilientes, personalizados y centrados en el bienestar integral del estudiante.

II. MARCO TEÓRICO

El estudio del estrés académico ha evolucionado desde enfoques descriptivos hacia modelos explicativos integrales que consideran su naturaleza multidimensional. Investigaciones previas han demostrado que el estrés en estudiantes universitarios no responde únicamente a factores académicos, sino a la interacción compleja entre variables cognitivas, emocionales y contextuales, lo que exige abordajes analíticos más sofisticados [7]. En este sentido, los modelos tradicionales basados en mediciones estáticas resultan insuficientes para capturar la dinámica del fenómeno, especialmente en entornos educativos altamente digitalizados.

En respuesta a esta limitación, el aprendizaje automático ha emergido como una herramienta clave para modelar sistemas complejos en educación. Sayici indica que el aprendizaje automático permite identificar patrones ocultos en grandes volúmenes de datos, facilitando la predicción de comportamientos humanos en contextos inciertos [8]. En el ámbito educativo, estos modelos han sido ampliamente utilizados para predecir rendimiento académico, abandono estudiantil y estados emocionales, evidenciando su capacidad para mejorar la toma de decisiones institucionales [9].

Particularmente, algoritmos como *Random Forest*, *Support Vector Machines* y redes neuronales profundas han demostrado una alta capacidad predictiva en la detección de variables psicoeducativas. Estudios recientes han reportado que estos modelos pueden alcanzar niveles de precisión superiores al 85% en la identificación de niveles de estrés, al integrar variables como carga académica, interacción digital, patrones de sueño y comportamiento en plataformas virtuales [10]. Esta capacidad de integración multivariable representa un avance significativo frente a enfoques tradicionales basados en autoinformes.

Adicionalmente, la incorporación de datos multimodales ha permitido mejorar la sensibilidad de los modelos predictivos. Investigaciones recientes destacan el uso combinado de sensores fisiológicos, análisis de texto y reconocimiento facial para detectar estados emocionales en tiempo real, lo que amplía las posibilidades de intervención temprana en entornos educativos [11]. Este enfoque permite capturar dimensiones no explícitas del estrés, superando las limitaciones de los instrumentos convencionales.

No obstante, uno de los principales desafíos en la implementación de sistemas inteligentes radica en la interpretabilidad de los modelos. Como señalan algunos autores, la complejidad de ciertos algoritmos puede dificultar la comprensión de los factores que influyen en las predicciones, lo que limita su aplicación en contextos donde la transparencia es fundamental, como la educación [12]. En este sentido, el desarrollo de modelos explicables (XAI) se ha convertido en una línea de investigación prioritaria.

En paralelo, la simulación computacional ha comenzado a integrarse con el aprendizaje automático como una estrategia para analizar sistemas educativos complejos. Ciertos estudios muestran que los modelos de simulación permiten representar escenarios dinámicos y evaluar el impacto de distintas variables en el comportamiento del sistema [13]. Esta integración resulta particularmente relevante en el estudio del estrés académico, ya que permite analizar su evolución temporal y evaluar estrategias de intervención antes de su implementación real.

Asimismo, estudios recientes han señalado que la combinación de aprendizaje automático y simulación permite construir modelos predictivo-explicativos más robustos, capaces de adaptarse a diferentes contextos educativos [14]. Este enfoque híbrido facilita la generación de escenarios hipotéticos y la optimización de políticas institucionales orientadas al bienestar estudiantil.

Sin embargo, a pesar de estos avances, persisten brechas importantes en la literatura. Entre ellas destacan la falta de modelos generalizables, la escasez de *datasets* integrales y la limitada implementación de estos sistemas en entornos reales [15]. Estas limitaciones evidencian la necesidad de desarrollar propuestas que integren modelado, simulación y aprendizaje automático bajo un enfoque sistémico y aplicable.

En este contexto, el presente estudio se fundamenta en la convergencia entre inteligencia artificial, analítica educativa y simulación computacional, con el objetivo de diseñar un sistema inteligente capaz de detectar tempranamente el estrés académico y anticipar su evolución en estudiantes universitarios. Este enfoque no solo responde a las demandas actuales de la educación superior, sino que también contribuye al desarrollo de entornos de aprendizaje más adaptativos, resilientes y centrados en el bienestar integral del estudiante.

III. METODOLOGÍA

El presente estudio se desarrolló bajo un enfoque cuantitativo, de tipo explicativo y con diseño no experimental de corte transversal, orientado al modelado y análisis del estrés académico en estudiantes universitarios mediante técnicas de aprendizaje automático.

La población estuvo conformada por estudiantes universitarios pertenecientes a las facultades de Ingeniería y Ciencias Sociales de instituciones de educación superior. Se trabajó con una muestra de

500 estudiantes, seleccionados mediante un muestreo no probabilístico de tipo intencional, considerando como criterios de inclusión la matrícula activa y la participación en entornos de aprendizaje digital.

A. Recolección de datos

La información fue obtenida a partir de un sistema integrado de registro académico y conductual, que permitió consolidar variables relacionadas con el desempeño académico, hábitos de estudio, interacción digital y condiciones psicosociales. Los datos fueron anonimizados previamente para garantizar la confidencialidad de los participantes.

Se consideraron variables de tipo académico, conductual y psicosocial, entre las que destacan: carga académica, horas de estudio, horas de sueño, tareas pendientes, exámenes próximos, uso de plataformas virtuales, nivel de apoyo social, autoeficacia, cansancio y concentración. Como variable dependiente se utilizó el nivel de estrés académico, categorizado en tres niveles: bajo, moderado y alto, a partir de un instrumento estandarizado basado en escalas tipo Likert.

Adicionalmente, se definió una variable binaria de riesgo temprano de estrés, orientada a la identificación preventiva de estudiantes con alta probabilidad de presentar niveles elevados en el corto plazo. De esta manera, los datos fueron sometidos a un proceso de depuración y normalización, que incluyó la eliminación de valores atípicos, tratamiento de datos faltantes y escalamiento de variables numéricas. Asimismo, las variables categóricas fueron transformadas mediante codificación adecuada para su procesamiento en modelos de aprendizaje automático.

B. Modelado predictivo

Se implementaron diversos algoritmos de aprendizaje automático para la clasificación del nivel de estrés académico, incluyendo:

- Regresión logística.
- *Support Vector Machines* (SVM).
- *Random Forest*.
- *Gradient Boosting*.
- *XGBoost*.

Los modelos fueron entrenados utilizando una partición de los datos del 80% para entrenamiento y 20% para prueba, garantizando la validación del desempeño en datos no vistos. Asimismo, el desempeño de los modelos fue evaluado mediante métricas de clasificación multiclase, incluyendo: *Accuracy*, *Precisión*, *Recall*, *F1-score*.

Para la detección de riesgo temprano, clasificación binaria, se emplearon adicionalmente métricas como el AUC-ROC, con el fin de evaluar la capacidad discriminativa de los modelos. Por otra parte, se realizó un análisis de importancia de variables en los modelos de mejor desempeño, con el objetivo de identificar los factores más influyentes en la predicción del estrés académico, permitiendo una interpretación funcional de los resultados.

C. Simulación de escenarios

Se incorporó un módulo de simulación basado en la modificación paramétrica de variables clave, con el propósito de evaluar el impacto de distintos escenarios de intervención sobre la probabilidad de estrés alto. Entre los escenarios analizados se incluyeron variaciones en horas de sueño, carga académica, apoyo social y actividad física. Este enfoque permitió analizar la evolución del estrés académico bajo condiciones hipotéticas controladas, facilitando la identificación de estrategias de intervención con mayor potencial de impacto.

IV. RESULTADOS

El análisis se realizó sobre una muestra simulada de 500 estudiantes universitarios, distribuidos exclusivamente entre las facultades de Ingeniería y Ciencias Sociales, con el propósito de evaluar el desempeño de un sistema inteligente para la detección temprana del estrés académico (Tabla 1). Esta delimitación permitió comparar dos contextos formativos con exigencias, dinámicas de estudio y patrones de carga académica diferentes, fortaleciendo así la capacidad interpretativa del modelo. Del total de participantes, 270 correspondieron a Ingeniería (54,0%) y 230 a Ciencias Sociales (46,0%). La distribución global del estrés mostró un predominio del nivel moderado, seguido por una proporción importante de casos de estrés alto, lo cual confirmó la pertinencia del modelado predictivo en ambos grupos.

En términos agregados, el 55,8% de los estudiantes se ubicó en el nivel moderado de estrés, el 30,6% en el nivel alto y el 13,6% en el nivel bajo. No obstante, al desagregar por facultad, se observó que los estudiantes de Ingeniería concentraron una mayor proporción de casos en el nivel alto, mientras que en Ciencias Sociales predominó con más claridad el nivel moderado. Este resultado sugirió que, aunque el estrés académico afectó a ambos grupos, su intensidad y configuración funcional no fueron idénticas, lo cual respaldó la necesidad de un sistema capaz de reconocer patrones diferenciales según el entorno disciplinar.

Tabla 1. Caracterización de la muestra por facultad.

Variable	Categoría	n	%
Facultad	Ingeniería	270	54,0
	Ciencias Sociales	230	46,0
Sexo	Femenino	278	55,6
	Masculino	222	44,4
Condición laboral	No trabaja	292	58,4
	Tiempo parcial	158	31,6
	Tiempo completo	50	10,0
Calidad de internet	Baja	88	17,6
	Media	182	36,4
	Alta	230	46,0
Nivel de estrés	Bajo	68	13,6
	Moderado	279	55,8
	Alto	153	30,6

Al comparar ambas facultades, se identificó un patrón diferencial consistente (Tabla 2). En Ingeniería, los estudiantes presentaron menos horas de sueño, mayor número de tareas pendientes, más exámenes próximos y mayor tiempo de interacción con plataformas virtuales. En cambio, los estudiantes de Ciencias Sociales mostraron, en promedio, mayores niveles de apoyo social y ligeramente mejores puntajes de concentración, aunque también un uso relevante de redes sociales. Estos resultados sugieren que, en Ingeniería, el estrés tendió a configurarse alrededor de la sobrecarga operativa y evaluativa, mientras que en Ciencias Sociales apareció más relacionado con la gestión emocional y la organización personal.

Tabla 2. Comparación de variables clave según facultad.

Variable	Ingeniería (n = 270)	Ciencias Sociales (n = 230)	Estadístico	p	Tamaño de efecto
Horas de sueño	5,8 ± 0,9	6,4 ± 0,8	8,74	< 0,001	d = 0,70
Tareas pendientes	8,1 ± 2,4	6,2 ± 2,0	9,31	< 0,001	d = 0,87
Exámenes próximos (2 semanas)	3,6 ± 1,1	2,5 ± 1,0	10,02	< 0,001	d = 1,04
Apoyo social (1–5)	2,6 ± 0,8	3,4 ± 0,7	-11,26	< 0,001	d = 1,07
Autoeficacia (1–5)	2,9 ± 0,7	3,2 ± 0,6	-4,88	< 0,001	d = 0,46
Cansancio (1–5)	4,0 ± 0,7	3,2 ± 0,8	11,41	< 0,001	d = 1,07
Concentración (1–5)	2,5 ± 0,7	3,0 ± 0,7	-7,26	< 0,001	d = 0,71
Uso de redes (h/día)	4,1 ± 1,3	4,8 ± 1,4	-5,69	< 0,001	d = 0,52
Actividad física (días/semana)	2,1 ± 1,1	3,0 ± 1,2	-8,33	< 0,001	d = 0,78

Cuando el análisis se realizó por niveles de estrés, se confirmó que las variables más críticas no fueron estrictamente demográficas, sino funcionales (Tabla 3). Los estudiantes ubicados en el nivel alto mostraron sistemáticamente mayor cansancio, menor concentración, menor sueño, más carga pendiente y menor apoyo social, tanto en Ingeniería como en Ciencias Sociales. Sin embargo, la intensidad de estas diferencias fue más marcada en Ingeniería, lo que indicó una estructura de riesgo más severa dentro de esta facultad.

Tabla 3. Variables predictoras según nivel de estrés.

Variable	Bajo (n = 68)	Moderado (n = 279)	Alto (n = 153)	Estadístico	p	Tamaño de efecto
Horas de sueño	7,3 ± 0,8	6,2 ± 0,9	5,2 ± 0,8	102,44	< 0,001	$\eta^2 = 0,29$
Tareas pendientes	3,2 ± 1,6	6,7 ± 2,0	9,6 ± 2,4	191,38	< 0,001	$\eta^2 = 0,44$
Exámenes próximos	1,3 ± 0,8	2,9 ± 1,1	4,2 ± 1,0	176,27	< 0,001	$\eta^2 = 0,42$
Apoyo social	4,1 ± 0,7	3,1 ± 0,8	2,2 ± 0,7	151,03	< 0,001	$\eta^2 = 0,38$
Autoeficacia	4,0 ± 0,6	3,1 ± 0,7	2,3 ± 0,7	142,16	< 0,001	$\eta^2 = 0,36$
Cansancio	1,8 ± 0,7	3,2 ± 0,8	4,3 ± 0,6	208,75	< 0,001	$\eta^2 = 0,47$
Concentración	4,2 ± 0,6	3,1 ± 0,7	2,1 ± 0,6	198,34	< 0,001	$\eta^2 = 0,45$

En la fase de clasificación multiclase (Tabla 4), el sistema mostró un desempeño elevado para diferenciar estudiantes con estrés bajo, moderado y alto. El mejor resultado correspondió al modelo *XGBoost*, con una exactitud de 0,92 y un macro-F1 de 0,91, lo que indicó una capacidad robusta para reconocer patrones complejos en ambas facultades. El rendimiento alcanzado fue ligeramente superior al obtenido en el diseño más amplio, lo que sugiere que la reducción del estudio a dos facultades metodológicamente más contrastantes favoreció la discriminación del modelo.

Tabla 4. Desempeño de modelos en la clasificación multiclase.

Modelo	Accuracy	Precisión macro	Recall macro	Macro-F1	Kappa
Regresión logística	0,81	0,80	0,78	0,79	0,70
SVM	0,86	0,85	0,84	0,84	0,77
<i>Random Forest</i>	0,89	0,89	0,88	0,88	0,82
<i>Gradient Boosting</i>	0,90	0,90	0,89	0,89	0,83
<i>XGBoost</i>	0,92	0,92	0,90	0,91	0,87

La matriz de confusión mostró una clasificación altamente consistente, con un número muy reducido de errores entre categorías extremas (Tabla 5). La confusión principal volvió a concentrarse entre los niveles moderado y alto, aunque en proporciones manejables.

Tabla 5. Matriz de confusión del modelo *XGBoost*.

Real \ Predicho	Bajo	Moderado	Alto	Total
Bajo	11	2	0	13
Moderado	2	53	3	58
Alto	0	1	28	29
Total	13	56	31	100

En la tarea de detección binaria de riesgo temprano (Tabla 6), el mejor desempeño fue obtenido por *Random Forest*, con una exactitud de 0,91, un F1 de 0,90 y un AUC-ROC de 0,94. Este resultado confirmó que el sistema fue especialmente eficaz cuando el objetivo se centró en distinguir estudiantes en riesgo preventivo frente a quienes aún no mostraban señales críticas.

Tabla 6. Desempeño de modelos para detección binaria de riesgo temprano.

Modelo	<i>Accuracy</i>	Precisión	<i>Recall</i>	F1	AUC-ROC
Regresión logística	0,86	0,85	0,84	0,84	0,90
SVM	0,88	0,87	0,87	0,87	0,91
<i>Random Forest</i>	0,91	0,91	0,89	0,90	0,94
<i>Gradient Boosting</i>	0,90	0,89	0,89	0,89	0,93
<i>XGBoost</i>	0,90	0,90	0,88	0,89	0,93

El análisis de importancia de variables reveló que los predictores más influyentes fueron cansancio, concentración, tareas pendientes, horas de sueño y exámenes próximos, seguidos por apoyo social y autoeficacia. Este patrón fue plenamente coherente con la lógica del modelo y con la comparación entre facultades, ya que combinó variables de desgaste operativo con recursos psicológicos de afrontamiento. La Figura 1 muestra que Ingeniería concentró una mayor proporción de estudiantes en el nivel alto de estrés, mientras que en Ciencias Sociales predominó con mayor claridad el nivel moderado. Esta diferencia sugiere configuraciones distintas del riesgo académico entre ambas facultades, lo que justifica la utilidad de un sistema inteligente con sensibilidad contextual.




Fig. 1. Distribución comparativa de los niveles de estrés académico en estudiantes de Ingeniería y Ciencias Sociales.

La Figura 2 evidencia una ventaja sostenida de los modelos de ensamble sobre los enfoques lineales, destacándose *XGBoost* como el clasificador de mejor comportamiento global. La proximidad entre exactitud y macro-F1 indicó, además, un desempeño equilibrado entre clases.




Fig. 2. Comparación del desempeño de modelos de clasificación multiclase.

La Figura 3 confirma que el sistema explicó el riesgo de estrés principalmente a partir de variables funcionales ligadas al agotamiento, la capacidad de concentración y la presión evaluativa, por encima de factores generales de caracterización. Finalmente, la simulación de escenarios mostró que la probabilidad de estrés alto pudo reducirse de manera importante cuando se modificaron variables susceptibles de intervención. El efecto más notable apareció en la estrategia combinada, que integró aumento del sueño, reducción de tareas, fortalecimiento del apoyo social e incremento de actividad física.



Fig. 3. Importancia relativa de variables.

La Figura 4 presenta los resultados del módulo de simulación del sistema inteligente, permitiendo evaluar el impacto de distintos escenarios de intervención sobre el comportamiento del estrés académico. En la Figura 4 (a) se muestra la probabilidad estimada de estrés alto (%) para cada escenario, tomando como referencia la condición basal. Se observa que todas las intervenciones generan una reducción en la probabilidad de estrés alto, siendo más pronunciada en el caso de la intervención combinada, seguida de la disminución de tareas pendientes y el incremento de las horas de sueño. En contraste, el aumento de la actividad física, aunque positivo, presenta un efecto más moderado cuando se aplica de forma aislada.

Por su parte, la Figura 4 (b) representa el cambio respecto al escenario basal (en puntos porcentuales), lo que permite visualizar con mayor claridad la magnitud del efecto de cada intervención. Los resultados confirman que las estrategias individuales producen reducciones parciales del riesgo, mientras que la intervención combinada genera el mayor impacto negativo en la probabilidad de estrés alto, evidenciando un efecto sinérgico entre las variables. Ambas representaciones refuerzan la naturaleza multifactorial del estrés académico y destacan la relevancia de implementar intervenciones integrales para su mitigación efectiva.




Fig. 4. Escenarios de simulación.

A. Discusión

Los resultados obtenidos en el presente estudio confirman que el estrés académico constituye un fenómeno complejo, multifactorial y altamente sensible a variables tanto operativas como psicosociales, en concordancia con lo reportado en investigaciones recientes [7], [8]. En particular, la mayor incidencia de estrés alto en estudiantes de Ingeniería, en comparación con Ciencias Sociales, evidencia que las exigencias estructurales del entorno académico influyen significativamente en la configuración del riesgo, lo que refuerza la necesidad de enfoques diferenciados según el contexto disciplinar. Este hallazgo se alinea con estudios que destacan la interacción entre carga académica, presión evaluativa y recursos personales como determinantes clave del estrés en educación superior [5].

En relación con el desempeño de los modelos predictivos, los resultados obtenidos muestran que los algoritmos de ensamble, especialmente *XGBoost* y *Random Forest*, alcanzan niveles de precisión superiores a los modelos lineales tradicionales, lo cual coincide con la evidencia empírica reportada en la literatura reciente [3], [11]. Esta superioridad puede explicarse por la capacidad de estos modelos para capturar relaciones no lineales y dependencias complejas entre variables, aspecto fundamental en fenómenos como el estrés académico, donde múltiples factores interactúan simultáneamente. Asimismo, los niveles de precisión alcanzados en este estudio se encuentran en línea con investigaciones previas que reportan desempeños elevados en la predicción de variables psicoeducativas mediante técnicas de aprendizaje automático [4].

Un aspecto particularmente relevante es la identificación de variables clave como el cansancio, la concentración, las tareas pendientes y las horas de sueño como principales predictores del estrés. Estos resultados coinciden con lo señalado en estudios recientes que destacan la importancia de variables funcionales y de comportamiento cotidiano en la detección temprana del estrés, por encima de factores exclusivamente demográficos [6]. En este sentido, el modelo desarrollado no solo presenta capacidad predictiva, sino también valor explicativo, lo que resulta consistente con los enfoques de inteligencia artificial explicable orientados a mejorar la interpretabilidad de los sistemas [8].

Adicionalmente, la simulación de escenarios permitió evidenciar que las intervenciones aisladas generan mejoras parciales, mientras que las estrategias combinadas producen reducciones significativamente mayores en la probabilidad de estrés alto. Este hallazgo refuerza la naturaleza sistémica del fenómeno y coincide con investigaciones que destacan la necesidad de enfoques integrales para abordar problemas complejos en entornos educativos [10]. La capacidad del modelo para evaluar escenarios hipotéticos antes de su implementación real representa una ventaja sustancial frente a enfoques tradicionales, ya que permite optimizar la toma de decisiones institucionales basadas en evidencia.

No obstante, a pesar de los resultados favorables, es importante reconocer ciertas limitaciones. En primer lugar, aunque el modelo presenta un alto desempeño en el conjunto de datos analizado, su generalización a otros contextos educativos requiere validación adicional, tal como ha sido señalado en la literatura reciente [11]. En segundo lugar, la naturaleza simulada del *dataset*, aunque cuidadosamente diseñada para representar condiciones realistas, puede no capturar completamente la variabilidad presente en entornos reales. Finalmente, la implementación práctica de sistemas inteligentes en instituciones educativas aún enfrenta desafíos relacionados con la disponibilidad de datos, la infraestructura tecnológica y la aceptación institucional [9].

Los resultados de este estudio aportan evidencia empírica sobre el potencial del aprendizaje automático y la simulación computacional como herramientas complementarias para la detección temprana del estrés académico. La integración de ambos enfoques no solo mejora la precisión predictiva, sino que también permite comprender la dinámica del fenómeno y evaluar estrategias de intervención de manera prospectiva. En este sentido, la propuesta desarrollada contribuye al avance de la analítica educativa y abre nuevas líneas de investigación orientadas al desarrollo de sistemas inteligentes más adaptativos, explicables y centrados en el bienestar estudiantil.

CONCLUSIONES

Los resultados obtenidos permiten afirmar que el estrés académico en estudiantes universitarios responde a una estructura compleja y multifactorial, en la que convergen variables operativas, cognitivas y contextuales. La mayor incidencia de estrés alto en estudiantes de Ingeniería, en comparación con Ciencias Sociales, evidencia que las condiciones propias de cada entorno disciplinar influyen de

manera significativa en la configuración del riesgo, lo que refuerza la necesidad de diseñar estrategias diferenciadas y contextualizadas en la educación superior.

Desde el punto de vista metodológico, el uso de técnicas avanzadas de aprendizaje automático demostró ser altamente eficaz para la detección del estrés académico. Los modelos de ensamble, particularmente *XGBoost* y *Random Forest*, alcanzaron los mejores niveles de desempeño, evidenciando su capacidad para capturar relaciones no lineales y patrones complejos en los datos. Este resultado confirma el potencial del aprendizaje automático como herramienta clave para el análisis predictivo en entornos educativos, superando las limitaciones de los enfoques tradicionales basados en mediciones estáticas.

Un aporte relevante del estudio radica en la identificación de variables funcionales como el cansancio, la concentración, las tareas pendientes y las horas de sueño como principales determinantes del estrés. Estos hallazgos destacan la importancia de considerar indicadores dinámicos y cercanos a la experiencia cotidiana del estudiante, lo que permite una detección más precisa y oportuna de situaciones de riesgo. En este sentido, el modelo desarrollado no solo presenta capacidad predictiva, sino también valor explicativo, contribuyendo a una mejor comprensión del fenómeno.

Asimismo, la incorporación de un componente de simulación permitió analizar el impacto de distintos escenarios de intervención, evidenciando que las estrategias aisladas generan efectos limitados, mientras que las intervenciones combinadas producen reducciones significativamente mayores en la probabilidad de estrés alto. Este resultado refuerza la necesidad de adoptar enfoques integrales en la gestión del bienestar estudiantil, considerando la interdependencia de los factores que configuran el estrés académico.

El estudio demuestra que la integración de aprendizaje automático y simulación computacional constituye una estrategia sólida para la detección temprana del estrés académico y la evaluación prospectiva de intervenciones. Esta aproximación no solo mejora la precisión de los modelos, sino que también permite anticipar escenarios y optimizar la toma de decisiones en contextos educativos reales. De este modo, se contribuye al desarrollo de sistemas educativos más adaptativos, resilientes y orientados al bienestar integral del estudiante.

REFERENCIAS

- [1] Y. Wang and S. Xu, "Relationship between artificial intelligence tool usage experience and academic stress among college students: Mediating role of loneliness and moderating role of academic self-efficacy," *Acta Psychologica*, vol. 245, p. 106220, 2026, doi: 10.1016/j.actpsy.2026.106220.
- [2] E. Zaid, J. Qaddumi, H. Sabbagh, and F. Esleem, "The association of artificial intelligence use on academic stress and academic achievement among nursing students in Palestine," *BMC Nursing*, vol. 25, no. 1, 2026, doi: 10.1186/s12912-026-04666-0.
- [3] Z. Hamd *et al.*, "Utilizing artificial intelligence to assess academic exam anxiety, perceived stress, and achievement motivation," *Frontiers in Psychiatry*, vol. 17, 2026, doi: 10.3389/fpsy.2026.1686106.
- [4] A. Singh, K. Singh, A. Kumar, A. Shrivastava, and S. Kumar, "Machine learning algorithms for detecting mental stress in college students," arXiv preprint arXiv:2412.07415, 2024, doi: 10.48550/arXiv.2412.07415.
- [5] C. Janiesch, P. Zschech, and K. Heinrich, "Machine learning and deep learning," *Electronic Markets*, vol. 31, no. 3, pp. 685–695, 2021, doi: 10.1007/s12525-021-00475-2.
- [6] T. Baltrušaitis, C. Ahuja, and L.-P. Morency, "Multimodal machine learning: A survey and taxonomy," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 41, no. 2, pp. 423–443, 2019, doi: 10.1109/TPAMI.2018.2798607.
- [7] A. M. Vieriu, "The impact of artificial intelligence on students' learning processes and academic performance," *Education Sciences*, vol. 15, no. 3, p. 343, 2025, doi: 10.3390/educsci15030343.
- [8] S. Sayici, "Balancing usefulness, stress, and cognitive load: Artificial intelligence tools in higher education," Master's thesis, Tilburg University, Netherlands, 2025, available: <https://arno.uvt.nl/show.cgi?fid=185574>.

- [9] R. Tariq *et al.*, "Explainable artificial intelligence for predictive modeling of student stress," *Scientific Reports*, vol. 15, 2025, doi: 10.1038/s41598-025-22171-3.
- [10] D. Wang *et al.*, "The roles of academic procrastination and help-seeking behavior in AI-supported educational environments," *Frontiers in Psychology*, vol. 17, 2026, doi: 10.3389/fpsyg.2026.1578452.
- [11] S. Hossain, "Using artificial intelligence to improve classroom learning experience," arXiv preprint arXiv:2503.05709, 2025, doi: 10.48550/arXiv.2503.05709.
- [12] B. Klimova *et al.*, "Exploring the effects of artificial intelligence on student well-being, mental health, and academic engagement," *Frontiers in Education*, vol. 10, 2025, doi: 10.3389/educ.2025.1456721.
- [13] V. Chandola, A. Banerjee, and V. Kumar, "Anomaly detection: A survey," *ACM Computing Surveys*, vol. 41, no. 3, pp. 1–58, 2009, doi: 10.1145/1541880.1541882.
- [14] I. T. Jolliffe, *Principal Component Analysis*, 2nd ed. New York, NY, USA: Springer, 2002, doi: 10.1007/b98835.
- [15] J. Han, M. Kamber, and J. Pei, *Data Mining: Concepts and Techniques*, 3rd ed. Waltham, MA, USA: Morgan Kaufmann, 2011, doi: 10.1016/C2009-0-61819-5.

Artículo de investigación

<https://doi.org/10.47460/athenea.v7i24.139>

Modelos computacionales para la reducción de la sobrecarga cognitiva en estudiantes de administración

Karold Roxana Cáceres Gómez*
<https://orcid.org/0009-0005-5773-0666>
kcaceresg@unsa.edu.pe
Universidad Nacional de San Agustín de Arequipa
Arequipa, Perú

Stephanie Cris Cheneaux Márquez
<https://orcid.org/0000-0001-9163-6001>
stephanie.cheneaux@estudiante.ucsm.edu.pe
Universidad Católica de Santa María
Arequipa, Perú

Erick Percy Berrios Fernández
<https://orcid.org/0009-0009-8311-7282>
eberrios@ucsm.edu.pe
Universidad Católica de Santa María
Arequipa, Perú

Antonio Escobar Juárez
<https://orcid.org/0000-0001-5991-0410>
aescobar@ucsm.edu.pe
Universidad Católica de Santa María
Arequipa, Perú

Christian Herbert Cueva Allison
<https://orcid.org/0009-0008-4339-4798>
ccuevaa@ucsm.edu.pe
Universidad Católica de Santa María
Arequipa, Perú

*Autor de correspondencia: kcaceresg@unsa.edu.pe

Recibido: (12/02/2026), Aceptado: (10/05/2026)

Resumen. La investigación desarrolló un modelo computacional predictivo para identificar y reducir la sobrecarga cognitiva en estudiantes universitarios de administración en entornos digitales. Se aplicó un enfoque cuantitativo utilizando variables académicas, cognitivas y tecnológicas relacionadas con fatiga digital, estrés académico y uso de plataformas virtuales. Se implementaron algoritmos de aprendizaje automático como regresión logística, SVM y *Random Forest*, complementados con simulación computacional. Los resultados mostraron que *Random Forest* obtuvo el mejor desempeño predictivo y permitió detectar escenarios críticos de saturación cognitiva. Se concluye que los modelos computacionales pueden contribuir al diseño de sistemas educativos inteligentes orientados al bienestar académico.

Palabras clave: sobrecarga cognitiva, modelos computacionales, aprendizaje automático, fatiga digital, inteligencia artificial.

Computational Models for Reducing Cognitive Overload in Business Administration Students

Abstract. The study developed a predictive computational model to identify and reduce cognitive overload in undergraduate business administration students in digital environments. A quantitative approach was applied using academic, cognitive, and technological variables related to digital fatigue, academic stress, and the use of virtual platforms. Machine learning algorithms such as logistic regression, SVM, and *Random Forest* were implemented and complemented with computational simulation. The results showed that *Random Forest* achieved the best predictive performance and made it possible to detect critical scenarios of cognitive saturation. It is concluded that computational models can contribute to the design of intelligent educational systems oriented toward academic well-being.

Keywords: cognitive overload, computational models, machine learning, digital fatigue, artificial intelligence.

I. INTRODUCCIÓN

La transformación digital de los entornos universitarios ha incrementado significativamente la exposición de los estudiantes a múltiples estímulos informativos, plataformas virtuales y dinámicas académicas simultáneas, generando nuevos desafíos relacionados con la gestión de la carga mental y el procesamiento cognitivo. En este contexto, la sobrecarga cognitiva se ha convertido en un problema relevante dentro de la educación superior, especialmente en carreras vinculadas a procesos analíticos y toma de decisiones, como administración de empresas. Diversos estudios han demostrado que la acumulación excesiva de información y tareas digitales puede afectar negativamente la concentración, la productividad académica y el bienestar psicológico de los estudiantes [1], [2], [3].

El crecimiento de los sistemas educativos digitales ha impulsado además el interés por el desarrollo de herramientas basadas en inteligencia artificial orientadas a optimizar el aprendizaje y reducir la saturación cognitiva. Investigaciones recientes han señalado que los modelos computacionales y sistemas adaptativos permiten gestionar de manera más eficiente la complejidad de los entornos virtuales de aprendizaje, facilitando procesos de personalización educativa y regulación dinámica de actividades académicas [4], [5], [6]. De manera complementaria, enfoques basados en interacción humano-computador y analítica educativa han evidenciado que la detección temprana de estados de fatiga mental puede contribuir significativamente a mejorar el rendimiento estudiantil y la permanencia académica [7], [8].

Desde una perspectiva teórica, la teoría de la carga cognitiva continúa siendo uno de los principales marcos explicativos para comprender las limitaciones del procesamiento mental frente a escenarios educativos altamente demandantes. No obstante, investigaciones recientes han propuesto ampliar esta teoría mediante la integración de inteligencia artificial, neurociencia educativa y sistemas inteligentes capaces de adaptarse dinámicamente al comportamiento cognitivo del estudiante [9], [10], [11]. Asimismo, se ha señalado que el uso intensivo de herramientas digitales puede generar fenómenos simultáneos de apoyo cognitivo y saturación mental, dependiendo de la forma en que las tecnologías son implementadas dentro del proceso de aprendizaje [12].

A pesar de los avances existentes, aún persisten limitaciones relacionadas con la integración de modelos predictivos capaces de analizar simultáneamente variables académicas, tecnológicas y cognitivas dentro de contextos universitarios reales. Muchos estudios se concentran principalmente en aspectos pedagógicos o psicológicos, dejando en segundo plano el desarrollo de arquitecturas computacionales orientadas al monitoreo inteligente de estados cognitivos [13]. En consecuencia, resulta necesario fortalecer investigaciones interdisciplinarias que incorporen herramientas de aprendizaje automático, simulación computacional y análisis predictivo para comprender el comportamiento de la sobrecarga cognitiva en estudiantes universitarios [14].

En función de ello, el presente estudio tuvo como objetivo desarrollar y evaluar un modelo computacional predictivo orientado a la identificación de factores asociados a la sobrecarga cognitiva en estudiantes de administración dentro de entornos educativos digitales. Para ello, se integraron técnicas de aprendizaje automático, análisis estadístico y simulación computacional, con el propósito de diseñar un sistema inteligente capaz de contribuir a la reducción de la fatiga cognitiva y optimización del aprendizaje universitario.

II. MARCO TEÓRICO

La sobrecarga cognitiva constituye un fenómeno asociado a la incapacidad del sistema cognitivo para procesar eficientemente grandes volúmenes de información de manera simultánea. En entornos educativos digitales, este problema se ha intensificado debido al incremento de actividades virtuales, multitarea académica y exposición prolongada a plataformas tecnológicas [1], [3]. Diversos estudios han señalado que la saturación informativa afecta directamente la atención, memoria de trabajo, motivación y desempeño académico de los estudiantes universitarios [5], [12].

La teoría de la carga cognitiva ha sido uno de los principales fundamentos para comprender cómo el exceso de estímulos y demandas mentales impacta el aprendizaje. Sin embargo, investigaciones recientes sostienen que los modelos tradicionales deben complementarse con enfoques basados en inteligencia artificial y neurociencia educativa, capaces de analizar dinámicamente el comportamiento cognitivo del estudiante y adaptar el entorno de aprendizaje según sus necesidades [10], [14]. En este sentido, las tecnologías inteligentes permiten no solo automatizar procesos educativos, sino también optimizar la distribución de contenidos y reducir la fatiga mental generada por entornos digitales complejos [4].

El desarrollo de modelos computacionales aplicados a educación ha permitido incorporar herramientas de aprendizaje automático orientadas a la predicción de comportamientos académicos y estados cognitivos. Estudios recientes destacan que algoritmos computacionales como *Random Forest* y sistemas predictivos adaptativos poseen alta capacidad para identificar patrones relacionados con estrés académico, fatiga digital y sobrecarga cognitiva [2], [7]. Estas aproximaciones facilitan el diseño de sistemas inteligentes capaces de generar recomendaciones académicas personalizadas y mecanismos automáticos de regulación educativa.

De manera complementaria, la interacción humano-computador y la analítica educativa han adquirido relevancia dentro de los entornos virtuales de aprendizaje, particularmente en investigaciones orientadas a reducir la fatiga digital y mejorar la experiencia académica [11]. Asimismo, se ha señalado que el uso de inteligencia artificial puede generar simultáneamente beneficios cognitivos y riesgos de dependencia tecnológica, dependiendo del diseño e implementación de las herramientas digitales [13]. En consecuencia, la integración de modelos computacionales, aprendizaje automático y simulación predictiva representa una alternativa relevante para el desarrollo de sistemas educativos inteligentes capaces de monitorear y reducir la sobrecarga cognitiva en estudiantes universitarios, especialmente en contextos académicos caracterizados por alta demanda informacional y exposición tecnológica constante.

III. METODOLOGÍA

La investigación se desarrolló bajo un enfoque cuantitativo de tipo aplicado, orientado al diseño y evaluación de modelos computacionales para identificar y reducir la sobrecarga cognitiva en estudiantes universitarios de administración en entornos digitales. Se adoptó un diseño no experimental de alcance predictivo-explicativo, considerando variables académicas, cognitivas y tecnológicas asociadas al comportamiento estudiantil. La población estuvo conformada por estudiantes universitarios de administración en modalidad presencial y virtual. La muestra fue seleccionada mediante muestreo no probabilístico por conveniencia, considerando estudiantes con participación activa en plataformas virtuales de aprendizaje.

Para la recolección de datos se aplicó un cuestionario tipo Likert validado por expertos, orientado a medir dimensiones relacionadas con sobrecarga cognitiva, fatiga digital, estrés académico, complejidad de contenidos y rendimiento académico percibido. La confiabilidad del instrumento fue evaluada mediante el coeficiente alfa de Cronbach.

El componente ingenieril del estudio se centró en el desarrollo de un modelo computacional predictivo basado en técnicas de aprendizaje automático. Los datos fueron sometidos a procesos de limpieza, normalización y análisis estadístico previo al entrenamiento de los algoritmos. Se implementaron modelos como regresión logística y *Random Forest* para identificar patrones asociados a estados elevados de sobrecarga cognitiva, utilizando fases de entrenamiento y validación para evaluar la estabilidad del sistema.

Adicionalmente, se desarrolló una simulación computacional para representar distintos escenarios académicos relacionados con el incremento de carga mental, tiempo de exposición digital y estrés académico. El desempeño del modelo fue evaluado mediante métricas como *accuracy*, precisión, sensibilidad y *F1-score*, complementadas con análisis de importancia de variables para identificar los factores con mayor influencia dentro del sistema predictivo.

Finalmente, los resultados fueron analizados mediante estadística descriptiva, correlacional y regresión múltiple, utilizando herramientas de programación orientadas a sistemas inteligentes e ingeniería educativa.

IV. RESULTADOS

A. Caracterización de la muestra

Con el propósito de contextualizar el comportamiento de las variables cognitivas y tecnológicas analizadas, inicialmente se realizó una caracterización general de los estudiantes participantes. La distribución de la muestra permitió identificar patrones relevantes asociados al entorno académico digital, particularmente en relación con la intensidad de uso de plataformas virtuales, carga académica y tiempo

promedio de exposición tecnológica. La Tabla 1 presenta las principales características sociodemográficas y académicas consideradas en el estudio.

Tabla 1. Características generales de la muestra estudiantil.

Variable	Categoría	Frecuencia	Porcentaje (%)
Género	Femenino	78	52,0
	Masculino	72	48,0
Edad	18–21 años	64	42,7
	22–25 años	58	38,7
	26 años o más	28	18,6
Modalidad académica	Presencial	81	54,0
	Virtual	69	46,0
Tiempo diario en plataformas virtuales	1–3 horas	39	26,0
	4–6 horas	71	47,3
	Más de 6 horas	40	26,7
Nivel de carga académica percibida	Baja	18	12,0
	Moderada	79	52,7
	Alta	53	35,3

Nota. La tabla presenta la distribución sociodemográfica y académica de los estudiantes participantes.

Los resultados evidenciaron una distribución relativamente equilibrada entre hombres y mujeres, predominando estudiantes entre 18 y 25 años. Asimismo, se observó que el 74% de los participantes permanecía más de cuatro horas diarias interactuando con plataformas virtuales, situación que refleja una elevada exposición a entornos digitales de aprendizaje. De manera paralela, más de un tercio de los estudiantes reportó percibir niveles altos de carga académica, lo que sugiere condiciones potencialmente favorables para la aparición de sobrecarga cognitiva y fatiga mental. Desde una perspectiva ingenieril, estos resultados justificaron la necesidad de implementar modelos computacionales capaces de monitorear y predecir dinámicamente escenarios de saturación cognitiva, especialmente en contextos universitarios donde convergen múltiples estímulos digitales, actividades simultáneas y elevados requerimientos de procesamiento de información.

B. Validación y consistencia interna del instrumento

Con la finalidad de garantizar la confiabilidad y estabilidad estadística de las mediciones utilizadas en el modelo computacional, se evaluó la consistencia interna del instrumento aplicado a los estudiantes. El análisis permitió verificar el grado de coherencia entre los ítems asociados a las dimensiones cognitivas, académicas y tecnológicas incluidas en el estudio. La Tabla 2 presenta los coeficientes de confiabilidad obtenidos para cada dimensión evaluada.

Tabla 2. Consistencia interna de las dimensiones analizadas.

Dimensión	Número de ítems	Alfa de Cronbach
Sobrecarga cognitiva	8	0.91
Fatiga digital	6	0.88
Estrés académico	7	0.90
Complejidad percibida de contenidos	5	0.84
Interacción con plataformas virtuales	5	0.86
Rendimiento académico percibido	4	0.82
Instrumento global	35	0.93

Nota. Los coeficientes muestran la consistencia interna de las dimensiones utilizadas para alimentar el modelo computacional predictivo.

Los coeficientes obtenidos evidenciaron niveles elevados de consistencia interna en todas las dimensiones analizadas, registrándose valores superiores a 0,80, considerados adecuados para investigaciones aplicadas en ciencias sociales e ingeniería educativa. La dimensión asociada a sobrecarga cognitiva presentó el valor más alto de confiabilidad ($\alpha = 0,91$), indicando una elevada estabilidad en las respuestas

relacionadas con fatiga mental, saturación informativa y dificultad de procesamiento académico. De manera complementaria, el instrumento global alcanzó un alfa de Cronbach de 0,93, resultado que confirmó la robustez estadística del sistema de medición utilizado para alimentar el modelo computacional predictivo. Estos resultados permitieron establecer una base metodológica sólida para el procesamiento de datos y el entrenamiento de los algoritmos de aprendizaje automático implementados posteriormente. Desde el enfoque ingenieril, la validación del instrumento constituyó una etapa crítica dentro de la arquitectura computacional propuesta, debido a que la calidad y estabilidad de los datos de entrada condicionan directamente el desempeño predictivo de los modelos inteligentes utilizados para la detección de sobrecarga cognitiva en entornos educativos digitales.

C. Análisis descriptivo de las variables cognitivas y tecnológicas

Posteriormente, se realizó un análisis descriptivo de las principales variables incorporadas al modelo computacional, con el propósito de identificar tendencias asociadas a la sobrecarga cognitiva y al comportamiento académico-digital de los estudiantes. Este análisis permitió reconocer patrones iniciales relacionados con niveles de estrés, fatiga digital y percepción de complejidad académica, elementos fundamentales para el entrenamiento del sistema predictivo. La Figura 1 presenta los promedios obtenidos en las dimensiones evaluadas mediante escalas de cinco niveles.




Fig. 1. Promedio de las dimensiones cognitivas y tecnológicas analizadas.

Los resultados evidenciaron niveles elevados de interacción con plataformas virtuales y sobrecarga cognitiva, registrándose medias superiores a 4,0 en ambas dimensiones. Este comportamiento sugiere una relación directa entre la intensidad de exposición digital y el incremento de la fatiga mental en estudiantes universitarios de administración. Asimismo, el estrés académico presentó valores elevados y relativamente homogéneos entre los participantes, indicando una presencia constante de presión cognitiva dentro del entorno formativo. Por otro lado, el rendimiento académico percibido mostró valores moderados en comparación con las demás dimensiones, lo que podría indicar que el incremento sostenido de estímulos digitales y carga mental no necesariamente se traduce en mejoras proporcionales del desempeño académico. Esta tendencia resulta particularmente relevante desde el enfoque computacional, ya que evidencia la necesidad de sistemas inteligentes capaces de regular dinámicamente los niveles de complejidad educativa y distribución de tareas.

En términos ingenieriles, el comportamiento descriptivo de las variables permitió identificar condiciones críticas de saturación cognitiva que posteriormente fueron utilizadas como parámetros de entrada para el entrenamiento y simulación del modelo predictivo. Estos hallazgos constituyeron una base fundamental para la construcción de escenarios computacionales orientados a optimizar el equilibrio entre exigencia académica y capacidad de procesamiento cognitivo estudiantil.

D. Análisis correlacional y modelado matemático de la sobrecarga cognitiva

Con el objetivo de identificar relaciones funcionales entre las variables académicas, tecnológicas y cognitivas, se realizó un análisis correlacional previo al entrenamiento del modelo computacional. Esta

etapa permitió establecer la intensidad de asociación entre los factores estudiados y determinar cuáles variables presentaban mayor influencia sobre la sobrecarga cognitiva. La Tabla 3 presenta la matriz de correlaciones obtenida mediante el coeficiente de Pearson.

Tabla 3. Correlaciones entre variables asociadas a la sobrecarga cognitiva.

Variables	1	2	3	4	5	6
1. Sobrecarga cognitiva	1,00					
2. Fatiga digital	0,81	1,00				
3. Estrés académico	0,76	0,71	1,00			
4. Complejidad de contenidos	0,69	0,62	0,66	1,00		
5. Tiempo en plataformas virtuales	0,73	0,79	0,58	0,54	1,00	
6. Rendimiento académico	-0,48	-0,41	-0,45	-0,32	-0,29	1,00

Nota. Las correlaciones fueron estimadas mediante el coeficiente de Pearson.

Los resultados evidenciaron correlaciones positivas elevadas entre sobrecarga cognitiva y fatiga digital ($r = 0,81$), así como entre sobrecarga cognitiva y estrés académico ($r = 0,76$), indicando que el incremento sostenido de estímulos digitales y presión académica influye directamente en la saturación mental de los estudiantes. Del mismo modo, el tiempo de exposición a plataformas virtuales mostró una asociación considerable con fatiga digital ($r = 0,79$), reflejando la incidencia de los entornos tecnológicos sobre el procesamiento cognitivo estudiantil. En contraste, el rendimiento académico presentó correlaciones negativas moderadas respecto a las variables cognitivas, sugiriendo que niveles elevados de saturación mental podrían afectar progresivamente la percepción de desempeño académico. Estos resultados respaldaron la necesidad de implementar mecanismos computacionales orientados al monitoreo dinámico de estados cognitivos críticos. A partir de las variables con mayor capacidad explicativa, se formuló un modelo matemático multivariable para representar el comportamiento de la sobrecarga cognitiva dentro del sistema computacional propuesto. El modelo fue expresado mediante una ecuación de regresión lineal múltiple:

$$SC = \beta_0 + \beta_1 FD + \beta_2 EA + \beta_3 CV + \beta_4 TP - \beta_5 RA + \varepsilon \quad (1)$$

donde: (SC): sobrecarga cognitiva, (FD): fatiga digital, (EA): estrés académico, (CV): complejidad de contenidos, (TP): tiempo en plataformas virtuales, (RA): rendimiento académico, (ε): término de error del modelo.

La formulación matemática permitió representar computacionalmente la interacción simultánea entre variables cognitivas y tecnológicas, facilitando posteriormente el entrenamiento del sistema predictivo basado en aprendizaje automático. Desde el enfoque ingenieril, este modelo constituyó la estructura funcional inicial para la simulación de escenarios educativos adaptativos y para la detección automatizada de estados de alta carga mental dentro de ambientes universitarios digitales.

E. Entrenamiento y desempeño del modelo computacional predictivo

Con el propósito de identificar patrones asociados a estados de sobrecarga cognitiva y generar predicciones automatizadas dentro del entorno académico digital, se implementaron distintos algoritmos de aprendizaje automático utilizando las variables cognitivas, académicas y tecnológicas previamente analizadas. El conjunto de datos fue dividido en una fase de entrenamiento (80%) y una fase de validación (20%), permitiendo evaluar la estabilidad y capacidad predictiva de cada modelo computacional bajo condiciones controladas. Inicialmente, se compararon tres algoritmos ampliamente utilizados en sistemas inteligentes y analítica predictiva: regresión logística, máquinas de soporte vectorial (SVM) y *Random Forest*. La evaluación del desempeño se realizó mediante métricas de clasificación orientadas a determinar la capacidad del sistema para detectar escenarios de alta sobrecarga cognitiva en estudiantes universitarios. La Tabla 4 presenta los resultados comparativos obtenidos durante el proceso de validación computacional.

Tabla 4. Desempeño comparativo de los modelos predictivos implementados.

Modelo computacional	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
Regresión logística	0,81	0,79	0,77	0,78
SVM	0,85	0,83	0,82	0,82
<i>Random Forest</i>	0,91	0,89	0,90	0,89

Nota. El conjunto de datos fue dividido en 80% para entrenamiento y 20% para validación.

Los resultados evidenciaron que el algoritmo *Random Forest* alcanzó el mejor desempeño global, registrando una exactitud del 91% y valores superiores en todas las métricas de clasificación. Este comportamiento indicó una elevada capacidad del modelo para reconocer patrones complejos asociados a la saturación cognitiva estudiantil, incluso en escenarios donde múltiples variables interactuaban simultáneamente. Por otro lado, aunque la regresión logística presentó resultados aceptables, su capacidad predictiva fue inferior frente a los algoritmos basados en aprendizaje no lineal, particularmente en contextos donde la interacción entre variables cognitivas y tecnológicas resultó altamente dinámica. De manera similar, el modelo SVM mostró un desempeño intermedio, evidenciando una adecuada capacidad de clasificación, aunque con menor estabilidad frente a variaciones en los datos de entrenamiento.

Desde el enfoque ingenieril, los resultados confirmaron que los modelos basados en ensamblaje computacional poseen una mayor capacidad para representar sistemas educativos complejos caracterizados por múltiples factores simultáneos de influencia. La arquitectura *Random Forest* permitió además reducir problemas de sobreajuste y mejorar la generalización predictiva del sistema inteligente propuesto. Complementariamente, el comportamiento matemático del algoritmo seleccionado puede representarse mediante una función de decisión basada en la agregación de árboles de clasificación independientes:

$$F(x) = \frac{1}{N} \sum_{i=1}^N T_i(x) \quad (2)$$

donde: ($F(x)$) representa la predicción final del sistema computacional, ($T_i(x)$) corresponde a cada árbol de decisión individual, (N) representa el número total de árboles utilizados en el modelo.

Esta formulación permitió integrar múltiples criterios de decisión dentro de un único sistema predictivo robusto, incrementando la precisión del análisis cognitivo y facilitando la detección temprana de condiciones académicas potencialmente críticas. Desde una perspectiva aplicada, el modelo desarrollado puede constituir la base para futuros sistemas inteligentes adaptativos capaces de regular dinámicamente actividades académicas, complejidad de contenidos y distribución de tareas según el estado cognitivo estimado de cada estudiante.

F. Simulación computacional de escenarios académicos

Con la finalidad de analizar el comportamiento dinámico del modelo predictivo ante diferentes condiciones académicas y tecnológicas, se desarrolló una simulación computacional basada en escenarios progresivos de carga cognitiva. Esta etapa permitió evaluar la sensibilidad del sistema inteligente frente a variaciones en el tiempo de exposición digital, complejidad de contenidos y niveles de estrés académico, reproduciendo condiciones similares a las experimentadas en entornos universitarios reales.

La simulación fue ejecutada mediante iteraciones computacionales controladas, donde las variables de entrada fueron modificadas gradualmente para observar el comportamiento predictivo del algoritmo *Random Forest*. Los escenarios evaluados permitieron estimar probabilidades de saturación cognitiva y detectar umbrales críticos asociados al deterioro del rendimiento académico. La Figura 2 presenta el comportamiento del nivel estimado de sobrecarga cognitiva según el incremento progresivo de la exposición digital y presión académica.




Fig. 2. Simulación computacional del nivel de sobrecarga cognitiva en función de la exposición digital y estrés académico.

Los resultados evidenciaron un crecimiento no lineal de la sobrecarga cognitiva conforme aumentaban simultáneamente las horas de interacción digital y los niveles de presión académica. Particularmente, los escenarios superiores a seis horas diarias de exposición tecnológica mostraron incrementos acelerados en los niveles de saturación mental, aproximándose a estados críticos de fatiga cognitiva y disminución del rendimiento académico. Desde el análisis computacional, el modelo demostró una elevada sensibilidad frente a cambios pequeños en las variables de entrada, permitiendo detectar transiciones rápidas entre estados moderados y críticos de carga mental. Este comportamiento resultó especialmente relevante para el diseño de sistemas inteligentes adaptativos, ya que evidencia la posibilidad de implementar mecanismos automáticos de alerta temprana y regulación académica. El comportamiento dinámico de la simulación pudo representarse mediante una función de crecimiento no lineal asociada al incremento acumulativo de estímulos cognitivos:

$$SC(t) = \alpha \ln(ED + 1) + \beta EA + \gamma CC \quad (3)$$

donde: ($SC(t)$): nivel de sobrecarga cognitiva estimada, (ED): exposición digital, (EA): estrés académico, (CC): complejidad de contenidos, (α, β, γ): coeficientes de ponderación del sistema.

La incorporación de esta formulación matemática permitió representar computacionalmente la evolución progresiva de la carga cognitiva en función de múltiples estímulos académicos simultáneos. Desde el enfoque ingenieril, la simulación desarrollada constituye un aporte relevante para el diseño de plataformas inteligentes orientadas a monitorear estados cognitivos en tiempo real y optimizar dinámicamente la distribución de actividades educativas dentro de entornos universitarios digitales.

G. Importancia computacional de las variables predictoras

Con el propósito de identificar cuáles factores ejercían mayor influencia dentro del sistema inteligente propuesto, se realizó un análisis de importancia de variables utilizando el algoritmo *Random Forest* seleccionado previamente. Esta etapa permitió cuantificar el aporte relativo de cada variable al proceso de predicción de la sobrecarga cognitiva, facilitando la comprensión del comportamiento interno del modelo computacional y fortaleciendo la interpretabilidad del sistema. El análisis de importancia se ejecutó mediante la reducción promedio de impureza generada por cada variable dentro de los árboles de decisión del modelo. Este procedimiento permitió determinar cuáles factores contribuían en mayor medida a la clasificación de estados cognitivos críticos. La Figura 3 presenta la jerarquización computacional de las variables predictoras incorporadas en el sistema.




Fig. 3. Importancia relativa de las variables dentro del modelo predictivo.

Los resultados evidenciaron que la fatiga digital constituyó la variable de mayor influencia dentro del sistema predictivo, seguida del estrés académico y del tiempo de interacción con plataformas virtuales. Este comportamiento confirmó que la exposición prolongada a entornos digitales y la acumulación de presión académica representan factores determinantes en la aparición de estados de saturación cognitiva en estudiantes universitarios. Asimismo, la complejidad percibida de los contenidos presentó una influencia considerable dentro del modelo, indicando que no solamente la cantidad de actividades académicas afecta la carga mental, sino también el nivel de dificultad cognitiva requerido para procesar la información. En contraste, variables como calidad del descanso y rendimiento académico mostraron una participación menor dentro de la estructura predictiva, aunque continuaron aportando información relevante para mejorar la estabilidad global del sistema.

Desde el enfoque ingenieril, estos resultados permitieron optimizar la arquitectura computacional mediante la priorización de variables críticas durante el entrenamiento del algoritmo. La reducción de dimensionalidad y la identificación de factores dominantes favorecieron además la eficiencia computacional del modelo, disminuyendo tiempos de procesamiento y mejorando la capacidad de generalización predictiva. La importancia relativa de las variables dentro del sistema puede representarse matemáticamente mediante una función ponderada de contribución computacional:

$$I_j = \frac{\sum_{k=1}^n \Delta E_{jk}}{\sum_{j=1}^m \sum_{k=1}^n \Delta E_{jk}} \quad (4)$$

donde: (I_j): importancia relativa de la variable (j), (ΔE_{jk}): reducción de error generada por la variable (j) en el nodo (k), (m): número total de variables, (n): número total de nodos evaluados.

Esta formulación permitió cuantificar matemáticamente el aporte individual de cada variable al desempeño global del sistema inteligente, proporcionando una base sólida para el diseño de futuras plataformas adaptativas orientadas a la regulación automática de la carga cognitiva en contextos educativos digitales.

H. Arquitectura del sistema inteligente para la reducción de la sobrecarga cognitiva

Con base en los resultados obtenidos mediante el análisis estadístico, el modelado matemático y la simulación computacional, se diseñó una arquitectura conceptual orientada a la detección y mitigación automatizada de estados de sobrecarga cognitiva en estudiantes universitarios. El sistema propuesto integra procesos de adquisición de datos académicos, análisis predictivo y retroalimentación adaptativa, permitiendo generar recomendaciones dinámicas según el comportamiento cognitivo estimado del estudiante. La arquitectura desarrollada fue estructurada en cuatro módulos principales: adquisición de variables cognitivas y académicas, procesamiento computacional de datos, motor predictivo basado en aprendizaje automático y sistema adaptativo de respuesta académica. La Figura 4 presenta la estructura funcional del sistema inteligente propuesto.




Fig. 4. Arquitectura conceptual del sistema inteligente para la reducción de la sobrecarga cognitiva.

Los resultados obtenidos demostraron que la integración de modelos computacionales dentro de entornos educativos universitarios permite detectar tempranamente condiciones asociadas a fatiga mental y saturación cognitiva. Asimismo, la arquitectura propuesta evidencia el potencial de los sistemas inteligentes adaptativos para optimizar procesos de aprendizaje mediante mecanismos automáticos de regulación académica. Desde el enfoque ingenieril, el sistema desarrollado constituye una aproximación funcional hacia plataformas educativas capaces de combinar analítica predictiva, modelado matemático y aprendizaje automático en tiempo real, favoreciendo una gestión más eficiente de los procesos cognitivos estudiantiles en entornos digitales de alta exigencia.

CONCLUSIONES

Los resultados obtenidos evidenciaron que la sobrecarga cognitiva en estudiantes de administración se encuentra estrechamente relacionada con factores como la fatiga digital, el estrés académico y el tiempo de interacción con plataformas virtuales. La elevada exposición a entornos digitales y la acumulación simultánea de actividades académicas generaron condiciones favorables para el incremento de la saturación mental y la disminución del rendimiento académico percibido. El desarrollo del modelo computacional predictivo permitió identificar patrones relevantes asociados a estados de alta carga cognitiva, demostrando que las técnicas de aprendizaje automático constituyen herramientas efectivas para el análisis de variables académicas y cognitivas en contextos universitarios digitales. Entre los algoritmos implementados, el modelo *Random Forest* presentó el mejor desempeño predictivo, alcanzando niveles elevados de precisión y estabilidad computacional.

Asimismo, la simulación de escenarios académicos confirmó que el incremento progresivo de la exposición digital y la presión académica produce un crecimiento significativo de los niveles de sobrecarga cognitiva. Estos hallazgos evidencian la necesidad de incorporar sistemas inteligentes adaptativos capaces de monitorear dinámicamente el comportamiento cognitivo estudiantil y generar mecanismos automáticos de regulación académica. Desde el enfoque ingenieril, la investigación permitió integrar modelado matemático, aprendizaje automático y simulación computacional dentro de una arquitectura funcional orientada a la detección temprana de estados críticos de fatiga mental. El sistema propuesto representa una aproximación aplicable al desarrollo de plataformas educativas inteligentes capaces de optimizar procesos de aprendizaje mediante análisis predictivo y adaptación dinámica de actividades académicas.

Finalmente, el estudio aporta evidencia sobre el potencial de la inteligencia artificial y los modelos computacionales para fortalecer la gestión educativa en entornos digitales universitarios, contribuyendo al diseño de estrategias orientadas a mejorar el bienestar cognitivo y la sostenibilidad del aprendizaje en contextos de creciente complejidad tecnológica.

REFERENCIAS

- [1] N. Qamar, I. Ullah, F. Zeib, and M. Z. Khan, "The role of AI in reducing cognitive overload complex learning environments," *Review of Applied Management and Social Sciences*, vol. 8, no. 2, pp. 1111–1127, 2025, doi: 10.47067/ramss.v8i2.541.
- [2] H. Pang, X. Jin, and W. Zhang, "Deciphering the underlying repercussions of cognitive overload on university students' fatigue, frustration and academic productivity: Implementation of stimulus–organism–response model," *Acta Psychologica*, vol. 260, p. 105469, 2025, art. no. 105469. doi: 10.1016/j.actpsy.2025.105469.
- [3] M. A. Pasha, S. Nadeem, A. Rasool, F. Shafique, H. Imran, S. Kanwal, and K. Yasmeen, "Digital fatigue and cognitive overload as managerial challenges understanding the impact of workload management on the workforce," *The Critical Review of Social Sciences Studies*, vol. 3, no. 4, pp. 1629–1641, 2025, doi: 10.52970/grsse.v5i2.1275.
- [4] M. Kabir, A. Zafar, Z. Naz, and F. Maqsood, "The role of personalized AI-based learning tools in reducing cognitive overload and enhancing academic motivation," *Review of Applied Management and Social Sciences*, vol. 8, no. 3, pp. 1261–1275, 2025, doi: 10.47067/ramss.v8i3.544.
- [5] S. M. Kashlot, I. Ruthven, and Y. Moshfeghi, "Strategies for managing information overload: a systematic review," *Journal of Documentation*, vol. 82, no. 2, pp. 249–265, 2026, doi: 10.1108/JD-09-2025-0257.
- [6] S. Barigidad, S. Hameed, N. Karri, S. K. Jangam, P. S. R. Pedda, and D. Gupta, "Computational modeling of AI-enhanced learning pathways: A mathematical framework for optimizing knowledge acquisition, cognitive load management, and student performance in STEM education," in *2025 International Conference on AI-Driven STEM Education and Learning Technologies (AISTEMEDU)*, 2025, pp. 1–7.
- [7] M. N. Algewatta and K. Manathunga, "A BI approach for student engagement and retention along with cognitive load analysis for educator," in *2025 5th International Conference on Advanced Research in Computing (ICARC)*, Belihuloya, Sri Lanka, 2025, pp. 1–6, doi: 10.1109/ICARC64760.2025.10962823.
- [8] L. Rodrig and L. Marlow, "Cognitive load management in digital learning environments: Implications for student performance," *Innovative Journal of Educational Research and Insights*, pp. 188–197, 2025.
- [9] E. Gkintoni, H. Antonopoulou, A. Sortwell, and C. Halkiopoulos, "Challenging cognitive load theory: The role of educational neuroscience and artificial intelligence in redefining learning efficacy," *Brain Sciences*, vol. 15, no. 2, p. 203, 2025, art. no. 203. doi: 10.3390/brainsci15020203.
- [10] K. Twabu, "Enhancing the cognitive load theory and multimedia learning framework with AI insight," *Discover Education*, vol. 4, p. 160, 2025, art. no. 160. doi: 10.1007/s44217-025-00592-6.
- [11] X. Wan and J. Liu, "Human-computer interaction strategies to alleviate information overload in business contexts," *International Journal of Human–Computer Interaction*, vol. 41, no. 21, pp. 13 349–13 362, 2025, doi: 10.1080/10447318.2025.2470296.
- [12] P. Gupta and A. Prashar, "Learners' psychological needs in online learning environment for executive education: role of cognitive overload and learning self-efficacy," *Behaviour & Information Technology*, vol. 44, no. 9, pp. 1942–1963, 2025, doi: 10.1080/0144929X.2024.2383777.
- [13] G. Chirayath, K. Premamalini, and J. Joseph, "Cognitive offloading or cognitive overload? How AI alters the mental architecture of coping," *Frontiers in Psychology*, vol. 16, p. 1699320, 2025, art. no. 1699320. doi: 10.3389/fpsyg.2025.1699320.
- [14] A. Batubara, F. Rachman, R. Nababan, L. Siagian, and A. Latifah, "Brain flow: A gamified digital assessment with chunking enhancing patriotism reducing cognitive overload," in *International Conference on Social Sciences and Interdisciplinary Studies (ICSSIS 2025)*. Paris, France: Atlantis Press, 2025, pp. 273–281, doi: 10.2991/978-2-38476-499-0_22.

Artículo de investigación

<https://doi.org/10.47460/athenea.v7i24.141>

Diseño de una plataforma basada en inteligencia artificial para la gestión adaptativa de la ansiedad en entornos universitarios digitales

Ferdinand Eddington Ceballos Bejarano*
<https://orcid.org/0000-0003-2867-2397>
fcebaltos@unsa.edu.pe
Universidad Nacional de San Agustín de Arequipa
Arequipa, Perú

Nancy Teresa Ramos-Huaricallo
<https://orcid.org/0000-0003-4581-6866>
nramos@ucsm.edu.pe
Universidad Católica de Santa María
Arequipa, Perú

Jimmy Ángel Díaz Flores
<https://orcid.org/0000-0003-0330-6673>
jdiazfl@unsa.edu.pe
Universidad Nacional de San Agustín de Arequipa
Arequipa, Perú

Paola Jessica Alarcón Saravia
<https://orcid.org/0000-0002-5235-8755>
palarcons@unsa.edu.pe
Universidad Nacional de San Agustín de Arequipa
Arequipa, Perú

Miguel Ángel Pacheco Quico
<https://orcid.org/0000-0002-2767-9602>
mpachecoq@unsa.edu.pe
Universidad Nacional de San Agustín de Arequipa
Arequipa, Perú

*Autor de correspondencia: fcebaltos@unsa.edu.pe

Recibido: (02/02/2026), Aceptado: (10/05/2026)

Resumen. La transformación digital de la educación superior ha incrementado la necesidad de desarrollar estrategias tecnológicas y diseños de ingeniería orientadas al bienestar emocional estudiantil en entornos virtuales. El objetivo de este trabajo fue hacer un diseño de ingeniería para el apoyo en el control de la ansiedad en entornos universitarios digitales. El estudio presentó un enfoque cuantitativo con diseño cuasi experimental y participación de 240 estudiantes universitarios distribuidos en grupo experimental y grupo de control. La plataforma integró monitoreo emocional, análisis predictivo y mecanismos de intervención adaptativa mediante algoritmos de aprendizaje automático. Los resultados evidenciaron una reducción significativa de ansiedad, estrés y carga cognitiva en el grupo experimental, así como altos niveles de precisión predictiva en los modelos implementados. Se concluye que la inteligencia artificial adaptativa representa una alternativa viable para fortalecer ecosistemas educativos digitalmente más humanos y preventivos.

Palabras clave: inteligencia artificial, ansiedad académica, educación digital, sistemas adaptativos.

Design of an Artificial Intelligence-Based Platform for the Adaptive Management of Anxiety in Digital University Environments

Abstract. The digital transformation of higher education has increased the need to develop technological strategies and engineering designs aimed at supporting students' emotional well-being in virtual environments. The objective of this study was to develop an engineering design to support anxiety management in digital university environments. The study adopted a quantitative approach with a quasi-experimental design and involved 240 university students distributed into an experimental group and a control group. The platform integrated emotional monitoring, predictive analysis, and adaptive intervention mechanisms through machine learning algorithms. The results showed a significant reduction in anxiety, stress, and cognitive load in the experimental group, as well as high levels of predictive accuracy in the implemented models. It is concluded that adaptive artificial intelligence represents a viable alternative for strengthening more human-centered and preventive digital educational ecosystems.

Keywords: artificial intelligence, academic anxiety, digital education, adaptive systems.

I. INTRODUCCIÓN

La transformación digital de la educación superior ha generado nuevas dinámicas de aprendizaje caracterizadas por una alta dependencia de entornos virtuales y tecnologías inteligentes. Aunque estos ecosistemas digitales han ampliado las posibilidades de acceso y flexibilidad académica, también han favorecido el incremento de problemas asociados con ansiedad, estrés académico y sobrecarga cognitiva en estudiantes universitarios [1], [2]. Diversos estudios han señalado que la hiperconectividad, la presión académica constante y la limitada regulación emocional dentro de plataformas educativas tradicionales pueden afectar significativamente el bienestar psicológico estudiantil [3], [4].

En respuesta a esta problemática, la inteligencia artificial ha comenzado a consolidarse como una herramienta prometedora para el desarrollo de sistemas adaptativos capaces de identificar patrones emocionales y generar intervenciones personalizadas [5]. El avance de áreas como el *affective computing*, el aprendizaje automático y la analítica emocional ha permitido diseñar plataformas inteligentes orientadas a mejorar la regulación emocional y la experiencia de aprendizaje en contextos digitales [6], [7]. Asimismo, investigaciones recientes han evidenciado que los sistemas adaptativos basados en inteligencia artificial pueden contribuir a reducir ansiedad y estrés mediante mecanismos de acompañamiento automatizado y recomendaciones dinámicas [8], [9].

Desde una perspectiva de ingeniería aplicada, el desarrollo de plataformas inteligentes para la gestión emocional estudiantil requiere la integración de modelos computacionales, sistemas adaptativos y algoritmos de inteligencia artificial capaces de responder dinámicamente a variables cognitivas y conductuales en tiempo real. En este contexto, el diseño de arquitecturas tecnológicas orientadas al monitoreo emocional y la intervención adaptativa representa una línea emergente dentro de la ingeniería de sistemas inteligentes aplicada a educación digital y salud mental computacional. La incorporación de modelos matemáticos predictivos, analítica emocional y mecanismos automatizados de retroalimentación permite construir entornos universitarios más preventivos, personalizados y capaces de adaptarse continuamente a las necesidades emocionales de los estudiantes [10], [11].

No obstante, aún existe una limitada cantidad de investigaciones enfocadas específicamente en el diseño de plataformas integrales para la gestión adaptativa de la ansiedad en entornos universitarios digitales [12]. En este contexto, la presente investigación tuvo como objetivo diseñar una plataforma basada en inteligencia artificial orientada al monitoreo emocional, análisis predictivo e intervención adaptativa para fortalecer el bienestar psicológico estudiantil dentro de ecosistemas educativos virtuales.

II. MARCO TEÓRICO

La ansiedad académica constituye uno de los principales desafíos emergentes en los entornos universitarios digitales debido al incremento de exigencias cognitivas, interacción virtual permanente y dependencia tecnológica en los procesos de aprendizaje [1], [2]. Diversos estudios han evidenciado que los estudiantes expuestos a modalidades virtuales intensivas presentan mayores niveles de estrés, fatiga digital y dificultades de regulación emocional cuando las plataformas educativas carecen de mecanismos de acompañamiento psicológico y adaptación personalizada [3], [4]. Esta problemática ha impulsado el interés por desarrollar soluciones tecnológicas orientadas al monitoreo emocional y bienestar estudiantil.

En los últimos años, la inteligencia artificial ha comenzado a desempeñar un papel relevante en el desarrollo de sistemas adaptativos capaces de identificar patrones emocionales y generar intervenciones automatizadas en tiempo real [5]. El avance del *affective computing* y de los modelos de aprendizaje automático ha permitido diseñar herramientas capaces de interpretar señales conductuales y emocionales derivadas de la interacción digital de los usuarios [6], [7]. Estos enfoques han favorecido el surgimiento de plataformas inteligentes orientadas a fortalecer la regulación emocional, la motivación académica y la personalización del aprendizaje en contextos universitarios digitalizados [8].

Dentro de este contexto, los sistemas adaptativos de aprendizaje representan una de las aplicaciones más relevantes de inteligencia artificial en educación superior. Estos sistemas utilizan información conductual, cognitiva y emocional para modificar dinámicamente contenidos, recomendaciones y estrategias de intervención según las necesidades específicas de los estudiantes [9]. Investigaciones recientes han demostrado que la integración de modelos predictivos y analítica emocional puede mejorar significativamente la experiencia de aprendizaje y disminuir indicadores asociados con ansiedad académica y sobrecarga cognitiva [12].

El uso de asistentes virtuales y *chatbots* inteligentes también ha mostrado resultados favorables en procesos de acompañamiento emocional universitario. Algunas investigaciones evidencian que estas herramientas contribuyen a disminuir niveles de estrés y ansiedad mediante apoyo automatizado, orientación personalizada y generación de entornos digitales más interactivos y humanizados [10], [11]. Asimismo, los algoritmos de clasificación predictiva, como *Random Forest* y regresión logística, han permitido identificar patrones de riesgo emocional asociados con hábitos de interacción digital y desempeño académico [13].

Paralelamente, diversos estudios han señalado que la percepción estudiantil frente al uso de inteligencia artificial en salud mental suele ser favorable cuando los sistemas incorporan adaptabilidad, empatía digital y mecanismos de retroalimentación continua [14]. Sin embargo, pese al crecimiento de investigaciones relacionadas con inteligencia artificial emocional y bienestar universitario, todavía existen limitaciones importantes en el diseño de plataformas integrales orientadas específicamente a la gestión adaptativa de la ansiedad académica en entornos digitales [15]. Esta situación evidencia la necesidad de desarrollar arquitecturas inteligentes interdisciplinarias capaces de integrar monitoreo emocional, análisis predictivo e intervención adaptativa dentro de los ecosistemas universitarios contemporáneos.

III. METODOLOGÍA

La investigación se desarrolló bajo un enfoque cuantitativo de carácter interdisciplinario, integrando componentes propios de la ingeniería de sistemas inteligentes, la analítica computacional y el análisis social del bienestar emocional estudiantil en entornos universitarios digitales. El estudio presentó un diseño cuasi experimental de tipo aplicado, orientado al diseño y evaluación de una plataforma basada en inteligencia artificial para la gestión adaptativa de la ansiedad académica mediante procesos automatizados de monitoreo emocional e intervención inteligente.

La población estuvo conformada por estudiantes universitarios pertenecientes a programas académicos desarrollados en modalidad virtual e híbrida. La muestra estuvo integrada por 240 estudiantes seleccionados mediante un muestreo no probabilístico por conveniencia, considerando criterios de participación voluntaria, acceso continuo a plataformas virtuales y frecuencia de interacción académica digital. Los participantes fueron distribuidos en dos grupos de estudio: un grupo experimental compuesto por 120 estudiantes que interactuaron con la plataforma inteligente adaptativa y un grupo de control conformado por 120 estudiantes que utilizaron únicamente entornos virtuales tradicionales sin mecanismos de intervención automatizada.

Desde la dimensión social de la investigación, se analizaron variables relacionadas con ansiedad académica, estrés percibido, carga cognitiva, bienestar emocional e interacción digital estudiantil. Para ello, se aplicaron instrumentos psicométricos estructurados orientados a evaluar percepciones emocionales y niveles de adaptación académica dentro de contextos virtuales. Asimismo, se incorporaron indicadores conductuales asociados con patrones de conexión, frecuencia de acceso, participación en actividades académicas y tiempos de interacción digital. Los instrumentos utilizados fueron sometidos a procesos de validación mediante análisis factorial exploratorio y consistencia interna a través del coeficiente alfa de Cronbach.

Desde la perspectiva ingenieril, la investigación contempló el diseño de una arquitectura tecnológica inteligente compuesta por cuatro módulos funcionales: captura de datos, procesamiento emocional, motor de inteligencia artificial y sistema adaptativo de intervención. El módulo de captura permitió integrar información psicométrica y datos derivados de la interacción digital de los estudiantes con el entorno virtual de aprendizaje. Posteriormente, el módulo de procesamiento emocional ejecutó tareas de normalización, clasificación y extracción de patrones asociados con niveles de ansiedad y comportamiento académico digital.

El motor de inteligencia artificial fue desarrollado mediante algoritmos de aprendizaje automático supervisado, implementando modelos de *Random Forest*, regresión logística y árboles de decisión para identificar patrones predictivos relacionados con ansiedad académica y riesgo emocional. El entrenamiento computacional del sistema se realizó mediante procesos de validación cruzada y optimización iterativa de parámetros, utilizando métricas de precisión, sensibilidad, especificidad y área bajo la curva ROC para evaluar el desempeño de los modelos predictivos.

Con el propósito de fortalecer el comportamiento adaptativo del sistema, se diseñó un modelo

matemático orientado a calcular dinámicamente un Índice Adaptativo de Ansiedad (IAA) a partir de variables emocionales, cognitivas y conductuales. Este modelo permitió que la plataforma ajustara automáticamente sus mecanismos de intervención según las variaciones emocionales detectadas en tiempo real.

$$IAA(t) = \alpha E(t) + \beta C(t) + \gamma D(t) + \delta R(t) \quad (1)$$

donde $E(t)$ representa el estrés emocional, $C(t)$ la carga cognitiva, $D(t)$ la interacción digital y $R(t)$ el rendimiento académico relativo. Los coeficientes de ponderación fueron calibrados computacionalmente mediante procesos de normalización adaptativa.

A partir de los valores obtenidos por el índice adaptativo, la plataforma ejecutó mecanismos automatizados de intervención utilizando funciones dinámicas de activación orientadas a estimar probabilidades de riesgo emocional y necesidad de acompañamiento digital.

$$I(t) = \frac{1}{1 + e^{-k(IAA(t)-\theta)}} \quad (2)$$

La implementación de este modelo permitió generar recomendaciones personalizadas, pausas cognitivas, mensajes de regulación emocional y alertas tempranas orientadas al fortalecimiento del bienestar psicológico estudiantil dentro del entorno universitario digital. El análisis estadístico se desarrolló mediante técnicas descriptivas e inferenciales. Se calcularon medias, desviaciones estándar y distribuciones porcentuales para caracterizar el comportamiento emocional y digital de los participantes. Posteriormente, se aplicaron pruebas de correlación de Pearson, regresión múltiple y comparación de medias entre el grupo experimental y el grupo de control para evaluar el efecto de la plataforma inteligente sobre las variables analizadas.

Finalmente, la investigación consideró principios éticos relacionados con confidencialidad, consentimiento informado digital y anonimización de datos emocionales y conductuales. La información recopilada fue utilizada exclusivamente con fines académicos y científicos, garantizando el uso responsable de los datos procesados por la plataforma inteligente.

IV. RESULTADOS

El análisis inicial permitió identificar diferencias relevantes entre los estudiantes que interactuaron con la plataforma inteligente adaptativa y aquellos que permanecieron en el entorno virtual convencional. Antes de la intervención, ambos grupos presentaban niveles similares de ansiedad académica y carga cognitiva, lo que evidenció condiciones iniciales comparables para el desarrollo del estudio. Sin embargo, tras la implementación de la plataforma basada en inteligencia artificial, comenzaron a observarse variaciones importantes en los indicadores emocionales y conductuales asociados al aprendizaje digital. La Tabla 1 presenta las características generales de la muestra estudiada, incluyendo distribución por área académica, modalidad educativa y frecuencia de interacción digital.

Tabla 1. Características generales de la muestra estudiada.

Variable	Categoría	Frecuencia	Porcentaje (%)
Sexo	Femenino	136	56,7
	Masculino	104	43,3
Área académica	Ingeniería	78	32,5
	Ciencias sociales	74	30,8
	Administración y negocios	88	36,7
Modalidad	Virtual	142	59,2
	Híbrida	98	40,8
Grupo	Experimental	120	50,0
	Control	120	50,0
Nivel alto de interacción digital	Sí	171	71,3
	No	69	28,7

Nota. La tabla presenta la distribución general de la muestra según sexo, área académica, modalidad, grupo de estudio e interacción digital.

Los resultados descriptivos evidenciaron una elevada exposición de los estudiantes a dinámicas digitales de aprendizaje, especialmente en contextos virtuales intensivos. La predominancia de estudiantes con altos niveles de interacción digital permitió identificar un entorno propicio para la aparición de fenómenos asociados a fatiga tecnológica, sobrecarga cognitiva y ansiedad académica. Asimismo, la distribución equilibrada entre grupo experimental y grupo de control fortaleció la comparabilidad de los análisis posteriores. El análisis comparativo de los niveles de ansiedad mostró una disminución significativa en el grupo experimental tras la implementación de la plataforma inteligente. La Figura 1 presenta la variación promedio de los niveles de ansiedad académica antes y después de la intervención.




Fig. 1. Variación de los niveles promedio de ansiedad académica antes y después de la intervención.

Los resultados reflejaron que el grupo experimental presentó una reducción considerable de ansiedad académica en comparación con el grupo de control, donde las variaciones fueron mínimas. Esta tendencia sugiere que las estrategias adaptativas implementadas por la plataforma inteligente generaron efectos positivos sobre la regulación emocional de los estudiantes. Las intervenciones automatizadas, particularmente aquellas relacionadas con pausas cognitivas y recomendaciones personalizadas, mostraron una asociación importante con la disminución de síntomas de tensión digital y saturación emocional. El análisis inferencial confirmó diferencias estadísticamente significativas entre ambos grupos. La Tabla 2 resume los resultados de la comparación de medias para las principales variables analizadas durante la intervención.

Tabla 2. Comparación de medias entre grupo experimental y grupo de control.

Variable	Grupo experimental	Grupo control	p-valor
Ansiedad académica	4,9	6,8	0,001
Estrés percibido	4,5	6,4	0,003
Carga cognitiva	5,1	6,7	0,005
Bienestar emocional	7,8	5,9	0,002
Engagement digital	8,1	6,3	0,001

Nota. La tabla presenta la comparación de medias entre el grupo experimental y el grupo de control para las variables principales del estudio.

Los valores obtenidos evidenciaron diferencias significativas en todas las variables analizadas. El grupo experimental mostró menores niveles de ansiedad, estrés y carga cognitiva, mientras que los indicadores de bienestar emocional e interacción académica presentaron incrementos importantes. Estos hallazgos sugieren que la integración de inteligencia artificial adaptativa no solo contribuyó a disminuir factores emocionales negativos, sino que además favoreció una interacción digital más estable y participativa dentro del entorno universitario. Desde el punto de vista computacional, el modelo de inteligencia artificial presentó niveles elevados de precisión predictiva para la identificación de estudiantes con riesgo emocional moderado y alto. La Figura 2 presenta el desempeño predictivo de los modelos de inteligen-

cia artificial implementados para la identificación de niveles de ansiedad académica en estudiantes universitarios digitales.




Fig. 2. Desempeño predictivo de los modelos de inteligencia artificial implementados.

El modelo *Random Forest* alcanzó el mejor desempeño general debido a su capacidad para procesar múltiples variables emocionales y conductuales de forma simultánea. La precisión superior al 90% permitió identificar patrones complejos de ansiedad académica asociados con cambios en los hábitos digitales de los estudiantes. Asimismo, la elevada sensibilidad observada indicó una adecuada capacidad del sistema para detectar estudiantes en condiciones de riesgo emocional, reduciendo la probabilidad de falsos negativos dentro del entorno universitario.

El análisis correlacional reveló asociaciones importantes entre carga cognitiva, frecuencia de interacción digital y niveles de ansiedad académica. Se identificó una correlación positiva moderada-alta entre tiempo excesivo de exposición digital y aumento de síntomas emocionales negativos ($r = 0,71$). Paralelamente, las intervenciones adaptativas generadas por la plataforma mostraron correlaciones negativas con los niveles de ansiedad ($r = -0,68$), lo que sugiere efectos reguladores relevantes derivados de la personalización inteligente del sistema.

A nivel institucional, la plataforma permitió construir patrones agregados de comportamiento emocional capaces de generar alertas tempranas para estudiantes con indicadores persistentes de estrés y desconexión académica. Esta capacidad predictiva representa uno de los principales aportes tecnológicos del estudio, debido a que trasciende los modelos tradicionales de monitoreo académico centrados exclusivamente en calificaciones o asistencia. En contraste, el sistema propuesto incorporó variables emocionales dinámicas y patrones de comportamiento digital que facilitaron una comprensión más integral del bienestar estudiantil en contextos universitarios virtuales.

Finalmente, los resultados demostraron que la incorporación de inteligencia artificial adaptativa puede constituir una estrategia viable para fortalecer ecosistemas educativos digitalmente más humanos, preventivos y emocionalmente sostenibles. Más allá de la automatización tecnológica, la plataforma evidenció potencial para transformar la relación entre universidad, bienestar emocional y aprendizaje digital, integrando procesos de acompañamiento inteligente orientados a reducir la ansiedad académica en contextos universitarios contemporáneos.

La Figura 3 presenta la arquitectura funcional propuesta para la plataforma inteligente orientada a la gestión adaptativa de la ansiedad en entornos universitarios digitales. El sistema integra procesos de captura de datos, análisis emocional, inteligencia artificial y retroalimentación adaptativa orientados al acompañamiento emocional estudiantil.




Fig. 3. Arquitectura funcional de la plataforma inteligente para la gestión adaptativa de la ansiedad en entornos universitarios digitales.

La arquitectura desarrollada evidencia una integración interdisciplinaria entre analítica emocional, aprendizaje automático y sistemas adaptativos de intervención. La incorporación de mecanismos de retroalimentación continua permite que la plataforma responda dinámicamente a variaciones emocionales y conductuales de los estudiantes, favoreciendo procesos de regulación emocional más personalizados dentro de ecosistemas universitarios digitalizados.

A. Modelo matemático de adaptación emocional inteligente

Con el propósito de fortalecer la capacidad predictiva y adaptativa de la plataforma inteligente propuesta, se desarrolló un modelo matemático orientado a representar dinámicamente el comportamiento emocional de los estudiantes dentro de entornos universitarios digitales. El modelo permitió integrar variables emocionales, cognitivas y conductuales mediante un índice adaptativo capaz de identificar niveles de riesgo asociados con ansiedad académica y sobrecarga digital. El sistema se fundamentó en la construcción de un Índice Adaptativo de Ansiedad (IAA), diseñado para cuantificar el estado emocional del estudiante en función de múltiples variables derivadas de la interacción académica digital. La formulación general del modelo se representa mediante la siguiente expresión:

$$IAA(t) = \alpha E(t) + \beta C(t) + \gamma D(t) + \delta R(t) \quad (3)$$

donde: $E(t)$ representa el nivel de estrés emocional detectado en el instante t , $C(t)$ corresponde a la carga cognitiva percibida, $D(t)$ representa la intensidad de interacción digital, $R(t)$ corresponde al rendimiento académico relativo del estudiante, α , β , γ , δ representan coeficientes de ponderación adaptativa asociados a cada variable del modelo.

Los coeficientes de ponderación fueron definidos dinámicamente mediante procesos de calibración computacional y normalización estadística, permitiendo que el sistema ajustara automáticamente la relevancia de cada variable según los patrones emocionales y conductuales identificados durante la interacción del usuario con la plataforma. Para garantizar estabilidad matemática y coherencia interna del modelo, se estableció la siguiente condición de normalización:

$$\alpha + \beta + \gamma + \delta = 1 \quad (4)$$

La implementación del modelo permitió que la plataforma procesara continuamente datos derivados de cuestionarios emocionales, patrones de navegación, frecuencia de conexión, participación académica y comportamiento digital general. Esta integración favoreció la construcción de perfiles emocionales adaptativos capaces de identificar variaciones dinámicas asociadas con estados de ansiedad académica. A partir del valor obtenido para el índice $IAA(t)$, la plataforma ejecutó mecanismos automatizados de intervención adaptativa mediante una función logística orientada a estimar la probabilidad de activación de estrategias de regulación emocional. La función utilizada se expresa de la siguiente manera:

$$I(t) = \frac{1}{1 + e^{-k(IAA(t)-\theta)}} \quad (5)$$

donde: $I(t)$ representa la probabilidad de intervención adaptativa, k corresponde al parámetro de sensibilidad del sistema, θ representa el umbral crítico de ansiedad establecido para activar mecanismos automáticos de apoyo emocional.

El comportamiento dinámico de esta función permitió que la plataforma incrementara progresivamente las intervenciones adaptativas a medida que el índice de ansiedad aumentaba. Entre las acciones automatizadas implementadas se incluyeron recomendaciones personalizadas, pausas cognitivas, mensajes de regulación emocional, reorganización de actividades académicas y generación de alertas institucionales tempranas.

Desde una perspectiva ingenieril, el modelo matemático desarrollado permitió integrar inteligencia artificial, analítica emocional y sistemas adaptativos dentro de una misma arquitectura computacional. Asimismo, la incorporación de funciones dinámicas de intervención favoreció la construcción de un sistema capaz de responder en tiempo real a las variaciones emocionales y conductuales de los estudiantes, fortaleciendo la capacidad preventiva y personalizada de la plataforma inteligente propuesta.

CONCLUSIONES

Los resultados obtenidos permitieron evidenciar que el diseño e implementación de una plataforma basada en inteligencia artificial puede constituir una estrategia viable para la gestión adaptativa de la ansiedad en entornos universitarios digitales. La integración de modelos predictivos, monitoreo emocional automatizado y mecanismos de intervención personalizada favoreció la reducción de niveles de ansiedad académica, estrés percibido y sobrecarga cognitiva en los estudiantes que participaron en la intervención experimental.

El estudio demostró que la incorporación de inteligencia artificial dentro de ecosistemas educativos virtuales puede trascender las funciones tradicionales de automatización académica para asumir un rol más orientado al acompañamiento emocional y al bienestar psicológico estudiantil. En este sentido, la plataforma desarrollada permitió identificar patrones conductuales y emocionales asociados con riesgo adaptativo, facilitando la generación de respuestas dinámicas orientadas a fortalecer la regulación emocional y la interacción académica digital.

Desde el punto de vista computacional, los modelos de aprendizaje automático implementados presentaron niveles elevados de precisión predictiva, destacando especialmente el algoritmo *Random Forest* por su capacidad para clasificar patrones complejos de ansiedad académica. Estos hallazgos evidencian el potencial de los sistemas inteligentes para apoyar procesos preventivos dentro de instituciones universitarias que enfrentan escenarios crecientemente digitalizados y emocionalmente demandantes.

Asimismo, la investigación permitió identificar que las intervenciones adaptativas automatizadas, tales como recomendaciones personalizadas, pausas cognitivas y estrategias digitales de acompañamiento emocional, contribuyeron positivamente a mejorar la percepción de bienestar y *engagement* académico de los estudiantes. Esto sugiere que la personalización emocional mediada por inteligencia artificial puede convertirse en un componente relevante dentro de futuras plataformas educativas inteligentes.

No obstante, el estudio presentó limitaciones relacionadas con el tamaño muestral, el periodo de intervención y la dependencia de variables autorreportadas y patrones digitales específicos de un contexto universitario determinado. Por ello, futuras investigaciones podrían ampliar la validación del sistema mediante estudios longitudinales, integración de inteligencia artificial multimodal y evaluación en diferentes contextos culturales y educativos.

Finalmente, se puede afirmar que el desarrollo de plataformas inteligentes orientadas a la gestión emocional representa una línea emergente con alto potencial para fortalecer universidades digitalmente más humanas, preventivas y sostenibles. La integración de inteligencia artificial y bienestar psicológico estudiantil no solo constituye un avance tecnológico, sino también una oportunidad para replantear el papel de las instituciones educativas frente a los desafíos emocionales de la educación superior contemporánea.

REFERENCIAS

- [1] Q. Zafar, A. Kiren, and Z. Naz, "The role of artificial intelligence in supporting students' emotional regulation and learning anxiety," *The Critical Review of Social Sciences Studies*, vol. 4, no. 1, pp. 589–600, 2026, doi: 10.59075/884gdn98.
- [2] K. P. Das and P. Gavade, "A review on the efficacy of artificial intelligence for managing anxiety disorders," *Frontiers in Artificial Intelligence*, vol. 7, p. 1435895, 2024, doi: 10.3389/frai.2024.1435895.
- [3] A. S. ElBarazi, H. Mohamed, and R. Nasser, "Exploring students' perceptions and usage of artificial intelligence in supporting mental health: A preliminary study in higher education in qatar," *Healthcare*, vol. 14, no. 9, p. 1247, 2026, doi: 10.3390/healthcare14091247.
- [4] Z. Ding and W. Xue, "Navigating anxiety in digital learning: How AI-driven personalization and emotion recognition shape EFL students' engagement," *Acta Psychologica*, vol. 257, p. 105466, 2025, doi: 10.1016/j.actpsy.2025.105466.
- [5] A. Pavlopoulos, T. Rachiotis, and I. Maglogiannis, "An overview of tools and technologies for anxiety and depression management using AI," *Applied Sciences*, vol. 14, no. 19, p. 9068, 2024, doi: 10.3390/app14199068.
- [6] S. Shifa, S. Hameed, H. Suhail, and A. Kiren, "Emotional intelligence meets artificial intelligence: Affective computing and student well-being in online classrooms," *The Critical Review of Social Sciences Studies*, vol. 3, no. 3, pp. 271–289, 2025.
- [7] A. O. R. Vistorte, A. Deroncele-Acosta, J. L. M. Ayala, A. Barrasa, C. López-Granero, and M. Martí-González, "Integrating artificial intelligence to assess emotions in learning environments: a systematic literature review," *Frontiers in Psychology*, vol. 15, p. 1387089, 2024, doi: 10.3389/fpsyg.2024.1387089.
- [8] T. S. Moghadam, A. Darejeh, M. Delaramifar, and S. Mashayekh, "Toward an artificial intelligence-based decision framework for developing adaptive e-learning systems to impact learners' emotions," *Interactive Learning Environments*, vol. 32, no. 7, pp. 3665–3685, 2024.
- [9] F. Altinay, G. Dagli, R. Shadiev, Z. Altinay, İ. Suiçmez, and N. Kerimbayev, "Evaluation of artificial intelligence supporting emotional intelligence of students in the context of sustainable development," *BRAIN. Broad Research in Artificial Intelligence and Neuroscience*, vol. 17, no. 1, pp. 132–144, 2026.
- [10] G. D. la Puente, A. Silva, and R. Felix, "Development of a chatbot powered by artificial intelligence to diagnose and improve stress and anxiety levels in university students," in *2024 IEEE XXXI International Conference on Electronics, Electrical Engineering and Computing (INTERCON)*, 2024, pp. 1–8.
- [11] U. S. Isaiyah, A. T. Naibo, M. T. Ugondo, S. Ogwuche, S. J. Iziengbuwa, E. E. Abiama *et al.*, "The role of AI companions in supporting adaptive emotion regulation among university students with social anxiety," *Discover Mental Health*, vol. 6, p. 53, 2026, doi: 10.1007/s44192-026-00387-7.
- [12] M. M. L. Elkishif, M. Rahmath, S. A. E. Mohamed *et al.*, "The impact of artificial intelligence-based emotional support tools on anxiety and stress levels in high-risk pregnant women," *Scientific Reports*, 2026, doi: 10.1038/s41598-026-49427-w.
- [13] C. Kai, "AI anxiety and adoption intention in higher education based on social and computer anxiety," *Education and Information Technologies*, 2026, available: <https://pmc.ncbi.nlm.nih.gov/articles/PMC12881405/>.
- [14] M. He, "AI-driven language learning in higher education," *Humanities and Social Sciences Communications*, vol. 12, 2025, doi: 10.1057/s41599-025-05817-5.
- [15] L. Siyan, T. Shao, Z. Yu, and J. Hirschberg, "Using adaptive empathetic responses for teaching english," arXiv preprint arXiv:2404.13764, 2024, available: <https://arxiv.org/abs/2404.13764>.

Artículo de investigación

<https://doi.org/10.47460/athenea.v7i24.142>

Modelo de inteligencia artificial para la mitigación del estrés académico en estudiantes de administración

Beth Evelyn Cárdenas Núñez
<https://orcid.org/0000-0003-4949-2117>
beth.cardenas@ucsm.edu.pe
Universidad Católica de Santa María
Arequipa, Perú

María del Carmen Barriga García
<https://orcid.org/0009-0005-1477-1820>
mbarrigag@ucsm.edu.pe
Universidad Católica de Santa María
Arequipa, Perú

Stephanie Delia Rivera Pinto
<https://orcid.org/0009-0000-1059-8171>
srivera@ucsm.edu.pe
Universidad Católica de Santa María
Arequipa, Perú

Alonso Pinto Hurtado
<https://orcid.org/0009-0007-3552-2676>
apinto@ucsm.edu.pe
Universidad Católica de Santa María
Arequipa, Perú

Gonzalo Ernesto Vera Zavala
<https://orcid.org/0009-0000-7951-0991>
gveraz@ucsm.edu.pe
Universidad Católica de Santa María
Arequipa, Perú

*Autor de correspondencia: beth.cardenas@ucsm.edu.pe

Recibido: (02/02/2026), Aceptado: (10/05/2026)

Resumen. El estrés académico constituye uno de los principales problemas emocionales en estudiantes universitarios debido a la creciente presión académica y digital presente en la educación superior contemporánea. La presente investigación tuvo como objetivo desarrollar un modelo de inteligencia artificial para la mitigación del estrés académico en estudiantes de administración mediante técnicas de aprendizaje automático y simulación predictiva. El estudio presentó un enfoque cuantitativo, diseño no experimental y alcance explicativo-predictivo, considerando una muestra de 384 estudiantes universitarios. Se emplearon algoritmos como *Random Forest*, *XGBoost*, *SVM* y redes neuronales multicapa para identificar patrones emocionales y académicos asociados al estrés. Los resultados evidenciaron que *XGBoost* alcanzó el mayor desempeño predictivo y que la intervención inteligente adaptativa permitió reducir progresivamente los niveles de estrés académico. Se concluyó que la inteligencia artificial posee elevado potencial para fortalecer estrategias preventivas y sistemas de apoyo emocional en educación superior.

Palabras clave: inteligencia artificial, estrés académico, aprendizaje automático, educación superior.

Artificial Intelligence Model for Mitigating Academic Stress in Management Students

Abstract. Academic stress constitutes one of the main emotional challenges among university students due to the increasing academic and digital pressure present in contemporary higher education. This study aimed to develop an artificial intelligence model for mitigating academic stress in management students through machine learning techniques and predictive simulation. The study adopted a quantitative approach, a non-experimental design, and an explanatory-predictive scope, considering a sample of 384 university students. Algorithms such as *Random Forest*, *XGBoost*, *SVM*, and multilayer neural networks were used to identify emotional and academic patterns associated with stress. The results showed that *XGBoost* achieved the highest predictive performance and that adaptive intelligent intervention progressively reduced academic stress levels. It is concluded that artificial intelligence has strong potential to strengthen preventive strategies and emotional support systems in higher education.

Keywords: artificial intelligence, academic stress, machine learning, higher education.

I. INTRODUCCIÓN

La transformación digital de la educación superior ha modificado significativamente las dinámicas de aprendizaje, interacción académica y gestión emocional de los estudiantes universitarios. El crecimiento del uso de plataformas digitales y herramientas basadas en inteligencia artificial ha generado nuevos escenarios educativos orientados a la automatización, personalización y análisis de procesos académicos complejos [1], [2]. En este contexto, la inteligencia artificial se ha consolidado como una tecnología estratégica capaz de identificar patrones conductuales y emocionales mediante técnicas avanzadas de aprendizaje automático [3], [4].

Diversas investigaciones han evidenciado que la incorporación intensiva de tecnologías digitales también ha incrementado las exigencias académicas, la sobrecarga cognitiva y los niveles de estrés emocional en estudiantes universitarios [5], [6]. Particularmente, los estudiantes de administración enfrentan elevados niveles de presión académica debido a la competitividad, la carga de actividades y la adaptación constante a entornos digitales [7]. Estas condiciones favorecen síntomas asociados al agotamiento mental, ansiedad académica, procrastinación y deterioro del bienestar psicológico [8], [9].

El estrés académico constituye actualmente uno de los principales problemas psicoeducativos en la educación superior debido a sus efectos negativos sobre la concentración, el rendimiento y la estabilidad emocional [10]. Estudios recientes han demostrado que factores como la calidad del sueño, la ansiedad frente a evaluaciones y la sobreexposición digital mantienen relaciones significativas con el incremento del estrés estudiantil [11], [12]. Sin embargo, la complejidad de estas variables dificulta la identificación temprana de patrones de riesgo mediante métodos tradicionales de análisis [13], [14].

Frente a esta problemática, la inteligencia artificial ha emergido como una alternativa innovadora para el análisis predictivo de fenómenos educativos complejos. Algoritmos como *Random Forest*, *XG-Boost* y redes neuronales multicapa permiten identificar relaciones no lineales y construir modelos predictivos con elevados niveles de precisión [4], [5]. Asimismo, los sistemas inteligentes adaptativos posibilitan generar recomendaciones dinámicas orientadas a mejorar hábitos de estudio, regulación emocional y organización académica [1], [3].

En este sentido, la presente investigación tuvo como objetivo desarrollar un modelo de inteligencia artificial para la mitigación del estrés académico en estudiantes de administración, integrando variables emocionales, académicas y conductuales mediante técnicas avanzadas de aprendizaje automático y simulación predictiva. El estudio buscó identificar patrones de riesgo emocional, comparar el desempeño de distintos algoritmos predictivos y evaluar la capacidad de un sistema inteligente adaptativo para reducir progresivamente los niveles de estrés académico en contextos universitarios.

II. MARCO TEÓRICO

A. Inteligencia artificial y transformación de la educación superior

La inteligencia artificial ha transformado significativamente los entornos educativos contemporáneos mediante el desarrollo de sistemas capaces de procesar grandes volúmenes de información, identificar patrones complejos y generar respuestas adaptativas orientadas a optimizar procesos de aprendizaje [5], [6]. En la educación superior, estas tecnologías han comenzado a desempeñar un papel estratégico debido a su capacidad para automatizar análisis académicos, personalizar experiencias educativas y mejorar la toma de decisiones institucionales basadas en datos [7]. El crecimiento de herramientas inteligentes en contextos universitarios ha favorecido el surgimiento de modelos educativos más dinámicos, interactivos y centrados en las necesidades individuales de los estudiantes.

Diversas investigaciones han señalado que la inteligencia artificial permite analizar variables académicas, emocionales y conductuales de manera simultánea, facilitando la identificación temprana de riesgos asociados al desempeño estudiantil y al bienestar psicológico [1], [3]. Este enfoque resulta especialmente relevante en escenarios universitarios complejos donde los estudiantes enfrentan elevados niveles de presión académica, adaptación tecnológica y sobrecarga cognitiva. En consecuencia, el uso de modelos inteligentes ha comenzado a expandirse hacia áreas vinculadas con la salud mental, la regulación emocional y la prevención del estrés académico.

El desarrollo reciente de algoritmos de aprendizaje automático ha fortalecido la capacidad predictiva

de los sistemas educativos inteligentes. Técnicas como *Random Forest*, *XGBoost* y redes neuronales multicapa permiten construir modelos capaces de identificar relaciones no lineales entre múltiples variables, superando las limitaciones de los enfoques estadísticos tradicionales [4], [5]. Estos algoritmos presentan ventajas importantes en términos de precisión, adaptabilidad y capacidad de generalización, lo que ha impulsado su aplicación en estudios relacionados con comportamiento estudiantil, rendimiento académico y detección de vulnerabilidades emocionales [9].

B. Estrés académico en estudiantes universitarios

El estrés académico constituye una respuesta psicológica y fisiológica generada por las exigencias cognitivas, emocionales y sociales presentes en los entornos educativos [10]. En estudiantes universitarios, este fenómeno se encuentra asociado con múltiples factores, entre ellos la carga académica excesiva, la ansiedad frente a evaluaciones, la presión por el rendimiento, las dificultades de organización del tiempo y la adaptación a dinámicas institucionales altamente demandantes [2], [8].

Diversos estudios han evidenciado que los estudiantes de carreras relacionadas con administración presentan niveles elevados de estrés debido a la combinación de actividades analíticas, presión competitiva y constante exposición a procesos de evaluación [1], [12]. Estas condiciones generan efectos negativos sobre la concentración, la motivación, el bienestar emocional y el desempeño académico, incrementando además la probabilidad de agotamiento mental y deterioro de la salud psicológica.

La calidad del sueño ha sido identificada como uno de los principales factores asociados al incremento del estrés académico. Investigaciones recientes demostraron que la privación del descanso afecta significativamente la capacidad de concentración, la regulación emocional y el procesamiento cognitivo, favoreciendo el desarrollo de síntomas de ansiedad y agotamiento mental [3], [11]. De manera complementaria, el uso excesivo de plataformas digitales y la exposición prolongada a pantallas han comenzado a relacionarse con procesos de fatiga cognitiva y procrastinación académica, especialmente en contextos educativos altamente digitalizados [7].

Asimismo, el estrés académico presenta una naturaleza multidimensional debido a la interacción simultánea de variables emocionales, académicas, conductuales y tecnológicas. Esta complejidad dificulta la detección temprana de estudiantes en situación de riesgo utilizando únicamente métodos convencionales de evaluación psicológica o análisis descriptivos tradicionales [13]. En consecuencia, la incorporación de modelos de inteligencia artificial ha surgido como una alternativa innovadora para abordar este problema desde una perspectiva predictiva y adaptativa.

C. Aprendizaje automático y analítica predictiva en contextos educativos

El aprendizaje automático constituye una rama de la inteligencia artificial orientada al desarrollo de algoritmos capaces de aprender automáticamente a partir de datos y mejorar progresivamente su desempeño predictivo [5]. En el ámbito educativo, estas técnicas han sido utilizadas para analizar grandes conjuntos de información académica, identificar patrones de comportamiento estudiantil y generar modelos de predicción relacionados con rendimiento, deserción, participación y salud emocional [6].

La minería de datos educativos ha permitido fortalecer significativamente los procesos de analítica predictiva en instituciones de educación superior. Mediante la integración de variables académicas, psicológicas y tecnológicas, los sistemas inteligentes pueden construir perfiles estudiantiles complejos y segmentar grupos de riesgo emocional con elevados niveles de precisión [15]. Estas capacidades han favorecido el desarrollo de modelos capaces de anticipar comportamientos asociados al estrés académico antes de que se manifiesten consecuencias severas sobre el rendimiento o el bienestar psicológico.

Entre los algoritmos más utilizados en analítica predictiva educativa destacan *Random Forest* y *XGBoost* debido a su elevada capacidad para procesar relaciones complejas y reducir errores de clasificación [4], [9]. *Random Forest* funciona mediante conjuntos de árboles de decisión que permiten mejorar la estabilidad predictiva y minimizar el sobreajuste, mientras que *XGBoost* optimiza progresivamente el aprendizaje mediante técnicas avanzadas de *boosting* orientadas a maximizar precisión y velocidad computacional [5].

Por otro lado, las redes neuronales multicapa han demostrado gran eficacia en escenarios donde

existen patrones emocionales altamente dinámicos y relaciones no lineales entre variables psicológicas y académicas [6]. Estas arquitecturas computacionales permiten modelar comportamientos complejos mediante múltiples capas de procesamiento, favoreciendo la identificación de estructuras latentes difíciles de detectar mediante modelos lineales convencionales.

D. Modelos inteligentes adaptativos para la mitigación del estrés académico

El desarrollo de sistemas inteligentes adaptativos ha abierto nuevas posibilidades para la intervención personalizada en contextos educativos universitarios. A diferencia de los modelos tradicionales de evaluación psicológica, los sistemas basados en inteligencia artificial poseen la capacidad de ajustar dinámicamente sus recomendaciones según los patrones emocionales y conductuales de cada estudiante [1], [12].

Estos modelos permiten generar estrategias de mitigación orientadas a mejorar hábitos de estudio, organización académica, regulación emocional y equilibrio cognitivo mediante recomendaciones personalizadas sustentadas en datos predictivos [3]. En este contexto, la inteligencia artificial no solo actúa como herramienta de detección temprana, sino también como mecanismo de apoyo preventivo orientado a reducir progresivamente el impacto del estrés académico sobre el bienestar estudiantil. Asimismo, la incorporación de simulaciones predictivas y modelos de comportamiento dinámico permite evaluar distintos escenarios de intervención emocional en estudiantes universitarios. Estas simulaciones facilitan la construcción de estrategias institucionales más eficientes para la prevención de riesgos psicológicos y la promoción de entornos educativos más saludables y adaptativos [11].

Desde esta perspectiva, la integración de inteligencia artificial, analítica predictiva y modelado emocional representa una línea emergente de investigación con elevado potencial para transformar los sistemas contemporáneos de apoyo estudiantil. La capacidad de los algoritmos inteligentes para identificar patrones complejos y generar respuestas adaptativas convierte a estas tecnologías en herramientas estratégicas para la mitigación del estrés académico en escenarios universitarios caracterizados por alta complejidad emocional y tecnológica.

III. METODOLOGÍA

La investigación se desarrolló bajo un enfoque cuantitativo, de tipo aplicado y alcance explicativo-predictivo, orientado al diseño y validación de un modelo de inteligencia artificial para la mitigación del estrés académico en estudiantes de administración. El estudio presentó un diseño no experimental, transversal y correlacional multivariado, incorporando técnicas de analítica predictiva y aprendizaje automático. Por otra parte, la población estuvo conformada por estudiantes universitarios de la carrera de administración pertenecientes a distintos niveles académicos. La muestra estuvo integrada por 384 estudiantes, seleccionados mediante muestreo probabilístico estratificado según semestre académico y modalidad de estudio.

Para esta investigación se consideraron variables académicas, emocionales y tecnológicas asociadas al estrés estudiantil, entre ellas calidad del sueño, carga académica percibida, ansiedad frente a evaluaciones, tiempo de exposición digital, organización académica y apoyo docente. El nivel de estrés académico fue evaluado mediante una adaptación del Inventario SISCO SV-21. La recolección de datos se realizó mediante encuestas digitales aplicadas a los estudiantes participantes. Posteriormente, se desarrolló un proceso de preprocesamiento que incluyó limpieza de datos, normalización de variables y normalización y optimización de variables para mejorar el desempeño predictivo del modelo.

Para la construcción del modelo predictivo se emplearon algoritmos de aprendizaje supervisado, incluyendo *Random Forest*, *XGBoost*, *Support Vector Machine* (SVM), redes neuronales multicapa (MLP) y regresión logística. El entrenamiento se efectuó utilizando validación cruzada *k-fold* ($k = 10$), distribuyendo los datos en conjuntos de entrenamiento (70%), validación (15%) y prueba (15%). El desempeño de los algoritmos fue evaluado mediante métricas como *accuracy*, *precision*, *recall*, *F1-score* y curva ROC-AUC. Asimismo, se incorporó un sistema inteligente adaptativo orientado a generar recomendaciones para la mitigación del estrés académico mediante simulaciones predictivas.

Finalmente, se aplicaron análisis descriptivos y correlacionales orientados a identificar patrones emocionales y académicos asociados al estrés estudiantil, permitiendo evaluar la capacidad predictiva y funcional del modelo de inteligencia artificial en contextos universitarios.

IV. RESULTADOS

La caracterización de la muestra evidenció una predominancia de estudiantes del sexo femenino y una mayor concentración de participantes entre los 21 y 23 años, correspondientes principalmente a semestres intermedios de la carrera de administración. Asimismo, se observó que más de la mitad de los estudiantes dedicaban entre dos y cuatro horas diarias al estudio, mientras que una proporción considerable reportó niveles moderados y bajos de calidad del sueño.

En relación con el uso de plataformas digitales, los resultados mostraron una elevada exposición tecnológica, debido a que más del 77% de los estudiantes utilizaban herramientas académicas digitales durante más de cuatro horas al día. Respecto al estrés académico, predominó el nivel moderado; sin embargo, cerca del 35% de los participantes presentó niveles altos o severos, lo cual evidenció la existencia de condiciones emocionales relevantes que justificaron la implementación del modelo predictivo basado en inteligencia artificial.

Tabla 1. Características sociodemográficas y académicas de la muestra.

Variable	Categoría	Frecuencia (n)	Porcentaje (%)
Sexo	Masculino	172	44,8
	Femenino	212	55,2
Edad	18–20 años	96	25,0
	21–23 años	168	43,8
	24–26 años	82	21,4
	Más de 26 años	38	9,8
Semestre académico	Inicial (1.º–3.º)	121	31,5
	Intermedio (4.º–6.º)	156	40,6
	Avanzado (7.º–10.º)	107	27,9
Horas de estudio diarias	Menos de 2 horas	74	19,3
	2–4 horas	194	50,5
	Más de 4 horas	116	30,2
Calidad del sueño	Baja	143	37,2
	Moderada	171	44,5
	Alta	70	18,3
Uso diario de plataformas digitales	1–3 horas	88	22,9
	4–6 horas	179	46,6
	Más de 6 horas	117	30,5
Nivel inicial de estrés académico	Bajo	69	18,0
	Moderado	181	47,1
	Alto	107	27,9
	Severo	27	7,0

Nota. La tabla presenta la distribución sociodemográfica y académica de la muestra analizada.

Por otra parte, la distribución del estrés académico mostró una concentración predominante en los niveles moderado y alto, lo que sugirió la existencia de una presión académica sostenida dentro del entorno universitario analizado. El nivel moderado representó casi la mitad de la muestra, mientras que más de una cuarta parte de los estudiantes manifestó niveles altos de estrés, asociados principalmente con sobrecarga de actividades, presión evaluativa y dificultades en la organización del tiempo.

De manera complementaria, aunque el porcentaje de estudiantes con estrés severo fue menor, su presencia resultó significativa debido al potencial impacto sobre el rendimiento académico, la estabilidad emocional y la adaptación universitaria. Estos hallazgos evidenciaron la necesidad de desarrollar mecanismos inteligentes de detección temprana y estrategias adaptativas orientadas a la mitigación del estrés académico mediante modelos basados en inteligencia artificial.




Fig. 1. Distribución del nivel de estrés académico en estudiantes de administración.

El análisis de importancia de variables (Tabla 2) evidenció que la calidad del sueño constituyó el principal factor predictivo asociado al estrés académico, alcanzando el mayor peso dentro del modelo de inteligencia artificial. Este resultado sugirió que las alteraciones en los patrones de descanso presentaron una relación directa con el incremento de síntomas de agotamiento emocional, disminución de concentración y vulnerabilidad psicológica en estudiantes universitarios.

Además, la ansiedad frente a evaluaciones y la carga académica percibida mostraron niveles predictivos elevados, consolidándose como factores críticos dentro de la dinámica del estrés estudiantil. Asimismo, variables relacionadas con hábitos digitales y organización del tiempo presentaron una influencia considerable en el desempeño del modelo, lo que evidenció la interacción compleja entre componentes emocionales, académicos y tecnológicos.

En contraste, factores como el apoyo docente y la interacción social universitaria registraron niveles moderados de influencia predictiva, aunque mantuvieron relevancia dentro de la estructura multivariable del sistema inteligente. Estos hallazgos permitieron identificar patrones prioritarios para el diseño de estrategias adaptativas de mitigación del estrés académico.

Tabla 2. Importancia de variables predictoras en el modelo de inteligencia artificial.

Variable predictora	Peso predictivo	Nivel de importancia	Ranking
Calidad del sueño	0,91	Muy alto	1
Ansiedad frente a evaluaciones	0,88	Muy alto	2
Carga académica percibida	0,84	Muy alto	3
Organización del tiempo	0,79	Alto	4
Tiempo de exposición a pantallas	0,74	Alto	5
Agotamiento mental	0,71	Alto	6
Frecuencia de pausas cognitivas	0,66	Moderado	7
Apoyo docente percibido	0,61	Moderado	8
Interacción social universitaria	0,57	Moderado	9
Horas de estudio diarias	0,52	Moderado	10

Nota. La tabla presenta el peso predictivo de las variables incluidas en el modelo de inteligencia artificial.

El mapa de calor (Tabla 3) evidenció la existencia de relaciones significativas entre las variables emocionales, académicas y conductuales analizadas. Las correlaciones más elevadas se observaron entre estrés académico y ansiedad frente a evaluaciones, así como entre estrés y agotamiento mental, lo que confirmó la interacción directa entre presión académica y desgaste psicológico en estudiantes universitarios.

Asimismo, se identificó una fuerte correlación negativa entre calidad del sueño y niveles de estrés, indicando que la disminución del descanso se asoció con un incremento considerable de síntomas

emocionales adversos. De forma similar, el rendimiento académico y la capacidad de concentración presentaron relaciones inversamente proporcionales con el estrés y la procrastinación, evidenciando el impacto funcional de las alteraciones emocionales sobre el desempeño estudiantil.

Otro hallazgo relevante correspondió a la relación positiva entre tiempo de exposición digital y procrastinación académica, sugiriendo que el uso excesivo de plataformas digitales podría actuar como factor amplificador del agotamiento cognitivo y de la dificultad para gestionar adecuadamente las actividades universitarias. En conjunto, estos resultados respaldaron la pertinencia del modelo de inteligencia artificial para detectar patrones complejos de interacción asociados al estrés académico.

Tabla 3. Mapa de calor de correlaciones entre variables académicas y emocionales.

Variables	Estrés	Sueño	Ansiedad	Rendimiento	Agotamiento	Concentración	Procrastinación	Tiempo digital
Estrés	1	-0,82	0,87	-0,71	0,84	-0,73	0,76	0,69
Sueño	-0,82	1	-0,68	0,66	-0,72	0,63	-0,58	-0,51
Ansiedad	0,87	-0,68	1	-0,62	0,81	-0,66	0,73	0,59
Rendimiento	-0,71	0,66	-0,62	1	-0,64	0,78	-0,55	-0,43
Agotamiento	0,84	-0,72	0,81	-0,64	1	-0,69	0,74	0,61
Concentración	-0,73	0,63	-0,66	0,78	-0,69	1	-0,57	-0,46
Procrastinación	0,76	-0,58	0,73	-0,55	0,74	-0,57	1	0,65
Tiempo digital	0,69	-0,51	0,59	-0,43	0,61	-0,46	0,65	1

Nota. Los valores corresponden a coeficientes de correlación entre variables académicas, emocionales y conductuales.

Los resultados del análisis comparativo (Tabla 4) evidenciaron diferencias significativas en el desempeño predictivo de los algoritmos de inteligencia artificial utilizados para la identificación de niveles de estrés académico. El modelo *XGBoost* alcanzó el mayor rendimiento global, registrando valores superiores en *accuracy*, precisión, *F1-score* y área bajo la curva ROC, lo que indicó una elevada capacidad para clasificar correctamente los niveles de estrés en estudiantes universitarios.

Por otro lado, los modelos basados en *Random Forest* y redes neuronales multicapa también presentaron desempeños robustos, con métricas superiores al 89% en la mayoría de los indicadores evaluados. Estos resultados sugirieron que los algoritmos basados en aprendizaje *ensemble* y arquitecturas neuronales lograron captar relaciones complejas y patrones no lineales entre variables académicas, emocionales y conductuales.

En Cambio, la regresión logística presentó el menor desempeño predictivo, evidenciando limitaciones para modelar dinámicas multidimensionales asociadas al estrés académico. Este comportamiento confirmó la necesidad de emplear modelos de inteligencia artificial más avanzados en escenarios educativos caracterizados por alta complejidad emocional y variabilidad conductual.

Tabla 4. Desempeño comparativo de algoritmos de inteligencia artificial para la predicción del estrés académico.

Algoritmo	Accuracy	Precision	Recall	F1-score	ROC-AUC
<i>Random Forest</i>	0,89	0,88	0,87	0,88	0,92
<i>XGBoost</i>	0,93	0,92	0,91	0,92	0,96
SVM	0,86	0,84	0,83	0,84	0,89
MLP	0,90	0,89	0,88	0,89	0,93
Regresión logística	0,81	0,80	0,78	0,79	0,84

Nota. La tabla compara las métricas de desempeño predictivo de los algoritmos empleados.

La curva ROC (Tabla 4) comparativa evidenció que el modelo *XGBoost* presentó la mayor capacidad discriminativa para la predicción de niveles de estrés académico, alcanzando un área bajo la curva de 0,96. Este resultado indicó un desempeño predictivo sobresaliente y una elevada capacidad del algoritmo para diferenciar correctamente estudiantes con distintos niveles de riesgo emocional. Asimismo, los modelos MLP y *Random Forest* mostraron desempeños altamente competitivos, manteniendo valores de ROC-AUC superiores a 0,90, lo que confirmó la eficacia de los enfoques basados en aprendizaje profundo y árboles de decisión *ensemble* para el análisis de variables académicas complejas.

Por otro lado, aunque el modelo de regresión logística presentó un comportamiento aceptable, su capacidad discriminativa resultó inferior respecto a los algoritmos avanzados de inteligencia artificial, evidenciando limitaciones para capturar relaciones no lineales y patrones multidimensionales presentes en el comportamiento estudiantil. En términos generales, los resultados confirmaron que los modelos de aprendizaje automático avanzados ofrecieron una mayor precisión para la detección temprana del estrés académico, fortaleciendo el potencial de la inteligencia artificial como herramienta de apoyo en contextos universitarios.




Fig. 2. Curvas ROC comparativas de los modelos de inteligencia artificial empleados para la predicción del estrés académico.

El análisis de agrupamiento realizado mediante algoritmos de inteligencia artificial permitió identificar cuatro perfiles diferenciados de estudiantes según sus patrones emocionales, académicos y conductuales asociados al estrés académico (Tabla 5). El clúster predominante correspondió al grupo de estrés moderado adaptativo, caracterizado por estudiantes que, pese a experimentar presión académica, mantuvieron niveles funcionales de organización y rendimiento.

Se observa también que, cerca de un tercio de la muestra, fue clasificada dentro del clúster de alto estrés y privación de sueño, evidenciando una interacción significativa entre agotamiento mental, ansiedad evaluativa y deterioro del descanso. Este grupo presentó mayores probabilidades de desarrollar síntomas emocionales persistentes y disminución del desempeño académico.

Asimismo, se identificó un clúster de riesgo emocional severo compuesto por estudiantes con elevados niveles de procrastinación, agotamiento cognitivo y bajo apoyo social universitario. Aunque este grupo representó la menor proporción de participantes, constituyó el segmento de mayor vulnerabilidad emocional dentro del modelo predictivo.

Finalmente, el clúster resiliente mostró patrones de regulación académica y emocional significativamente más estables, caracterizados por hábitos organizacionales adecuados y menor afectación psicológica frente a la carga universitaria. Estos hallazgos permitieron demostrar la capacidad del modelo de inteligencia artificial para segmentar perfiles estudiantiles complejos y detectar grupos prioritarios para intervenciones adaptativas.

Tabla 5. Clústeres de estudiantes según patrones de estrés académico identificados mediante inteligencia artificial.

Clúster	Características predominantes	Nivel de estrés	Porcentaje (%)
Clúster 1. Alto estrés y privación de sueño	Baja calidad del sueño, elevada ansiedad evaluativa, agotamiento mental y sobrecarga académica	Alto	29,4
Clúster 2. Estrés moderado adaptativo	Estrés funcional, organización académica moderada y adecuado rendimiento	Moderado	38,7
Clúster 3. Riesgo emocional severo	Elevada procrastinación, agotamiento cognitivo, bajo apoyo social y bajo rendimiento académico	Severo	12,8
Clúster 4. Perfil resiliente	Alta organización del tiempo, descanso adecuado y bajo impacto emocional	Bajo	19,1

Nota. La tabla presenta los perfiles estudiantiles identificados mediante el análisis de agrupamiento.

La simulación predictiva (Figura 3) evidenció diferencias significativas entre los escenarios evaluados para la mitigación del estrés académico. El escenario sin intervención mostró un incremento progresivo de los niveles de estrés a lo largo del periodo analizado, sugiriendo una acumulación sostenida de presión académica y agotamiento emocional en ausencia de estrategias de apoyo.

En contraste, la intervención básica produjo una reducción moderada de los índices de estrés, evidenciando efectos positivos asociados a recomendaciones generales de organización académica y regulación emocional. Sin embargo, el descenso observado fue considerablemente menor en comparación con el modelo inteligente adaptativo.

Por otro lado, el sistema basado en inteligencia artificial presentó la mayor capacidad de mitigación, mostrando una reducción acelerada y sostenida del estrés académico desde las primeras semanas de intervención. Este comportamiento evidenció la eficacia potencial de los modelos adaptativos personalizados para identificar patrones emocionales y generar recomendaciones dinámicas ajustadas a las necesidades específicas de cada estudiante. En términos generales, los resultados respaldaron la aplicabilidad de la inteligencia artificial como herramienta estratégica para la detección temprana y mitigación del estrés académico en contextos universitarios complejos.




Fig. 3. Simulación predictiva de reducción del estrés académico mediante intervención inteligente.

CONCLUSIONES

La investigación evidenció que la inteligencia artificial posee una elevada capacidad para identificar patrones asociados al estrés académico en estudiantes universitarios de administración, integrando variables emocionales, académicas y conductuales mediante modelos predictivos avanzados. Los resultados demostraron que factores como la calidad del sueño, la ansiedad frente a evaluaciones y la carga académica percibida mantuvieron una influencia significativa sobre los niveles de estrés estudiantil, confirmando la naturaleza multidimensional de este fenómeno en contextos de educación superior.

Asimismo, el análisis comparativo de algoritmos permitió determinar que los modelos basados en aprendizaje *ensemble* y aprendizaje profundo, particularmente *XGBoost* y redes neuronales multicapa, alcanzaron mayores niveles de precisión predictiva en comparación con enfoques tradicionales. Estos hallazgos evidenciaron el potencial de la inteligencia artificial para fortalecer procesos de detección temprana de riesgo emocional y mejorar el análisis de dinámicas académicas complejas en entornos universitarios digitalizados.

De manera complementaria, la segmentación de perfiles estudiantiles mediante técnicas de agrupamiento permitió identificar distintos niveles de vulnerabilidad emocional, diferenciando grupos caracterizados por agotamiento mental, privación del sueño y procrastinación académica. Esta capacidad de clasificación favorece el diseño de estrategias institucionales más focalizadas y adaptativas para el acompañamiento estudiantil.

Finalmente, la simulación predictiva mostró que las intervenciones inteligentes adaptativas podrían contribuir progresivamente a la reducción de los niveles de estrés académico, superando los efectos obtenidos mediante estrategias convencionales de apoyo. En este sentido, la investigación permitió evidenciar que la integración de inteligencia artificial y analítica predictiva representa una alternativa prometedora para el desarrollo de sistemas universitarios orientados a la prevención, monitoreo y mitigación del estrés académico en escenarios educativos contemporáneos.

REFERENCIAS

- [1] Y. Wang and S. Xu, "Relationship between artificial intelligence tool usage experience and academic stress among college students: Mediating role of loneliness and moderating role of academic self-efficacy," *Acta Psychologica*, vol. 245, p. 106220, 2026, doi: 10.1016/j.actpsy.2026.106220.
- [2] E. Zaid, J. Qaddumi, H. Sabbagh, and F. Esleem, "The association of artificial intelligence use on academic stress and academic achievement among nursing students in palestine," *BMC Nursing*, vol. 25, no. 1, 2026, doi: 10.1186/s12912-026-04666-0.
- [3] Z. Hamd *et al.*, "Utilizing artificial intelligence to assess academic exam anxiety, perceived stress, and achievement motivation," *Frontiers in Psychiatry*, vol. 17, 2026, doi: 10.3389/fpsy.2026.1686106.
- [4] A. Singh, K. Singh, A. Kumar, A. Shrivastava, and S. Kumar, "Machine learning algorithms for detecting mental stress in college students," arXiv preprint arXiv:2412.07415, 2024, doi: 10.48550/arXiv.2412.07415.
- [5] C. Janiesch, P. Zschech, and K. Heinrich, "Machine learning and deep learning," *Electronic Markets*, vol. 31, no. 3, pp. 685–695, 2021, doi: 10.1007/s12525-021-00475-2.
- [6] T. Baltrušaitis, C. Ahuja, and L.-P. Morency, "Multimodal machine learning: A survey and taxonomy," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 41, no. 2, pp. 423–443, 2019, doi: 10.1109/TPAMI.2018.2798607.
- [7] A. M. Vieriu, "The impact of artificial intelligence on students' learning processes and academic performance," *Education Sciences*, vol. 15, no. 3, p. 343, 2025, doi: 10.3390/educsci15030343.
- [8] S. Sayici, "Balancing usefulness, stress, and cognitive load: Artificial intelligence tools in higher education," Master's thesis, Tilburg University, Netherlands, 2025, available: <https://arno.uvt.nl/show.cgi?fid=185574>.
- [9] R. Tariq *et al.*, "Explainable artificial intelligence for predictive modeling of student stress," *Scientific Reports*, vol. 15, 2025, doi: 10.1038/s41598-025-22171-3.

- [10] D. Wang *et al.*, "The roles of academic procrastination and help-seeking behavior in AI-supported educational environments," *Frontiers in Psychology*, vol. 17, 2026, doi: 10.3389/fpsyg.2026.1578452.
- [11] S. Hossain, "Using artificial intelligence to improve classroom learning experience," arXiv preprint arXiv:2503.05709, 2025, doi: 10.48550/arXiv.2503.05709.
- [12] B. Klimova *et al.*, "Exploring the effects of artificial intelligence on student well-being, mental health, and academic engagement," *Frontiers in Education*, vol. 10, 2025, doi: 10.3389/fe-duc.2025.1456721.
- [13] V. Chandola, A. Banerjee, and V. Kumar, "Anomaly detection: A survey," *ACM Computing Surveys*, vol. 41, no. 3, pp. 1–58, 2009, doi: 10.1145/1541880.1541882.
- [14] I. T. Jolliffe, *Principal Component Analysis*, 2nd ed. New York, NY, USA: Springer, 2002, doi: 10.1007/b98835.
- [15] J. Han, M. Kamber, and J. Pei, *Data Mining: Concepts and Techniques*, 3rd ed. Waltham, MA, USA: Morgan Kaufmann, 2011, doi: 10.1016/C2009-0-61819-5.

Artículo de investigación

<https://doi.org/10.47460/athenea.v7i24.143>

Protocolos de laboratorio generados por inteligencia artificial para la enseñanza de la química: seguridad, valor didáctico y química verde

Wilian Bravo*

<https://orcid.org/0000-0002-2599-6532>
wilian.bravo@espoch.edu.ec
Escuela Superior Politécnica de Chimborazo
Riobamba, Ecuador

Graciela Guerrero Morocho

<https://orcid.org/0000-0002-4411-7513>
hilda.guerrero@unach.edu.ec
Universidad Nacional de Chimborazo
Riobamba, Ecuador

Ana María Castillo Reinoso

<https://orcid.org/0000-0002-5433-7819>
ana.castillo@espoch.edu.ec
Escuela Superior Politécnica de Chimborazo
Riobamba, Ecuador

María Eugenia Ramos Flores

<https://orcid.org/0009-0004-7985-6019>
mariaeugeniaramosflores@gmail.com
Unidad Educativa Nela Martínez Espinosa
La Troncal, Ecuador

*Autor de correspondencia: wilian.bravo@espoch.edu.ec

Recibido: (02/02/2026), Aceptado: (10/05/2026)

Resumen. En esta investigación se analizaron protocolos de laboratorio generados por inteligencia artificial para la enseñanza de la química, con el propósito de comparar su seguridad, valor didáctico y correspondencia con criterios de química verde. Se desarrolló un estudio de enfoque mixto, carácter exploratorio y alcance comparativo, basado en la generación de un corpus documental sobre temas introductorios de química mediante distintos sistemas de inteligencia artificial y diferentes *prompts*, posteriormente evaluados con una rúbrica analítica y una revisión complementaria de métricas formales de seguridad y química verde. Los hallazgos mostraron que el desempeño de los modelos dependió tanto del sistema utilizado como del tipo de *prompt*, aunque el efecto de la instrucción tuvo mayor influencia en la calidad final de los textos. En conjunto, los protocolos presentaron mejor desempeño en valor didáctico que en seguridad y química verde, por lo que su uso requiere validación experta previa en contextos formativos.

Palabras clave: inteligencia artificial, enseñanza de la química, protocolos de laboratorio, seguridad experimental.

Artificial Intelligence-Generated Laboratory Protocols for Chemistry Education: Safety, Didactic Value, and Green Chemistry

Abstract. This study analyzed laboratory protocols generated by artificial intelligence for chemistry teaching in order to compare their safety, didactic value, and alignment with green chemistry criteria. A cross-sectional analytical-descriptive study with comparative scope was conducted based on the generation of a documentary corpus of 54 protocols from six introductory chemistry topics, three *prompts*, and three artificial intelligence systems. The generated texts were evaluated through a rubric structured around three dimensions and were additionally reexamined using formal green chemistry and safety metrics. The findings showed that model performance depended on both the artificial intelligence system and the type of *prompt* used, although the *prompt* effect was stronger. Overall, the protocols performed better in didactic value than in safety and green chemistry. It is concluded that the usefulness of artificial intelligence for laboratory protocol generation depends not only on the model employed, but also on *prompt* orientation and on expert validation before implementation in educational contexts.

Keywords: artificial intelligence, chemistry teaching, laboratory protocols, experimental safety.

I. INTRODUCCIÓN

La incorporación de la inteligencia artificial generativa en educación ha ampliado las posibilidades de producción de materiales de apoyo, diseño de actividades y planificación de clases [1]. Sin embargo, también ha intensificado las dudas sobre la calidad conceptual, la pertinencia pedagógica y la confiabilidad de los contenidos producidos automáticamente. En la enseñanza de la química, esta discusión resulta particularmente relevante, ya que la disciplina exige no solo precisión conceptual, sino también coherencia procedimental, responsabilidad experimental y atención explícita a la seguridad y a la sostenibilidad del trabajo de laboratorio. En este contexto, estudios recientes han mostrado que sistemas de IA generativa y asistentes conversacionales como *ChatGPT*, *Gemini* y *Claude* pueden utilizarse para generar actividades de laboratorio y apoyar la planificación didáctica en química, aunque sus resultados dependen de la calidad de las consignas empleadas y, sobre todo, de la revisión crítica previa a su implementación [2], [3].

En este estudio se buscó determinar en qué medida los protocolos de laboratorio generados por distintos sistemas de inteligencia artificial generativa, pese a su apariencia estructurada y a su lenguaje técnicamente aceptable, cumplían condiciones mínimas de seguridad, valor didáctico y coherencia con criterios de química verde. En el laboratorio, estas instrucciones no se limitan a enumerar pasos, sino que orientan la articulación entre teoría y práctica, regulan el manejo de sustancias, condicionan la comprensión conceptual y pueden incrementar o reducir riesgos durante la actividad experimental. Por ello, la evaluación de estos procedimientos producidos por inteligencia artificial exige parámetros más rigurosos que la mera corrección formal del texto [4], [5].

La pertinencia de esta investigación también se apoya en antecedentes que subrayan la necesidad de integrar seguridad y sostenibilidad en el diseño experimental. En el ámbito latinoamericano, se ha propuesto una métrica integral para evaluar experimentos de laboratorio considerando de forma simultánea el tratamiento y la disposición de residuos, los riesgos para la salud, el ambiente y la seguridad, lo que evidencia que estos elementos deben analizarse de forma articulada [6]. De manera complementaria, los 12 principios de la química verde constituyen un marco consolidado para orientar prácticas hacia la prevención de residuos, la reducción de peligrosidad y el uso más responsable de materiales y procesos [7], [8]. En consecuencia, si un protocolo ha sido generado por inteligencia artificial con fines educativos, su evaluación debe incluir necesariamente estas dimensiones.

A partir de este panorama, se advierte una debilidad analítica en la literatura revisada: aunque existen estudios sobre el uso de asistentes conversacionales para generar actividades de laboratorio y trabajos sobre interacción docente con IA en planificación didáctica, sigue siendo limitada la evidencia comparativa centrada en protocolos de laboratorio generados por diferentes sistemas de IA y bajo distintos tipos de *prompt*, analizados de manera integrada desde criterios de seguridad, valor didáctico y química verde [3], [9]. En respuesta a ello, el objetivo de este estudio fue comparar protocolos de laboratorio generados por tres sistemas de inteligencia artificial generativa y tres *prompts* funcionalmente diferenciados, considerando su seguridad, su valor didáctico y su alineación con criterios de química verde. El aporte del trabajo radica en ofrecer una valoración comparativa de estos productos textuales como recursos potenciales para la docencia, así como en proponer una base metodológica para discutir de manera más crítica el papel del modelo y del *prompt* en la calidad de materiales experimentales generados por IA.

El artículo se organiza en cinco apartados. Luego de esta introducción, se presentan los fundamentos teóricos que sustentan la relación entre inteligencia artificial generativa, enseñanza de la química, seguridad experimental y química verde. Después se describe la metodología empleada para generar y evaluar los protocolos con tres sistemas de IA y tres *prompts*. Posteriormente, se exponen los resultados y su discusión integrada. Finalmente, se presentan las conclusiones derivadas del estudio.

II. MARCO TEÓRICO

A. IA generativa y asistentes conversacionales en enseñanza de la química

La incorporación de sistemas de inteligencia artificial generativa y asistentes conversacionales como *ChatGPT*, *Gemini* y *Claude* en la enseñanza de la química se inscribe en un proceso más amplio de adopción de herramientas capaces de apoyar tareas de explicación, planificación y producción de recursos didácticos. No obstante, en esta disciplina su utilización requiere especial cautela, debido a que

la química exige corrección conceptual, precisión terminológica, coherencia procedimental y correspondencia entre representación simbólica, interpretación teórica y acción experimental. En este sentido, la literatura reciente ha mostrado que estos sistemas pueden contribuir a la generación de actividades de laboratorio y al diseño inicial de materiales educativos, aunque sus respuestas no deben asumirse automáticamente como válidas o listas para su aplicación, pues su calidad depende tanto de las características del modelo como de la formulación del *prompt* y de la validación posterior realizada por un usuario con conocimiento disciplinar y pedagógico [3], [10], [11]. Por ello, la evaluación de materiales generados automáticamente requiere atender no solo al sistema utilizado, sino también al tipo de encuadre textual que orienta la producción de la respuesta.

B. Protocolo de laboratorio como recurso didáctico y de seguridad

En la enseñanza de la química, el protocolo de laboratorio constituye un recurso pedagógico de alta relevancia, ya que organiza el desarrollo de la actividad experimental, orienta la observación de fenómenos, articula teoría y práctica, y delimita condiciones de ejecución. Por consiguiente, su calidad no depende solo de que los pasos estén enumerados correctamente, sino de que el documento exprese con claridad el propósito de la práctica, la lógica del procedimiento, el fundamento químico involucrado y las condiciones necesarias para una ejecución segura. Cuando estas exigencias no se cumplen, el protocolo puede debilitar el aprendizaje esperado y, en el peor de los casos, propiciar errores operativos o interpretaciones inadecuadas del fenómeno químico. Bajo esta lógica, evaluar protocolos generados por inteligencia artificial exige analizar simultáneamente su utilidad didáctica y su consistencia técnica [3], [9].

En el caso del laboratorio, la seguridad constituye una dimensión inseparable del valor educativo del protocolo. No se trata de un componente adicional o meramente administrativo, sino de una condición básica de pertinencia experimental. En esta línea, Vargas-Rodríguez et al. [6] propusieron una métrica integral para evaluar experimentos a partir de diagramas de flujo, integrando tratamiento y disposición de residuos, así como riesgos para la salud, el ambiente y la seguridad. Este planteamiento resulta particularmente útil para este estudio, ya que permite sostener que un protocolo experimental solo puede considerarse adecuado cuando contempla, de forma articulada, advertencias sobre peligros, manejo responsable de sustancias y criterios explícitos de seguridad ecológica. En consecuencia, cualquier protocolo generado por IA para fines educativos debe ser examinado también desde esta perspectiva integral.

Asimismo, la valoración de la seguridad experimental se fortaleció mediante la consideración de referentes formales de laboratorio académico y comunicación de peligros. En particular, se tomaron como base las orientaciones de seguridad académica promovidas por la *American Chemical Society*, el estándar OSHA para exposición ocupacional a químicos peligrosos en laboratorios no productivos, incluido su enfoque de comunicación de peligros en consonancia con el sistema GHS. Esta integración permitió examinar los protocolos no solo desde una perspectiva pedagógica general, sino también desde criterios más explícitos de identificación de riesgos, protección, coherencia operativa y manejo de incidentes [12], [13], [14].

C. Química verde como criterio para la valoración de prácticas educativas

La química verde aporta un marco conceptual especialmente pertinente para valorar prácticas de laboratorio en el ámbito educativo, porque desplaza la atención desde la simple ejecución técnica hacia el diseño de procedimientos con menor peligrosidad, menor generación de residuos y mayor responsabilidad ambiental. Sus principios, difundidos por la *American Chemical Society* y sistematizados también por la *U.S. Environmental Protection Agency*, ofrecen criterios concretos para analizar la sostenibilidad de una práctica experimental y promover una formación química más coherente con los desafíos ambientales contemporáneos [7], [8].

En el terreno educativo, incorporar la química verde a la valoración de protocolos significa preguntarse si la práctica propuesta minimiza riesgos innecesarios, si reduce el volumen o peligrosidad de los residuos, si utiliza cantidades razonables de reactivos y si incorpora orientaciones explícitas sobre disposición final. Este enfoque resulta especialmente relevante cuando los protocolos son generados por inteligencia artificial, dado que un texto formalmente correcto puede seguir siendo inadecuado desde el punto de vista ambiental o de seguridad. Por ello, la química verde no solo funciona en este estudio

como un complemento temático, sino como un criterio de evaluación que permite ampliar la noción de calidad del protocolo y vincular la innovación tecnológica con una enseñanza experimental más segura, reflexiva y sostenible. Esta relación se vuelve más actual si se considera que ya existen propuestas recientes que integran *chatbots* de IA con principios de química verde en actividades de laboratorio de química [15].

Desde una perspectiva operativa, la química verde puede trasladarse al análisis de protocolos educativos mediante criterios verificables asociados a la prevención de residuos, la reducción de peligrosidad de reactivos y materiales, la gestión responsable de desechos y la racionalidad en el uso de recursos. Estos ejes derivan de los principios de química verde difundidos por la *American Chemical Society*, particularmente aquellos vinculados con la prevención, el diseño de procesos más seguros y la eficiencia material y energética. Por ello, en el presente estudio la dimensión de química verde no se asumió como una referencia abstracta, sino como un conjunto de métricas concretas aplicables a la evaluación de protocolos de laboratorio generados por inteligencia artificial.

III. METODOLOGÍA

La investigación se concibió como un estudio exploratorio, documental y comparativo de corte transversal, con enfoque mixto de alcance analítico-descriptivo. La unidad de análisis estuvo constituida por cada protocolo de laboratorio generado por inteligencia artificial, considerado como un texto independiente susceptible de valoración en términos de seguridad, valor didáctico y química verde.

El corpus quedó integrado por 54 protocolos elaborados en español a partir de seis temas de química introductoria: preparación de soluciones, diluciones seriadas, determinación de pH con indicadores, neutralización ácido-base, titulación ácido-base y reacción redox sencilla. Estos temas se seleccionaron por su centralidad curricular en cursos introductorios, su factibilidad en un laboratorio docente básico y su pertinencia para valorar simultáneamente seguridad, valor didáctico y química verde. En todos los casos se trabajó con el nivel de estudiantes de primer semestre de educación superior, con el fin de mantener homogeneidad en la complejidad conceptual y procedimental de las prácticas solicitadas.

La generación de los protocolos se efectuó mediante tres sistemas de inteligencia artificial generativa: *ChatGPT*, *Google Gemini* y *Claude*. En el caso de *ChatGPT* se utilizó el modelo GPT-5.4 Thinking, accedido mediante modalidad Plus; en *Google Gemini* se empleó la suscripción *Google AI Pro*, utilizando el modelo Pro con rendimiento y razonamiento 3.1 Pro; y en *Claude* se trabajó mediante el plan *Claude Pro*. Las consultas se realizaron entre febrero y marzo de 2026 en sesiones independientes, sin arrastre de contexto entre casos, con el propósito de reducir interferencias derivadas de respuestas previas. Debido a las características de acceso de las interfaces web utilizadas, no se configuraron parámetros avanzados de generación; en consecuencia, el estudio se centró en examinar el comportamiento de los modelos en condiciones de uso ordinario y controlado.

Para cada sistema se emplearon tres *prompts* funcionalmente equivalentes, pero con distinto énfasis: un *prompt* base, un *prompt* con énfasis didáctico y un *prompt* con énfasis en seguridad y química verde. Los tres conservaron la misma estructura general del protocolo, pero el segundo reforzó claridad pedagógica, coherencia entre teoría y práctica y utilidad formativa, mientras que el tercero priorizó identificación de riesgos, medidas de protección, manejo de incidentes, prevención de residuos, menor peligrosidad de materiales y racionalidad en el uso de recursos. De este modo, el diseño comparativo quedó estructurado en $3 \text{ IA} \times 3 \text{ prompts} \times 6 \text{ temas}$, con un protocolo por cada combinación, para un corpus total de 54 documentos.

La generación de los protocolos se realizó en español y bajo un mismo nivel educativo de referencia. En cada combinación IA-*prompt*-tema se conservó únicamente la primera respuesta completa emitida por el sistema, sin repreguntas ni solicitudes de reformulación. Esta decisión respondió al interés de comparar el desempeño inicial de cada modelo bajo condiciones homogéneas y controladas. Los protocolos obtenidos se registraron en una matriz de control con código, inteligencia artificial utilizada, *prompt* aplicado, tema, fecha de generación y texto completo.

La evaluación se efectuó mediante una rúbrica analítica diseñada para esta investigación. El instrumento se estructuró en tres dimensiones: seguridad, valor didáctico y química verde, cada una integrada por cuatro indicadores específicos. En la dimensión de química verde, la valoración se apoyó en cuatro métricas formales derivadas de principios ampliamente aceptados en este campo: prevención de resid-

uos, menor peligrosidad de materiales y reactivos, gestión responsable de desechos y racionalidad en el uso de materiales y energía. En la dimensión de seguridad, además de los criterios pedagógicos propios del laboratorio educativo, se consideraron referentes formales asociados a la identificación de peligros, medidas de protección, coherencia operativa y manejo de incidentes, tomando como base orientaciones de la *American Chemical Society* para laboratorios académicos y el estándar OSHA aplicable a laboratorios no productivos, incluido su enfoque de comunicación de peligros en consonancia con el sistema GHS [12], [13], [14].

Previamente a su aplicación, la rúbrica fue sometida a validación de contenido mediante juicio de tres expertos con experiencia en didáctica de la química, seguridad de laboratorio y química verde. Los especialistas valoraron la claridad, pertinencia y coherencia de los doce indicadores mediante una escala de 1 a 4 puntos. A partir de estas valoraciones se calculó la V de Aiken para cada criterio y para cada indicador. Los resultados mostraron valores altos de validez de contenido, con promedios por indicador entre 0,778 y 0,963, y un promedio global de 0,886. Por dimensiones, los promedios fueron 0,889 en seguridad, 0,935 en valor didáctico y 0,834 en química verde. A partir de las observaciones cualitativas de los expertos, se ajustó la redacción de los indicadores con menor puntuación relativa para mejorar su precisión operativa y evitar superposición entre criterios.

La Tabla 1 presenta la matriz de evaluación utilizada para la valoración de los protocolos generados por las tres inteligencias artificiales. Cada indicador se calificó con una escala ordinal de 0 a 3 puntos. Operacionalmente, el valor 0 indicó ausencia del criterio o presencia de información incorrecta; el valor 1 correspondió a cumplimiento insuficiente o impreciso; el valor 2 expresó cumplimiento aceptable, aunque parcial; y el valor 3 indicó cumplimiento adecuado, explícito y coherente con el propósito del indicador. Todos los indicadores tuvieron la misma ponderación, por lo que no se establecieron pesos diferenciales entre dimensiones ni entre criterios internos. En consecuencia, cada indicador aportó de forma equivalente al puntaje final y el valor máximo alcanzable por protocolo fue de 36 puntos.

Tabla 1. Rúbrica analítica para la evaluación de protocolos generados por las tres inteligencias artificiales comparadas.

Dimensión	Código	Indicador	Escala	Ponderación
Seguridad	S1	Identificación de riesgos y peligros	0–3	Igual
	S2	Medidas de protección	0–3	Igual
	S3	Coherencia operativa segura	0–3	Igual
	S4	Manejo de residuos o incidentes	0–3	Igual
Valor didáctico	D1	Claridad del objetivo	0–3	Igual
	D2	Coherencia entre teoría y práctica	0–3	Igual
	D3	Secuencia procedimental	0–3	Igual
	D4	Potencial de aprendizaje	0–3	Igual
Química verde	Q1	Prevención de residuos	0–3	Igual
	Q2	Menor peligrosidad de materiales y reactivos	0–3	Igual
	Q3	Gestión responsable de desechos	0–3	Igual
	Q4	Racionalidad en el uso de materiales y energía	0–3	Igual

Nota. Cada indicador fue valorado mediante una escala ordinal de 0 a 3 puntos, con ponderación equivalente entre dimensiones y criterios.

Con el fin de incrementar la trazabilidad del análisis, los protocolos también se reexaminaron mediante una matriz de cumplimiento específica para química verde y seguridad. En dicha matriz, cada protocolo fue revisado en función de las métricas formales definidas para química verde y de los criterios de seguridad alineados con ACS, OSHA y GHS. Esta revisión complementaria permitió identificar no solo el puntaje global por dimensión, sino también cuáles criterios formales aparecieron cumplidos, parcialmente cumplidos o ausentes en los textos generados.

La evaluación de los protocolos fue realizada por dos evaluadores independientes. El primero correspondió a un docente-investigador en enseñanza de la química, con experiencia en diseño y evaluación de prácticas de laboratorio. El segundo fue un responsable de un laboratorio de química con experiencia en seguridad de laboratorio y en procesos de certificación. Ambos aplicaron la misma rúbrica al conjunto documental de manera independiente. Posteriormente, se compararon las valoraciones y se estimó la consistencia entre evaluadores mediante el coeficiente de correlación intraclase (ICC), empleando un modelo de dos vías con criterio de acuerdo absoluto. Los resultados revelaron niveles altos de

concordancia, con un ICC de 0,931 en seguridad, 0,964 en valor didáctico, 0,918 en química verde y 0,948 en el puntaje total, lo que respaldó la estabilidad del proceso de calificación.

Además del puntaje por rúbrica, se incorporaron dos variables complementarias: viabilidad formativa y porcentaje estimado de cambios requeridos. La viabilidad formativa se definió como el nivel en que un protocolo podía adaptarse para uso docente real, mediante una escala de 1 a 5 puntos, donde 1 correspondió a inviabilidad y 5 a viabilidad alta con ajustes mínimos. El porcentaje de cambios requeridos expresó la proporción estimada de modificaciones necesarias para convertir el protocolo en un documento utilizable en el laboratorio. Ambas variables fueron consensuadas por los dos evaluadores una vez concluida la calificación independiente.

El procedimiento se desarrolló en cinco fases. Primero, se definieron los temas, el nivel educativo, las inteligencias artificiales comparadas y los tres *prompts* de trabajo. Luego, se generó el corpus documental en sesiones independientes y controladas. Posteriormente, se aplicó la rúbrica analítica al conjunto de protocolos. En una cuarta fase, se realizó una reevaluación complementaria mediante métricas formales de química verde y seguridad. Finalmente, se organizaron e interpretaron los resultados. El análisis cuantitativo incluyó estadísticos descriptivos, comparación factorial de medias por IA y por *prompt*, correlaciones de Spearman entre dimensiones, viabilidad y porcentaje de cambios requeridos, y un modelo de regresión lineal múltiple para estimar la contribución relativa de seguridad, valor didáctico y química verde sobre la viabilidad formativa. De forma complementaria, el análisis cualitativo permitió reconocer omisiones recurrentes, inconsistencias procedimentales, fortalezas estructurales y problemas vinculados con la seguridad, la utilidad didáctica y la gestión de residuos.

IV. RESULTADOS Y DISCUSIÓN

La evaluación de los 54 protocolos de laboratorio generados por las tres inteligencias artificiales evidenció un desempeño global intermedio-alto. El puntaje promedio general fue de 24,61 puntos sobre 36, equivalente al 68,4% del máximo posible. Este valor se obtuvo a partir de la suma total de puntajes del corpus dividida entre los 54 documentos evaluados. En términos comparativos, los resultados mostraron que ni la inteligencia artificial utilizada ni el *prompt* fueron variables neutrales, ya que ambas incidieron en la calidad final de los protocolos, aunque el efecto del *prompt* fue más marcado que el del modelo.

Al desagregar los resultados por dimensiones, se observó que el mejor desempeño correspondió al valor didáctico, con un promedio general de 9,20 puntos sobre 12. Luego, se ubicó la seguridad, con 8,06 puntos, mientras que química verde presentó el promedio más bajo, con 7,35 puntos. Este patrón confirmó una tendencia ya observada en la fase exploratoria inicial del estudio: las inteligencias artificiales comparadas respondieron con mayor solvencia cuando se trató de estructurar objetivos, secuencias de trabajo y apartados de análisis, pero mostraron mayores limitaciones al incorporar de manera explícita criterios de sostenibilidad experimental y control técnico de riesgos.

Como puede apreciarse en la Tabla 2, el mejor desempeño global correspondió a la combinación *Claude-Prompt 3*, con un promedio total de 27,50 puntos, seguida por *ChatGPT-Prompt 3* con 26,67 y *Gemini-Prompt 3* con 25,50. En contraste, los valores más bajos se localizaron en las tres IA cuando se utilizó el *Prompt 1*, es decir, la versión base sin énfasis adicional. Este comportamiento muestra que la orientación explícita del *prompt* mejoró de forma consistente los resultados en los tres sistemas comparados.

Tabla 2. Puntajes promedio por inteligencia artificial y tipo de *prompt*.

IA/ <i>Prompt</i>	Seguridad	Valor didáctico	Química verde	Puntaje total
ChatGPT- <i>Prompt</i> 1	7,50	8,83	6,67	23,00
ChatGPT- <i>Prompt</i> 2	8,00	9,67	7,17	24,83
ChatGPT- <i>Prompt</i> 3	8,83	9,50	8,33	26,67
Gemini- <i>Prompt</i> 1	7,17	8,50	6,33	22,00
Gemini- <i>Prompt</i> 2	7,67	9,17	6,83	23,67
Gemini- <i>Prompt</i> 3	8,50	9,17	7,83	25,50
Claude- <i>Prompt</i> 1	7,67	8,83	6,83	23,33
Claude- <i>Prompt</i> 2	8,17	9,50	7,33	25,00
Claude- <i>Prompt</i> 3	9,00	9,67	8,83	27,50

Nota. Los valores corresponden al promedio por dimensión y al puntaje total promedio obtenido por cada combinación IA-*prompt*.

Al considerar el efecto global del *prompt*, el promedio total fue de 22,78 puntos para el *Prompt* 1, 24,50 para el *Prompt* 2 y 26,56 para el *Prompt* 3. En consecuencia, la inclusión de instrucciones explícitas relacionadas con seguridad y química verde produjo el mayor incremento de calidad. La comparación factorial confirmó esta tendencia: el efecto del *prompt* sobre el puntaje total fue significativo ($F = 18,64$; $p < 0,001$), mientras que el efecto de la IA también resultó significativo, aunque de menor magnitud ($F = 4,12$; $p = 0,023$). La interacción IA $\times$ *prompt* no alcanzó significación estadística ($F = 0,84$; $p = 0,508$), lo que sugiere que la mejora producida por el cambio de *prompt* siguió un patrón relativamente estable en los tres modelos. En términos dimensionales, el mejor desempeño correspondió al valor didáctico, lo que indica que las tres inteligencias artificiales comparadas fueron más eficaces al construir la forma pedagógica general del recurso que al garantizar su solidez experimental. Esta interpretación coincide con lo señalado por Araújo y Saúde [3], así como con Yuriev, Orgill y Holme [11], quienes subrayan que el valor educativo de la IA generativa depende de una mediación crítica capaz de identificar tanto sus fortalezas como sus límites.

La dimensión de seguridad presentó resultados intermedios. Los protocolos tendieron a incluir recomendaciones generales, como el uso de bata, gafas o guantes, y en muchos casos señalaron precauciones básicas durante el desarrollo experimental. No obstante, estas advertencias aparecieron con frecuencia de forma genérica y sin un desarrollo suficientemente específico de riesgos asociados a reactivos, procedimientos o posibles incidentes. En consecuencia, aunque la seguridad no fue la dimensión con menor desempeño, tampoco alcanzó un nivel que permita considerar los protocolos como recursos plenamente confiables desde el punto de vista experimental. Desde esta perspectiva, los resultados refuerzan la idea de que la calidad del protocolo no puede evaluarse solo por su orden expositivo, sino también por la precisión con que anticipa y regula condiciones de riesgo. Esta lectura resulta consistente con los planteamientos de Vargas-Rodríguez et al. [6], quienes propusieron una evaluación integral de experimentos considerando salud, ambiente, seguridad y disposición de residuos, así como con la aproximación práctica de Reina y Reina [16], que insiste en la formación explícita para la prevención y respuesta ante accidentes en el laboratorio.

La revisión desde referentes formales de seguridad permitió observar que las mayores mejoras se produjeron cuando el *prompt* incorporó instrucciones explícitas sobre identificación de riesgos y manejo de incidentes. En promedio, el *Prompt* 3 incrementó la dimensión de seguridad en 0,89 puntos con respecto al *Prompt* 2 y en 1,28 puntos con respecto al *Prompt* 1. Este resultado confirmó que la calidad de la respuesta no dependió exclusivamente del modelo utilizado, sino también del grado de especificidad del encuadre instruccional.

La dimensión con menor rendimiento fue química verde, lo que evidenció una incorporación más limitada de criterios orientados a reducir la peligrosidad de materiales, minimizar residuos y optimizar el uso de recursos. Aunque varios protocolos incluyeron apartados de gestión de residuos, estos no siempre se desarrollaron con suficiente precisión operativa ni se integraron verdaderamente al diseño de la práctica. En términos generales, la sostenibilidad apareció más como un componente formal del protocolo que como una lógica de construcción experimental.

Este resultado es relevante, ya que sugiere que los modelos comparados tendieron a reproducir estructuras convencionales de prácticas de laboratorio sin incorporar de manera consistente decisiones orientadas a la prevención, la reducción del impacto y la selección más responsable de reactivos y

procedimientos. En consecuencia, la inteligencia artificial pareció responder mejor a la organización textual del protocolo que a su optimización desde una perspectiva de química verde. En este sentido, esta interpretación coincide con Ruff, Franz y West [17], quienes mostraron que *ChatGPT* puede apoyar actividades vinculadas con química verde, aunque su utilidad depende del modo en que se orienta y supervisa su uso. De forma similar, Kim [15] evidenció que la articulación entre *chatbots* de IA y principios de química verde es posible, pero requiere una intención pedagógica explícita que no emergió de forma suficientemente sólida en las respuestas basadas en el *prompt* general.

La viabilidad formativa promedio del corpus fue de 3,11 puntos sobre 5, mientras que el porcentaje estimado de cambios requeridos fue de 34,8%. Los mejores resultados se observaron nuevamente en los protocolos generados con el *Prompt* 3, cuyo porcentaje de cambios descendió a 29,4%, frente al 36,1% del *Prompt* 2 y al 46,8% del *Prompt* 1. Este patrón sugiere que el refinamiento del *prompt* no solo mejora el puntaje por rúbrica, sino también la proximidad del protocolo a una versión potencialmente utilizable en el aula o en el laboratorio.

El análisis correlacional mostró que el puntaje total se asoció positivamente con la viabilidad formativa ($\rho = 0,84$; $p < 0,001$) y negativamente con el porcentaje de cambios requeridos ($\rho = -0,81$; $p < 0,001$). De manera más específica, la seguridad presentó una correlación de 0,79 con la viabilidad, mientras que química verde mostró una correlación de $-0,74$ con el porcentaje de cambios requeridos. Estos resultados indican que, a medida que aumentan los puntajes en seguridad y química verde, disminuye la necesidad de corrección sustantiva del protocolo.

El análisis multivariado reforzó esta interpretación. El modelo de regresión lineal múltiple, en el que la variable dependiente fue la viabilidad formativa, mostró que las tres dimensiones evaluadas explicaron conjuntamente el 72,3% de su varianza ($R^2 = 0,723$). La seguridad presentó el mayor peso relativo ($\beta = 0,39$; $p < 0,001$), seguida del valor didáctico ($\beta = 0,31$; $p = 0,004$) y de química verde ($\beta = 0,29$; $p = 0,007$). Esto significa que, aunque el valor didáctico fue la dimensión mejor puntuada, la seguridad resultó ser la variable más influyente cuando se trató de explicar la viabilidad real del protocolo.

Con el fin de precisar qué criterios formales fueron efectivamente incorporados en los protocolos generados por las tres inteligencias artificiales, se realizó una reevaluación complementaria basada en métricas explícitas de química verde y seguridad. Esta revisión permitió identificar el grado de cumplimiento de criterios asociados a la prevención de residuos, la peligrosidad de reactivos, la gestión de desechos, la racionalidad en el uso de recursos, la identificación de peligros, las medidas de protección, la coherencia operativa segura y el manejo de incidentes. La Tabla 3 presenta la distribución de protocolos que cumplieron, cumplieron parcialmente o no cumplieron cada uno de estos criterios.

Tabla 3. Cumplimiento de métricas formales de química verde y seguridad en los protocolos evaluados.

Criterio	Cumple n (%)	Cumple parcialmente n (%)	No cumple n (%)
GV1. Prevención de residuos	22 (40,7)	20 (37,0)	12 (22,2)
GV2. Menor peligrosidad de materiales y reactivos	16 (29,6)	18 (33,3)	20 (37,0)
GV3. Gestión responsable de desechos	11 (20,4)	17 (31,5)	26 (48,1)
GV4. Racionalidad en el uso de materiales y energía	14 (25,9)	19 (35,2)	21 (38,9)
SEG1. Identificación de riesgos y peligros	20 (37,0)	21 (38,9)	13 (24,1)
SEG2. Medidas de protección	31 (57,4)	15 (27,8)	8 (14,8)
SEG3. Coherencia operativa segura	34 (63,0)	12 (22,2)	8 (14,8)
SEG4. Manejo de incidentes o residuos	13 (24,1)	14 (25,9)	27 (50,0)

Nota. Los porcentajes fueron calculados sobre el total de 54 protocolos evaluados.

Los resultados de esta reevaluación mostraron que las mayores deficiencias se concentraron en la gestión responsable de desechos y en el manejo de incidentes o residuos, criterios en los que 26 y 27 protocolos, respectivamente, no cumplieron los requisitos esperados. También se observaron niveles altos de incumplimiento en menor peligrosidad de materiales y reactivos y en racionalidad en el uso de materiales y energía. En contraste, los criterios con mejor comportamiento relativo fueron las medidas de protección y la coherencia operativa segura. Este patrón confirma que las tres

IA comparadas respondieron mejor cuando se trató de incorporar advertencias generales y organizar secuencias aceptables de trabajo que cuando debieron integrar decisiones más específicas sobre seguridad formal y química verde.

En conjunto, los resultados permiten sostener que la inteligencia artificial puede ser útil como herramienta de apoyo para la elaboración de borradores iniciales de protocolos de laboratorio en la enseñanza de la química, sobre todo cuando se utiliza un *prompt* explícitamente orientado a seguridad y química verde. Sin embargo, el desempeño de los modelos fue desigual entre dimensiones, y las principales limitaciones se concentraron en aquellos aspectos más sensibles para la implementación real de una práctica experimental, particularmente la seguridad específica, la gestión de incidentes y la coherencia con criterios de química verde. Por ello, el aporte de estas herramientas no reside en sustituir el juicio docente ni el diseño experto del protocolo, sino en ofrecer insumos preliminares que pueden ser adaptados, depurados y validados antes de su uso en el laboratorio.

CONCLUSIONES

El estudio permitió establecer que la calidad de los protocolos de laboratorio generados por inteligencia artificial estuvo condicionada tanto por el sistema utilizado como por el tipo de *prompt* aplicado, aunque el efecto del *prompt* resultó más determinante que el del modelo. En términos generales, las tres inteligencias artificiales comparadas mostraron mejor desempeño en valor didáctico que en seguridad y química verde, lo que indica que la estructura pedagógica básica del protocolo puede generarse con relativa solvencia, pero no así sus componentes técnicos más sensibles.

La principal fortaleza observada se situó en la formulación de objetivos, la secuencia procedimental y la estructuración general de actividades de análisis. En contraste, las mayores limitaciones se concentraron en la explicitación de condiciones de seguridad y en la incorporación operativa de criterios de química verde, particularmente en lo relativo a gestión de desechos, manejo de incidentes, peligrosidad de materiales y racionalidad en el uso de recursos. En este sentido, un protocolo puede resultar formalmente ordenado y didácticamente comprensible, pero seguir siendo insuficiente cuando se lo analiza desde exigencias de seguridad experimental y sostenibilidad.

El principal aporte del estudio no consistió en reiterar que la inteligencia artificial requiere supervisión humana, sino en demostrar que la pertinencia de los protocolos generados depende del criterio desde el cual se los examine y del modo en que se orienta la interacción con el sistema. La comparación entre *prompts* mostró que la simple generación automática de textos no garantiza calidad suficiente; por el contrario, la especificidad instruccional del *prompt* resultó decisiva para mejorar seguridad, química verde, viabilidad formativa y reducción del porcentaje de cambios requeridos.

Asimismo, la incorporación de métricas formales de química verde y de referentes explícitos de seguridad permitió profundizar la valoración crítica del corpus. A partir de ello, se evidenció que las principales debilidades de los protocolos no se localizaron en la estructura discursiva general, sino en la insuficiente integración de decisiones técnicas orientadas a prevenir residuos, reducir peligrosidad, comunicar riesgos de manera más precisa y orientar adecuadamente la respuesta ante incidentes. Por tanto, la evaluación de materiales generados por IA en enseñanza de la química debe ir más allá de la coherencia textual e incorporar criterios técnicos y ambientales que condicionan su viabilidad real.

En consecuencia, la inteligencia artificial puede considerarse una herramienta útil para la elaboración de borradores iniciales de protocolos de laboratorio, pero no como un generador de documentos directamente transferibles al trabajo experimental sin revisión especializada. Su valor pedagógico se ubica, sobre todo, en su capacidad para ofrecer una base preliminar susceptible de adaptación, validación y mejora por parte del profesorado. En este marco, la rúbrica aplicada y la comparación entre modelos y *prompts* constituyen una contribución metodológica pertinente para examinar críticamente recursos experimentales producidos por inteligencia artificial en contextos educativos introductorios.

Finalmente, aunque la ampliación del diseño permitió responder con mayor solidez a las observaciones metodológicas iniciales, los hallazgos siguen inscritos en un alcance comparativo acotado, centrado en tres inteligencias artificiales, tres *prompts* y seis temas introductorios. Por ello, futuras investigaciones podrían profundizar en diseños longitudinales, aplicaciones empíricas con estudiantes, contrastación entre niveles educativos y validaciones más amplias con protocolos desarrollados en condiciones reales de laboratorio.

REFERENCIAS

- [1] A. K. Erümit and R. Ö. Sarılioğlu, "Artificial intelligence in science and chemistry education: a systematic review," *Discover Education*, vol. 4, no. 1, p. 178, 2025.
- [2] Y. Feldman-Maggor, R. Blonder, and G. Alexandron, "Perspectives of generative ai in chemistry education within the tpack framework," *Journal of Science Education and Technology*, vol. 34, no. 1, pp. 1–12, 2024.
- [3] J. L. Araújo and I. Saúde, "Can chatgpt enhance chemistry laboratory teaching? using prompt engineering to enable ai in generating laboratory activities," *Journal of Chemical Education*, vol. 101, no. 5, pp. 1858–1864, 2024.
- [4] T. M. Clark, "Investigating the use of an artificial intelligence chatbot with general chemistry exam questions," *Journal of Chemical Education*, vol. 100, no. 5, pp. 1905–1916, 2023.
- [5] B. J. Yik and A. J. Dood, "Chatgpt convincingly explains organic chemistry reaction mechanisms slightly inaccurately with high levels of explanation sophistication," *Journal of Chemical Education*, vol. 101, no. 5, pp. 1836–1846, 2024.
- [6] Y. M. Vargas-Rodríguez *et al.*, "El diagrama de flujo como semáforo de seguridad ecológica de los experimentos de laboratorio," *Educación Química*, vol. 27, no. 1, pp. 30–36, 2016.
- [7] U.S. Environmental Protection Agency, "Basics of green chemistry," 2026, available: <https://www.epa.gov/greenchemistry/basics-green-chemistry>. Accedido: 6 de abril de 2026.
- [8] American Chemical Society, "12 principles of green chemistry," 2026, available: <https://www.acs.org/green-chemistry-sustainability/principles/12-principles-of-green-chemistry.html>. Accedido: 10 de abril de 2026.
- [9] S. A. Gunbatar, G. T. Sirin, O. C. Ilkyaz, and Y. Mutlu, "Exploring the artificial intelligence interaction profiles of participants with different levels of teaching experience for lesson planning in the context of acids and bases," *Chemistry Education Research and Practice*, vol. 26, no. 4, pp. 977–995, 2025.
- [10] M. E. Emenike and B. U. Emenike, "Was this title generated by chatgpt? considerations for artificial intelligence text-generation software programs for chemists and chemistry educators," *Journal of Chemical Education*, vol. 100, no. 4, pp. 1413–1418, 2023.
- [11] E. Yuriev, M. Orgill, and T. Holme, "Generative ai in chemistry education: Current progress, pedagogical values, and the challenge of rapid evolution," *Journal of Chemical Education*, vol. 102, no. 9, pp. 3773–3776, 2025.
- [12] American Chemical Society, "Safety in academic chemistry laboratories: Best practices for first- and second-year university students," 2017.
- [13] —, "Guidelines for chemical laboratory safety in academic institutions," Washington, DC, 2016.
- [14] Occupational Safety and Health Administration, "1910.1450 - occupational exposure to hazardous chemicals in laboratories," 2026, available: <https://www.osha.gov/laws-regs/regulations/standardnumber/1910/1910.1450>. Accedido: 13 de mayo de 2026.
- [15] J. Kim, "Integrating artificial intelligence (ai) chatbots and green chemistry principles in the synthesis of cyclohexene," *Journal of Chemical Education*, vol. 102, no. 7, pp. 3058–3064, 2025.
- [16] M. Reina and A. Reina, "Seguridad en el laboratorio: una aproximación práctica," *Educación Química*, vol. 32, no. 4, pp. 45–58, 2021.
- [17] E. F. Ruff, J. L. Franz, and J. K. West, "Using chatgpt for method development and green chemistry education in upper-level laboratory courses," *Journal of Chemical Education*, vol. 101, no. 8, pp. 3224–3232, 2024.

Artículo de investigación

<https://doi.org/10.47460/athenea.v7i24.144>

Modelado dinámico no lineal y simulación Monte Carlo de la propagación de fallas en redes energéticas antifrágiles bajo perturbaciones estocásticas

Yomber Montilla López*

<https://orcid.org/0000-0002-8592-248X>
ymontillal@uteq.edu.ec
Universidad Técnica Estatal de Quevedo
Quevedo, Ecuador

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

Brexys Linares Rodríguez

<https://orcid.org/0009-0003-0423-4971>
blinares9307@utm.edu.ec
Universidad Técnica de Manabí
Portoviejo, Ecuador

Rodolfo Cornejo

<https://orcid.org/0000-0001-9325-6512>
recpesq@gmail.com
Facultad de Ingeniería Pesquera y Alimentos,
Universidad Nacional del Callao; Instituto del
Mar del Perú (IMARPE)
Callao, Perú

*Autor de correspondencia: ymontillal@uteq.edu.ec

Recibido: (02/03/2026), Aceptado: (06/06/2026)

Resumen. Las redes energéticas modernas constituyen sistemas dinámicos complejos caracterizados por incertidumbre operativa y comportamientos no lineales. El objetivo de esta investigación fue desarrollar un marco físico-computacional para analizar la estabilidad y capacidad de adaptación de redes energéticas sometidas a perturbaciones estocásticas. Se empleó un modelo dinámico no lineal basado en ecuaciones diferenciales ordinarias, integrando simulación Monte Carlo, muestreo *Latin Hypercube*, un Índice de Antifragilidad Energética (EAI), análisis de sensibilidad mediante índices de Sobol y análisis de bifurcaciones. Los resultados evidenciaron comportamientos frágiles, resilientes y antifrágiles, con predominio de escenarios resilientes. La intensidad de acoplamiento y la magnitud de las perturbaciones fueron los parámetros de mayor influencia sobre el sistema. Asimismo, se identificó un umbral crítico asociado con la aparición de múltiples estados de equilibrio y transiciones dinámicas. Se concluye que la integración de dinámica no lineal y simulación probabilística permite comprender el comportamiento de sistemas energéticos complejos bajo incertidumbre.

Palabras clave: redes energéticas, sistemas dinámicos complejos, simulación Monte Carlo, antifragilidad, bifurcaciones.

Nonlinear Dynamic Modeling and Monte Carlo Simulation of Failure Propagation in Antifragile Energy Networks under Stochastic Perturbations

Abstract. Modern energy networks constitute complex dynamic systems characterized by operational uncertainty and nonlinear behavior. The objective of this research was to develop a physical-computational framework to analyze the stability and adaptive capacity of energy networks subjected to stochastic perturbations. A nonlinear dynamic model based on ordinary differential equations was employed, integrating Monte Carlo simulation, *Latin Hypercube* sampling, an Energy Antifragility Index (EAI), sensitivity analysis using Sobol indices, and bifurcation analysis. The results revealed fragile, resilient, and antifragile behaviors, with resilient scenarios predominating. Coupling intensity and perturbation magnitude were the parameters with the greatest influence on the system. Likewise, a critical threshold associated with the emergence of multiple equilibrium states and dynamic transitions was identified. It is concluded that the integration of nonlinear dynamics and probabilistic simulation makes it possible to understand the behavior of complex energy systems under uncertainty.

Keywords: energy networks, complex dynamic systems, Monte Carlo simulation, antifragility, bifurcations.



I. INTRODUCCIÓN

La creciente complejidad de las redes energéticas modernas ha incrementado la necesidad de desarrollar herramientas de modelado capaces de representar la interacción entre múltiples fuentes de generación, la incertidumbre operativa y la propagación de perturbaciones dentro de sistemas altamente interconectados. La integración de energías renovables, la digitalización de la infraestructura eléctrica y la creciente dependencia de sistemas ciberfísicos han convertido la estabilidad y la capacidad de adaptación de las redes energéticas en temas prioritarios de investigación científica y tecnológica [1], [2].

Diversos estudios han demostrado que las redes energéticas constituyen sistemas dinámicos complejos caracterizados por comportamientos no lineales, dependencias espaciales y temporales, y respuestas emergentes ante perturbaciones externas [2], [3]. En este contexto, las fallas en componentes individuales pueden propagarse a través de la red y generar fenómenos de cascada que comprometen el funcionamiento global del sistema [3], [4]. La comprensión de estos procesos resulta particularmente relevante en escenarios de incertidumbre, eventos extremos y condiciones operativas variables, donde las aproximaciones deterministas tradicionales presentan limitaciones para describir adecuadamente la dinámica del sistema [5].

En los últimos años, el concepto de antifragilidad ha despertado un creciente interés en el estudio de sistemas complejos debido a su capacidad para explicar situaciones en las que determinados sistemas no solo resisten perturbaciones, sino que también pueden reorganizarse y mejorar su desempeño después de experimentar condiciones adversas [2], [6]. Este enfoque ha sido aplicado en el diseño de sistemas energéticos renovables [6], en la sincronización de osciladores en redes complejas [7] y en el análisis de la resiliencia de infraestructuras críticas [8]. Sin embargo, la incorporación de principios de antifragilidad en el estudio dinámico de redes energéticas continúa siendo limitada, particularmente en investigaciones que integren simultáneamente incertidumbre paramétrica, análisis probabilístico y exploración de transiciones dinámicas.

Paralelamente, las investigaciones recientes han evidenciado la importancia de la simulación computacional para evaluar la respuesta de sistemas complejos ante perturbaciones y condiciones de incertidumbre [5]. Los modelos estocásticos, las simulaciones probabilísticas y las técnicas de propagación de fallas han permitido identificar configuraciones vulnerables, mecanismos de recuperación y estrategias de mitigación en sistemas energéticos de gran escala [4], [9], [10]. Asimismo, el empleo de grafos de propagación de fallas y modelos de acoplamiento ha contribuido a comprender la evolución de eventos en cascada y la interacción entre múltiples subsistemas energéticos [10], [11].

A pesar de estos avances, persiste una brecha de investigación relacionada con el desarrollo de marcos físico-computacionales que permitan analizar, de manera integrada, la dinámica no lineal, la incertidumbre estocástica y la aparición de comportamientos emergentes en redes energéticas complejas. En particular, son escasos los estudios que combinan simulación Monte Carlo, análisis global de sensibilidad y técnicas de bifurcación para identificar parámetros dominantes, umbrales críticos y posibles transiciones cualitativas en el comportamiento del sistema.

En respuesta a esta necesidad, el presente estudio propuso un marco de modelado dinámico no lineal para el análisis de redes energéticas sometidas a perturbaciones estocásticas. La investigación integró simulación Monte Carlo, análisis global de sensibilidad mediante índices de Sobol y análisis de bifurcaciones con el propósito de evaluar la estabilidad, la recuperación y la posible aparición de comportamientos frágiles, resilientes y antifrágiles. Se planteó la hipótesis de que la intensidad de acoplamiento y la magnitud de las perturbaciones constituyen parámetros dominantes capaces de inducir cambios cualitativos en la dinámica del sistema y de generar múltiples regímenes de comportamiento bajo condiciones de incertidumbre.

II. MARCO TEÓRICO

A. Redes energéticas como sistemas dinámicos complejos

Las redes energéticas modernas constituyen sistemas altamente interconectados cuya dinámica depende de la interacción simultánea entre generación, transmisión, consumo y mecanismos de control. La incorporación de energías renovables, sistemas ciberfísicos y múltiples fuentes distribuidas ha in-

crementado la complejidad estructural y funcional de las redes eléctricas, favoreciendo la aparición de fenómenos emergentes, comportamientos no lineales y procesos de autoorganización [1], [2].

Desde la perspectiva de la física de sistemas complejos, las redes energéticas pueden representarse como conjuntos de nodos acoplados cuyos estados evolucionan en función de interacciones locales y perturbaciones externas. Bajo determinadas condiciones operativas, pequeñas variaciones en la conectividad o en la demanda pueden producir cambios significativos en el comportamiento global del sistema, dando lugar a respuestas dinámicas que no pueden explicarse únicamente a partir del análisis individual de sus componentes [2], [3]. Asimismo, las fallas localizadas poseen la capacidad de propagarse mediante mecanismos de cascada y comprometer la estabilidad del sistema energético completo [3], [11].

B. Antifragilidad y comportamiento emergente en sistemas complejos

El concepto de antifragilidad ha adquirido creciente relevancia en el estudio de sistemas complejos debido a que describe la capacidad de ciertos sistemas para mejorar su desempeño después de experimentar perturbaciones o situaciones adversas [2]. A diferencia de la robustez, que implica resistencia al cambio, y de la resiliencia, que supone recuperación hacia un estado previo, la antifragilidad se caracteriza por la posibilidad de adaptación y reorganización positiva como consecuencia de la exposición a la incertidumbre [6].

Las investigaciones recientes han demostrado que la antifragilidad puede manifestarse en sistemas energéticos y redes complejas mediante procesos de redistribución de cargas, sincronización adaptativa y reorganización de las interacciones entre nodos [6], [7]. En particular, los estudios sobre sincronización de osciladores en redes complejas han evidenciado que determinadas configuraciones de acoplamiento favorecen respuestas emergentes capaces de mejorar la estabilidad global del sistema después de la ocurrencia de perturbaciones [7]. Sin embargo, la identificación de condiciones que permitan distinguir entre comportamientos frágiles, resilientes y antifrágiles continúa representando un desafío en el análisis de redes energéticas bajo incertidumbre [2].

C. Incertidumbre y simulación probabilística en redes energéticas

La operación de sistemas energéticos contemporáneos se encuentra influenciada por múltiples fuentes de incertidumbre asociadas con la variabilidad de la demanda, la intermitencia de las energías renovables, las fallas de componentes y los eventos extremos [4], [5]. Debido a la naturaleza estocástica de estos fenómenos, los enfoques deterministas tradicionales presentan limitaciones para representar adecuadamente la evolución dinámica de las redes energéticas.

En este contexto, la simulación probabilística se ha consolidado como una herramienta de gran utilidad para evaluar el comportamiento de sistemas complejos bajo diferentes escenarios operativos [5]. Los modelos estocásticos y los marcos probabilísticos han permitido analizar la propagación de fallas, estimar niveles de riesgo y explorar estrategias de mitigación en redes energéticas sometidas a perturbaciones de distinta naturaleza [3], [4], [9]. Asimismo, las técnicas de simulación basadas en múltiples escenarios han demostrado ser particularmente útiles para identificar configuraciones vulnerables y evaluar la capacidad de recuperación de sistemas de gran escala [4], [10].

D. Sensibilidad paramétrica y transiciones dinámicas

La respuesta de un sistema dinámico complejo depende no solo de la magnitud de las perturbaciones externas, sino también de la interacción entre los parámetros que gobiernan su evolución temporal. En consecuencia, la identificación de parámetros dominantes constituye un aspecto fundamental para comprender la estabilidad y la capacidad adaptativa de las redes energéticas [2], [11]. Los análisis globales de sensibilidad permiten cuantificar la contribución individual de los parámetros y determinar cuáles de ellos poseen mayor influencia sobre las variables de salida del sistema. Esta información resulta especialmente relevante en modelos no lineales, donde pequeñas variaciones paramétricas pueden generar respuestas desproporcionadas y cambios cualitativos en la dinámica global [2], [7].

De manera complementaria, la teoría de sistemas dinámicos establece que determinados parámetros de control pueden inducir transiciones entre diferentes estados de equilibrio, generando regiones de estabilidad, inestabilidad y comportamientos emergentes [2]. La identificación de umbrales críticos y

cambios de régimen constituye un elemento esencial para comprender la evolución de redes energéticas complejas, particularmente en escenarios caracterizados por incertidumbre y propagación de perturbaciones [3], [10], [11].

III. METODOLOGÍA

La investigación se desarrolló bajo un enfoque cuantitativo, computacional y explicativo, orientado al modelado del comportamiento dinámico de una red energética sometida a perturbaciones estocásticas. El estudio no tuvo como propósito reproducir una red eléctrica nacional completa, sino construir un marco físico-computacional controlado que permitiera analizar la estabilidad, recuperación y capacidad adaptativa de un sistema energético ante fallas, variaciones de carga e incertidumbre en la generación. Esta delimitación permitió mantener la coherencia entre la complejidad matemática del modelo, la capacidad de simulación y la interpretación física de los resultados.

A. Modelado dinámico de la red energética

El sistema energético se representó mediante una red de N nodos interconectados, donde cada nodo correspondió a una fuente de generación, una carga o un elemento de almacenamiento energético. La evolución temporal del sistema se describió mediante un sistema de ecuaciones diferenciales ordinarias no lineales:

$$\frac{dx(t)}{dt} = F(x(t), u(t), \theta) + \xi(t) \quad (1)$$

donde $x(t)$ es el vector de estados del sistema, $u(t)$ representa las entradas de control, θ corresponde a los parámetros físicos y operativos, y $\xi(t)$ representa la perturbación estocástica. La formulación no lineal permitió representar respuestas transitorias, recuperación parcial, pérdida de estabilidad y sensibilidad a variaciones paramétricas.

B. Representación topológica de la red

La estructura de la red se definió mediante una matriz de adyacencia ponderada:

$$A = [a_{ij}], \quad i, j = 1, \dots, N \quad (2)$$

donde a_{ij} representó la intensidad de conexión entre los nodos i y j . El término de acoplamiento energético se expresó como:

$$C_i(t) = \sum_{j=1}^N a_{ij} [x_j(t) - x_i(t)] \quad (3)$$

Esta formulación permitió modelar la propagación de perturbaciones y el intercambio energético entre nodos sin recurrir a modelos completos de flujo de potencia AC, lo cual habría incrementado considerablemente la complejidad computacional.

C. Formulación energética y análisis de estabilidad

La energía equivalente del sistema se estimó mediante:

$$E(t) = \sum_{i=1}^N \left(\frac{1}{2} C_i V_i^2(t) + \frac{1}{2} L_i I_i^2(t) \right) \quad (4)$$

donde C_i representa la capacitancia equivalente, L_i la inductancia equivalente, $V_i(t)$ la tensión normalizada e $I_i(t)$ la corriente normalizada. La estabilidad dinámica se evaluó mediante una función de Lyapunov:

$$V_L(t) = \frac{1}{2} \sum_{i=1}^N (x_i(t) - x_i^*)^2 \quad (5)$$

donde x_i^* representó el estado de equilibrio del nodo i . La evolución temporal de esta función permitió identificar la tendencia del sistema hacia condiciones de estabilidad o inestabilidad después de la aplicación de perturbaciones.

D. Construcción de escenarios estocásticos

Se consideraron tres escenarios de perturbación: fluctuaciones leves de carga modeladas mediante ruido gaussiano de baja amplitud; eventos moderados asociados con variaciones simultáneas de generación y demanda; y fallas severas que incluyeron desconexión temporal de nodos y reducción de la capacidad de transmisión. Las perturbaciones se generaron mediante:

$$\xi(t) \sim \mathcal{N}(0, \sigma^2) \quad (6)$$

donde σ representó la intensidad de la incertidumbre.

E. Simulación Monte Carlo y muestreo probabilístico

La incertidumbre de los parámetros se incorporó mediante simulación Monte Carlo y muestreo *Latin Hypercube*. Cada parámetro incierto se definió como:

$$\theta_i \sim f_i(\mu_i, \sigma_i) \quad (7)$$

donde f_i correspondió a una distribución probabilística apropiada para cada parámetro. Se generaron 1000 escenarios independientes, obteniendo trayectorias temporales del sistema bajo diferentes combinaciones de intensidad de acoplamiento, amortiguamiento, variabilidad de carga, severidad de falla y capacidad de recuperación.

F. Indicadores de recuperación dinámica

El tiempo de recuperación se definió como:

$$T_R = \min\{t : |x_i(t) - x_i^*| < \varepsilon, \forall t \geq T_R\} \quad (8)$$

donde ε representó una banda de tolerancia alrededor del equilibrio. La probabilidad de recuperación se calculó mediante:

$$P_R = \frac{n_R}{N_s} \quad (9)$$

donde n_R corresponde al número de simulaciones recuperadas y N_s al número total de simulaciones.

G. Índice de Antifragilidad Energética

Como aporte metodológico se propuso el Índice de Antifragilidad Energética, denominado *Energy Antifragility Index* (EAI):

$$EAI = \frac{P_{post} - P_{pre}}{S + \delta} \quad (10)$$

donde P_{pre} representa el desempeño previo a la perturbación, P_{post} el desempeño posterior a la recuperación, S la severidad de la perturbación y δ una constante positiva pequeña. La interpretación se estableció de la siguiente manera: $EAI < 0$ indicó comportamiento frágil; $EAI \approx 0$, comportamiento resiliente; y $EAI > 0$, comportamiento antifrágil.

H. Entropía dinámica del sistema

El grado de desorden inducido por las perturbaciones se cuantificó mediante:

$$H(t) = - \sum_{k=1}^m p_k(t) \ln p_k(t) \quad (11)$$

donde $p_k(t)$ representó la probabilidad de ocurrencia del estado discretizado k .

I. Análisis global de sensibilidad

La contribución individual de cada parámetro se estimó mediante índices de Sobol de primer orden:

$$S_i = \frac{\text{Var}_{\theta_i}(\mathbb{E}[Y|\theta_i])}{\text{Var}(Y)} \quad (12)$$

donde Y representó una salida del modelo, como el tiempo de recuperación, la energía disipada o el índice EAI.

J. Implementación computacional

La implementación se desarrolló en R, utilizando procedimientos de resolución numérica de ecuaciones diferenciales, simulación Monte Carlo, muestreo *Latin Hypercube*, análisis de sensibilidad global y construcción de mapas de estabilidad y recuperación. Las simulaciones que presentaron divergencias numéricas, soluciones no físicas o valores fuera de los rangos establecidos fueron excluidas del análisis y se reportó su proporción respecto al total de escenarios generados.

K. Análisis de bifurcaciones y comportamiento dinámico global

Con el propósito de identificar cambios cualitativos en la dinámica de la red energética, se realizó un análisis de bifurcaciones mediante la variación sistemática de parámetros de control asociados con la intensidad de acoplamiento energético, la tasa de amortiguamiento y la severidad de las perturbaciones. Los puntos de equilibrio del sistema se obtuvieron imponiendo:

$$F(x^*, u, \theta) = 0 \quad (1)$$

La estabilidad local de dichos equilibrios se evaluó mediante la matriz Jacobiana:

$$J = \left. \frac{\partial F}{\partial x} \right|_{x=x^*} \quad (13)$$

cuyos autovalores fueron calculados para cada escenario paramétrico. La condición de estabilidad local se estableció como:

$$\text{Re}(\lambda_i) < 0, \quad i = 1, \dots, N \quad (14)$$

mientras que la pérdida de estabilidad se identificó cuando al menos un autovalor satisfizo:

$$\text{Re}(\lambda_i) \geq 0 \quad (15)$$

La variación de los autovalores permitió detectar la posible aparición de transiciones dinámicas, regiones de inestabilidad y cambios cualitativos en el comportamiento del sistema.

IV. RESULTADOS

A. Comportamiento dinámico de la red energética bajo perturbaciones estocásticas

Se ejecutaron múltiples simulaciones del sistema energético mediante el modelo dinámico no lineal propuesto, considerando diferentes niveles de perturbación y variabilidad paramétrica. Los resultados mostraron que la red presentó una respuesta estable frente a perturbaciones de baja intensidad, caracterizada por desviaciones transitorias moderadas y tiempos de recuperación relativamente cortos. Sin embargo, al incrementarse la severidad de las perturbaciones, se observaron mayores oscilaciones en las variables de estado, acompañadas de incrementos en la dispersión de las trayectorias temporales.

La Figura 1 mostró la evolución temporal de la variable de estado normalizada para diferentes escenarios estocásticos. En condiciones de perturbación leve, las trayectorias convergieron rápidamente hacia el equilibrio. Por el contrario, los escenarios de alta incertidumbre produjeron respuestas transitorias prolongadas y una recuperación más lenta del sistema.




Fig. 1. Respuesta dinámica de la red energética bajo diferentes niveles de perturbación.

Los comportamientos oscilatorios observados en escenarios severos sugirieron la existencia de umbrales dinámicos asociados con cambios cualitativos en la estabilidad del sistema. Por tal motivo, se realizó un análisis de bifurcaciones para identificar regiones críticas de operación. Los escenarios presentados correspondieron a los tres niveles de perturbación definidos en la metodología: fluctuaciones leves de carga, eventos moderados y fallas severas.

De manera consistente con la teoría de sistemas dinámicos, el incremento de la incertidumbre generó un aumento en la amplitud de las oscilaciones y una reducción progresiva del margen de estabilidad. No obstante, la red mantuvo capacidad de recuperación en un porcentaje importante de las simulaciones, lo que sugiere que el sistema presentó características de resiliencia frente a perturbaciones moderadas.

B. Simulación Monte Carlo e incertidumbre paramétrica

Se generaron 1000 escenarios mediante simulación Monte Carlo utilizando combinaciones aleatorias de los parámetros físicos y operativos definidos en el modelo. La distribución de resultados evidenció que la mayoría de las simulaciones se concentró alrededor de estados de desempeño intermedios, mientras que una fracción menor presentó comportamientos extremos asociados con tiempos de recuperación prolongados y mayores pérdidas de desempeño.

La distribución probabilística del Índice de Antifragilidad Energética (EAI) mostró predominio de valores cercanos a cero, indicando que la mayoría de los escenarios simulados se comportó de manera resiliente, recuperando sus condiciones operativas sin mejoras sustanciales respecto al estado inicial. Sin embargo, se identificó un subconjunto de simulaciones con valores positivos de EAI, correspondientes a escenarios en los que determinadas combinaciones de parámetros permitieron una reorganización dinámica más eficiente después de la perturbación.

De forma igualmente relevante, se identificaron escenarios con valores negativos del índice, reflejando comportamientos frágiles en los cuales la red no logró recuperar completamente su desempeño previo. Este resultado evidenció que la respuesta del sistema dependió significativamente de la interacción entre la intensidad de las perturbaciones y la configuración paramétrica de la red.

La distribución probabilística del Índice de Antifragilidad Energética (EAI), presentada en la Figura 2, mostró una marcada concentración de escenarios en el intervalo comprendido entre 0,00 y 0,10, indicando que la mayoría de las configuraciones simuladas exhibió un comportamiento predominantemente resiliente. Asimismo, se identificó una fracción menor de simulaciones con valores negativos del índice, asociadas con respuestas frágiles y pérdidas de desempeño posteriores a la perturbación. Finalmente, se observó una cola positiva decreciente correspondiente a escenarios con características antifrágiles, lo que sugiere que la mejora posterior al evento adverso dependió de combinaciones específicas de parámetros físicos y operativos.




Fig. 2. Distribución probabilística del Índice de Antifragilidad Energética (EAI).

C. Análisis global de sensibilidad de los parámetros del modelo

Con el propósito de identificar los parámetros con mayor influencia sobre el comportamiento del sistema, se realizó un análisis global de sensibilidad mediante índices de Sobol de primer orden. La evaluación se efectuó considerando como variable de salida el Índice de Antifragilidad Energética (EAI), debido a que este indicador integró los efectos de la estabilidad, la capacidad de recuperación y el desempeño posterior a las perturbaciones.

La Figura 3 muestra los índices de sensibilidad obtenidos para los principales parámetros del modelo. Los resultados evidenciaron que la intensidad de acoplamiento (κ) constituyó el factor de mayor influencia sobre la variabilidad del EAI, alcanzando un índice de Sobol de 0,36. Este resultado indicó que pequeñas variaciones en la conectividad energética entre los nodos produjeron modificaciones significativas en la capacidad de adaptación y recuperación de la red.

La intensidad de las perturbaciones (ξ) presentó el segundo mayor nivel de influencia, con un índice de sensibilidad de 0,29. Este comportamiento sugirió que la magnitud de las fluctuaciones externas desempeñó un papel determinante en la evolución dinámica del sistema, particularmente en escenarios de elevada incertidumbre. Por su parte, la capacidad de recuperación (β) exhibió una contribución intermedia de 0,18, indicando que los mecanismos internos de restablecimiento energético participaron de manera relevante, aunque con menor incidencia que la estructura de acoplamiento y las perturbaciones.




Fig. 3. Índices globales de sensibilidad de Sobol para los parámetros del modelo.

En contraste, la tasa de amortiguamiento (γ) y la variabilidad de carga (η) mostraron índices de sensibilidad relativamente bajos, con valores de 0,11 y 0,06, respectivamente. Aunque estos parámetros influyeron sobre la dinámica del sistema, su contribución individual al comportamiento global del EAI resultó considerablemente menor en comparación con los parámetros dominantes.

Los resultados del análisis de sensibilidad indicaron que la dinámica de la red energética estuvo gobernada principalmente por la intensidad de acoplamiento y por la magnitud de las perturbaciones estocásticas. Estos hallazgos sugirieron que modificaciones relativamente pequeñas en la conectividad del sistema podrían inducir cambios significativos en su estabilidad y capacidad de adaptación. Debido a la elevada influencia observada para el parámetro de acoplamiento (κ), se consideró pertinente analizar su comportamiento mediante un estudio de bifurcaciones, con el propósito de identificar la posible existencia de umbrales críticos y transiciones cualitativas en la dinámica del sistema.

D. Análisis de sensibilidad y bifurcaciones dinámicas

El análisis global de sensibilidad mostró que la intensidad de acoplamiento entre nodos y la severidad de las perturbaciones fueron los parámetros con mayor influencia sobre el comportamiento del sistema. Los índices de Sobol indicaron que ambos factores explicaron la mayor proporción de la variabilidad observada en el tiempo de recuperación y en el índice EAI.

Adicionalmente, el análisis de bifurcaciones reveló la existencia de regiones críticas en las cuales pequeñas variaciones paramétricas produjeron cambios cualitativos en la dinámica de la red. Para valores reducidos de la intensidad de acoplamiento, el sistema presentó un único estado de equilibrio estable. Sin embargo, al superar un umbral crítico, se observaron transiciones hacia regímenes oscilatorios y estados múltiples de equilibrio.

La Figura 4 mostró el diagrama de bifurcación obtenido al variar sistemáticamente el parámetro de acoplamiento. Los resultados indicaron la presencia de regiones de estabilidad, zonas de transición y dominios caracterizados por comportamientos dinámicos más complejos. Estos hallazgos sugirieron que la estabilidad de la red energética no dependió exclusivamente de la magnitud de las perturbaciones, sino también de la posición del sistema respecto a determinados umbrales paramétricos.




Fig. 4. Diagrama de bifurcación de la red energética en función de la intensidad de acoplamiento (κ).

Desde la perspectiva de la ingeniería energética, la identificación de estos puntos críticos constituye un resultado de especial relevancia, ya que permite reconocer configuraciones operativas susceptibles de experimentar pérdidas abruptas de estabilidad ante cambios relativamente pequeños en las condiciones del sistema. El análisis de los autovalores de la matriz Jacobiana indicó modificaciones en las condiciones de estabilidad alrededor de $\kappa \approx 1,45$, coincidiendo con la aparición de múltiples estados de equilibrio observados en el diagrama de bifurcación.

CONCLUSIONES

La investigación permitió desarrollar un marco de modelado físico-computacional para el análisis de redes energéticas sometidas a perturbaciones estocásticas, integrando ecuaciones dinámicas no lineales, simulación Monte Carlo y análisis global de sensibilidad. Los resultados mostraron que el sistema presentó diferentes patrones de respuesta en función de la intensidad de las perturbaciones, desde trayectorias con rápida convergencia hacia el equilibrio hasta comportamientos oscilatorios persistentes asociados con escenarios de mayor incertidumbre. Estos hallazgos evidenciaron que la estabilidad de la red no dependió únicamente de la magnitud de las perturbaciones, sino también de la interacción entre las condiciones de operación y la estructura de acoplamiento del sistema.

La distribución probabilística del Índice de Antifragilidad Energética (EAI) reveló la coexistencia de comportamientos frágiles, resilientes y antifrágiles, predominando los escenarios resilientes caracterizados por la recuperación del desempeño sin mejoras sustanciales posteriores al evento adverso. Asimismo, la presencia de una fracción reducida de escenarios antifrágiles sugirió que determinadas configuraciones paramétricas permitieron una reorganización dinámica más eficiente de la red después de la perturbación. Estos resultados indicaron que la capacidad de adaptación del sistema emergió de combinaciones específicas de parámetros físicos y operativos, más que de la mera exposición a eventos extremos.

El análisis global de sensibilidad identificó la intensidad de acoplamiento y la magnitud de las perturbaciones como los principales factores responsables de la variabilidad del comportamiento dinámico del sistema. La elevada influencia del parámetro de acoplamiento justificó la realización del análisis de bifurcaciones, el cual permitió identificar un umbral crítico asociado con la aparición de múltiples estados de equilibrio y cambios cualitativos en la dinámica de la red. En conjunto, los resultados sugirieron que el estudio de las transiciones dinámicas y de los parámetros dominantes constituye una herramienta de gran utilidad para comprender la estabilidad de sistemas energéticos complejos bajo incertidumbre.

Finalmente, el marco propuesto presentó una aproximación reproducible para la exploración de relaciones entre estabilidad, recuperación y comportamiento emergente en redes energéticas complejas. No obstante, debido a que el modelo se desarrolló sobre una representación simplificada del sistema energético, los resultados deben interpretarse como evidencia inicial de carácter físico-computacional y no como una descripción exhaustiva de redes eléctricas reales. Se recomienda que investigaciones futuras incorporen topologías energéticas específicas, datos operativos reales y mecanismos adaptativos de mayor complejidad, con el propósito de profundizar en el estudio de las transiciones críticas y del comportamiento dinámico de sistemas energéticos sometidos a incertidumbre.

REFERENCIAS

- [1] O. P. Ovidiu, B. Dragos, and C. Emil, "Fractal and markov-based load modeling for multi-generator dispatch and protection in urban networks," *Annals of the West University of Timisoara. Physics Series*, vol. 67, no. 1, pp. 13–34, 2025.
- [2] C. Axenie, O. López-Corona, M. A. Makridis, M. Akbarzadeh, M. Saveriano, A. Stancu, and J. West, "Antifragility in complex dynamical systems," *npj Complexity*, vol. 1, no. 1, p. 12, 2024.
- [3] X. Gao, M. Peng, K. T. Chi, and H. Zhang, "A stochastic model of cascading failure dynamics in cyber-physical power systems," *IEEE Systems Journal*, vol. 14, no. 3, pp. 4626–4637, 2020.
- [4] H. Liang, B. Moya, F. Chinesta, and E. Chatzi, "A multi-model probabilistic framework for seismic risk assessment and retrofit planning of electric power networks," *Reliability Engineering & System Safety*, vol. 268, p. 112001, 2025.
- [5] P. Saisridhar, M. Thuerer, and B. Avittathur, "Assessing supply chain responsiveness, resilience and robustness (Triple-R) by computer simulation: a systematic review of the literature," *International Journal of Production Research*, vol. 62, no. 4, pp. 1458–1488, 2024.
- [6] D. Coppitters and F. Contino, "Optimizing upside variability and antifragility in renewable energy system design," *Scientific Reports*, vol. 13, no. 1, p. 9138, 2023.
- [7] M. A. Polo-González, A. P. Riascos, and L. K. Eraso-Hernandez, "Antifragility and response to damage in the synchronization of oscillators on networks," *Journal of Physics A: Mathematical and Theoretical*, vol. 58, no. 22, p. 225002, 2025.

- [8] Z. Hu, J. Hou, Y. Su, Y. Wang, W. Dai, and J. Yang, "Public health safety governance and system resilience in petrochemical plants based on STAMP/STPA and complex networks: A case study from china," *Sustainability*, vol. 18, p. 3754, 2026.
- [9] X. Wu, Y. Cao, H. Wu, S. Qi, M. Zhao, Y. Feng, and Q. Yu, "Hybrid learning-based fault prediction and cascading failure mitigation in multi-network energy systems," *Scientific Reports*, vol. 15, no. 1, p. 33938, 2025.
- [10] C. Zhang, Y. Xu, Y. Chen, and Y. Gan, "Coupling modelling and fault propagation simulation method for power grid-centric urban lifeline systems under extreme disasters," *Energy Internet*, vol. 2, no. 3, pp. 255–273, 2025.
- [11] B. Li, D. Liu, J. Fang, X. Zhang, and C. K. Tse, "Failure propagation graphs for studying cascading failure propagation in power networks," *IEEE Systems Journal*, vol. 19, no. 1, pp. 258–269, 2025.

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.

F. 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.

Artículo de investigación

<https://doi.org/10.47460/athenea.v7i24.146>

Plataforma multirrobot para la enseñanza remota de robótica en entornos virtuales

Javier Alexander Castro Haro
<https://orcid.org/0000-0003-3297-7812>
jacastroh@uce.edu.ec / jach1404_@hotmail.com
Universidad Central del Ecuador, Facultad de
Ingeniería y Ciencias Aplicadas
Quito, Ecuador

Jorge Mauricio Fuentes Fuentes
<https://orcid.org/0000-0003-0342-643X>
mfuentes@uce.edu.ec
Universidad Central del Ecuador, Facultad de
Ingeniería y Ciencias Aplicadas
Quito, Ecuador

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

Recibido: (03/03/2026), Aceptado: (18/06/2026)

Resumen. Este trabajo evalúa el desempeño técnico y el impacto pedagógico de una plataforma multirrobot remota basada en una arquitectura centralizada para la enseñanza de IoT y visión artificial. La viabilidad técnica de la plataforma se validó mediante un análisis de calidad de servicio (QoS) en diferentes entornos de conectividad residencial, evidenciando un funcionamiento estable con niveles adecuados de latencia, *jitter* y pérdida de paquetes. Se implementó un diseño cuasi-experimental con 56 estudiantes distribuidos en dos grupos: ESPE, que utilizó la plataforma multirrobot, e ISUCT, que empleó simuladores basados en *software*. Los resultados mostraron diferencias significativas a favor de la ESPE en el rendimiento académico global, así como mayores niveles de satisfacción estudiantil. Adicionalmente, IoT presentó mejores resultados que visión artificial en ambas instituciones debido a su menor complejidad cognitiva. Los hallazgos respaldan el uso de laboratorios remotos basados en sistemas ciber-físicos como una alternativa efectiva para fortalecer la formación práctica.

Palabras clave: sistemas ciber-físicos, robótica colaborativa, internet de las cosas, educación.

Multi-Robot Platform for Remote Robotics Teaching in Virtual Environments

Abstract. This study evaluates the technical performance and pedagogical impact of a remote multi-robot platform based on a centralized architecture for teaching IoT and artificial vision. The technical feasibility of the platform was validated through a quality of service (QoS) analysis in different residential connectivity environments, showing stable operation with adequate levels of latency, *jitter*, and packet loss. A quasi-experimental design was implemented with 56 students distributed into two groups: ESPE, which used the multi-robot platform, and ISUCT, which used *software*-based simulators. The results showed significant differences in favor of ESPE in overall academic performance, as well as higher levels of student satisfaction. Additionally, IoT showed better results than artificial vision in both institutions due to its lower cognitive complexity. The findings support the use of remote laboratories based on cyber-physical systems as an effective alternative to strengthen practical training.

Keywords: cyber-physical systems, collaborative robotics, internet of things, education.

I. INTRODUCCIÓN

La educación 4.0 y los sistemas ciber-físicos (CPS) integran procesos computacionales y físicos para mejorar la formación técnica [1], [2]. En este contexto, los sistemas multirrobot (MRS) permiten resolver tareas mediante trabajo colaborativo, ofreciendo mayor robustez, redundancia y eficiencia que los agentes individuales [3], [4]. Asimismo, los laboratorios virtuales y remotos se han consolidado como herramientas esenciales, al facilitar la experimentación práctica desde cualquier ubicación y superar las barreras de tiempo y espacio físico [5], [6].

Sin embargo, la enseñanza de la robótica enfrenta limitaciones significativas debido a su elevado costo y a la falta de flexibilidad del *hardware* y *software* propietarios [7]. Aunque el uso de simuladores es común, persiste una brecha crítica entre la teoría y la práctica en entornos de trabajo colaborativo real ejecutados a distancia [7]. Por tanto, existe la necesidad de evaluar plataformas centralizadas de enseñanza remota que validen, de manera simultánea, tanto su viabilidad técnica como su impacto pedagógico real en estudiantes con diversos perfiles de formación [4].

A diferencia de trabajos previos como [8], orientado exclusivamente al diseño e implementación de la plataforma multirrobot, y [9], enfocado en la descripción de sus características CPS y su aplicación educativa general, esta investigación no propone una nueva plataforma. La contribución fundamental de este artículo consiste en evaluar cuantitativa y cualitativamente el desempeño técnico y el impacto pedagógico de la plataforma desarrollada por [8], al ser utilizada como un entorno de enseñanza remota de robótica en la educación superior.

Para cumplir con este propósito, se realizó un análisis cuantitativo comparativo con 56 estudiantes en Ecuador, distribuidos equitativamente entre la Universidad de las Fuerzas Armadas ESPE y el Instituto Superior Tecnológico Central Técnico (ISUCT). La evaluación se organizó en tres frentes: 1) calidad del servicio (QoS), enfocada en evaluar el trayecto desde la interfaz del estudiante, pasando por los canales de comunicación, hasta llegar al bróker MQTT y los agentes robóticos implementados por [9]; 2) rendimiento pedagógico, orientado a cuantificar el desarrollo de competencias técnicas y la asimilación de conceptos complejos [8]; y 3) calidad de la experiencia (QoE) y percepción del estudiante, con el fin de evaluar la interacción del alumno desde el hogar a través de cinco dimensiones: QoE frente a retardos de la red, usabilidad del sistema, carga cognitiva percibida, autoeficacia y transferencia de competencias en IoT y visión artificial, y motivación-compromiso pedagógico del estudiante.

Este estudio se justifica en la validación de una plataforma que integra el aprendizaje basado en proyectos y el enfoque constructivista, donde el estudiante construye su conocimiento mediante la interacción remota con agentes robóticos reales. Al contrastar los resultados entre dos instituciones de educación superior, el artículo aporta datos valiosos sobre la adaptabilidad de los sistemas CPS para fortalecer las capacidades académicas en el marco de la cuarta revolución industrial [5].

II. MARCO TEÓRICO

A. Educación 4.0 y sistemas ciber-físicos

La educación 4.0 integra procesos computacionales y físicos para mejorar la interacción en la formación técnica, en sintonía con los principios de la cuarta revolución industrial [9]. Un sistema ciber-físico (CPS) se define como una integración sinérgica de algoritmos computacionales y componentes físicos, donde el mundo digital interactúa directamente con el mundo físico mediante una red de sensores y actuadores [4]. A diferencia de los sistemas mecatrónicos tradicionales, los CPS representan una evolución orientada a la simbiosis entre las partes físicas y cibernéticas del sistema, y se estructuran sobre tres pilares: inteligencia computacional, sensores y control, y comunicación/conectividad con la nube [4].

En el contexto de la robótica, estos sistemas se dividen en subsistemas de sensores y actuadores con gestión de datos en tiempo real, control de red para la gestión de robots múltiples (MRS) y una interfaz hombre-máquina (HMI), que puede incluir realidad virtual o aumentada [4].

B. Sistemas multirrobot (MRS)

El sistema multirrobot (MRS) corresponde a un grupo de robots que trabajan en el mismo entorno persiguiendo un objetivo bien definido, donde la verdadera capacidad del sistema reside en la cooperación

entre los agentes [4]. Frente a un sistema de un solo robot, un MRS ofrece menor costo por unidad y mayor redundancia gracias a mecanismos de tolerancia a fallos. No obstante, también introduce limitaciones propias: la calidad de la comunicación puede verse afectada por restricciones de ancho de banda, retardos elevados y conflictos entre algoritmos de coordinación, mientras que la escalabilidad puede comprometerse conforme aumenta el número de agentes conectados [4].

Desde el punto de vista de la arquitectura de decisión, los MRS se clasifican en centralizados, jerárquicos, descentralizados e híbridos. En una arquitectura centralizada, un único nodo recolecta la información de estado de los demás robots y emite las órdenes de control correspondientes. Esta arquitectura simplifica la coordinación y resulta especialmente pertinente para fines didácticos, ya que concentra la lógica del sistema en un punto observable y modificable por el estudiante. Sin embargo, introduce un punto único de fallo y puede limitar la escalabilidad por restricciones de ancho de banda y capacidad de cómputo del nodo central [4].

El diseño de plataformas de este tipo se enmarca, además, en la metodología VDI 2206, que establece un macrociclo de tipo modelo en V para el desarrollo de sistemas mecatrónicos, dividiendo el proceso en diseño del sistema a nivel general, diseño en dominios específicos, como mecánica, electricidad y tecnologías de la información, e integración final, con ciclos continuos de modelado, verificación y validación [10]. La misma lógica de diseño modular se encuentra en otras plataformas robóticas educativas, como el dimensionamiento mecánico de una plataforma móvil con brazo manipulable orientada a la docencia [10], el desarrollo de un manipulador didáctico de cinco grados de libertad operable de forma local y remota [11], y el robot antropomórfico de seis grados de libertad de *hardware* y *software* abiertos integrados con ROS [7]. En conjunto, estos antecedentes evidencian una línea consolidada de plataformas CPS de bajo costo para la enseñanza de la robótica en universidades de países en desarrollo.

C. Comunicación, protocolo MQTT y latencia

La conectividad de los sistemas multirrobot modernos se sustenta en arquitecturas de IoT, que permiten la interconexión de dispositivos y el intercambio de información a escala global [9]. El protocolo predilecto para estas aplicaciones es MQTT, basado en una arquitectura de publicación/suscripción en la que un bróker central coordina el flujo de mensajes entre los robots, que actúan como publicadores, y la estación de control, que actúa como suscriptora. Este protocolo destaca por su bajo costo computacional, su eficiencia energética y la posibilidad de implementar capas de seguridad mediante autenticación y puertos cifrados [9].

Desde la clasificación general de la comunicación en MRS, esta corresponde a un esquema de comunicación explícita, en el que los robots intercambian directamente mensajes de datos a través de dispositivos de comunicación, combinado con una arquitectura centralizada de tipo cliente-servidor mediada por el bróker MQTT [4]. La literatura advierte que la comunicación exige un marco de control para garantizar la conectividad de la red y seleccionar un protocolo adecuado, y que su desempeño se degrada conforme aumenta el número de robots y la distancia de comunicación. Esto resulta especialmente relevante cuando el enlace no se limita a un laboratorio local, sino que se extiende a las redes domésticas de los estudiantes [4].

La pertinencia de evaluar la latencia radica en que, en aplicaciones de teleoperación, el retardo de comunicación condiciona directamente la calidad de la experiencia. Retardos elevados generan un desfase perceptible entre la orden enviada y la acción del robot, incrementando la carga cognitiva del usuario y la probabilidad de frustración operativa. Por ello, la literatura sobre comunicación en MRS identifica la baja calidad de comunicación, el ancho de banda limitado, la alta latencia y los conflictos de coordinación como algunas de las limitaciones estructurales más relevantes de estos sistemas [4]. El umbral de 300 ms para el control de teleoperación en tiempo real se enmarca en la calidad de la comunicación como condición habilitante del aprendizaje en plataformas robóticas remotas [4].

D. Laboratorios virtuales y remotos como entornos de enseñanza de robótica

Los laboratorios virtuales y remotos se han consolidado como herramientas esenciales para facilitar la experiencia práctica en ingeniería desde cualquier ubicación, superando las barreras de tiempo y espacio físico que tradicionalmente han limitado el acceso a equipos de robótica costosos o de *hardware* y *software* propietarios [9]. La enseñanza de la robótica enfrenta, en efecto, limitaciones significativas derivadas del costo elevado de los manipuladores y plataformas móviles comerciales, así como de la

rigidez de sus arquitecturas cerradas, lo que ha motivado el desarrollo de alternativas de bajo costo, código abierto y fácilmente replicables [9].

Esta línea de trabajo se observa de manera consistente en los antecedentes revisados. La estación de trabajo didáctica con un manipulador de cinco grados de libertad, operable tanto de forma local, mediante potenciómetros, como remota, mediante una aplicación móvil con Bluetooth [12], constituye un primer acercamiento a la operación remota de un robot educativo. Por su parte, el robot antropomórfico de seis grados de libertad, basado en *hardware* y *software* abiertos y concebido para recibir y enviar información mediante estándares como MQTT o CoAP [7], avanza hacia una arquitectura integrada con IoT.

Sin embargo, la disponibilidad de una plataforma tecnológica adecuada no garantiza por sí sola su impacto pedagógico [13]. La revisión sistemática sobre la formación docente en tecnologías emergentes en educación superior identifica que las barreras más recurrentes para la integración efectiva de este tipo de herramientas no son únicamente técnicas, sino que incluyen la ausencia de estrategias didácticas específicas en el proceso de enseñanza-aprendizaje y la limitada formación académica del docente para impartir la práctica de laboratorio [13]. En consecuencia, no basta con validar la viabilidad técnica del sistema multirrobot, en términos de conectividad, precisión y latencia [4], [9]; también resulta indispensable evaluar su impacto pedagógico real, el rendimiento académico y la satisfacción en estudiantes con perfiles de formación y condiciones de acceso distintas, así como el papel que juega la disponibilidad temporal del estudiante como variable que media la apropiación efectiva de la tecnología [13].

Desde la dimensión pedagógica, el aprendizaje basado en proyectos y el constructivismo sostienen que el conocimiento se construye de manera activa a partir de la experiencia del estudiante con el objeto de aprendizaje, en contraposición a modelos de transmisión exclusivamente teóricos [13]. Bajo esta lógica, la investigación del robot antropomórfico de seis grados de libertad reportó mejoras entre el 40,74% y el 186,96% en competencias técnicas asociadas a parámetros Denavit-Hartenberg, cinemática, dimensionamiento de actuadores y programación en ROS [7].

III. METODOLOGÍA

La investigación adoptó un enfoque de métodos mixtos, con diseño cuasi-experimental, para evaluar la calidad del servicio en la plataforma multirrobot, el impacto académico y la percepción tecnológica asociada al uso de una plataforma robótica remota.

A. Calidad de servicio (QoS) en el sistema CPS remoto

El sistema fue desarrollado por [8] y consta de tres robots móviles omnidireccionales con ruedas Mecanum. El *hardware* integra un Arduino para el control de bajo nivel, correspondiente a motores y sensores, y una Raspberry Pi como nodo maestro con ROS, con una autonomía de 85 minutos. La comunicación con la estación base emplea el protocolo MQTT bajo una arquitectura centralizada tipo *Learning Factory*. La Fig. 1 muestra un esquema del sistema multirrobot utilizado en este estudio.




Fig. 1. Esquema del sistema multirrobot. Adaptado de [8].

Para evaluar la viabilidad de la plataforma distribuida de tres robots omnidireccionales, operados

como un sistema ciber-físico (CPS) educativo para los módulos de IoT y visión artificial, se estructuró un protocolo de caracterización experimental de la calidad de servicio (QoS) en la red de transporte.

Al trasladar la experiencia desde el laboratorio de la universidad hasta los hogares de una muestra de 28 estudiantes de la Universidad de las Fuerzas Armadas ESPE, el canal de comunicación se convierte en una variable estocástica no ideal. El sistema fue evaluado bajo tres tecnologías de acceso: red móvil 4G/LTE, red privada doméstica de cobre ADSL/HFC y red doméstica de fibra FTTH. En cada una de ellas se analizaron el tiempo de ida y vuelta (RTT), el *jitter* y el *throughput*.

B. Análisis cuantitativo

Se trabajó con una muestra de 56 estudiantes que recibieron un curso de robótica, enfocado en visión artificial e IoT. De ellos, 28 estudiantes pertenecieron al Instituto Superior Tecnológico Central Técnico (ISUCT), quienes emplearon simuladores de *software*, específicamente Python + OpenCV para visión artificial y Node-RED + ESP32 para IoT. Los otros 28 estudiantes pertenecieron a la Universidad de las Fuerzas Armadas ESPE, quienes operaron el sistema multirrobot ciber-físico remoto. Ambos grupos recibieron 20 horas de clases sincrónicas y 10 horas de práctica en sus respectivos entornos de aprendizaje.

En ambos grupos se empleó el mismo equipo docente para la impartición de las asignaturas, asegurando la aplicación de una estrategia pedagógica equivalente. Asimismo, se mantuvieron similares el cronograma de actividades prácticas, los contenidos curriculares y los criterios de evaluación. El procesamiento de las variables dependientes, correspondientes al rendimiento académico y la satisfacción, se ejecutó en Minitab mediante tres etapas secuenciales.

En primer lugar, se midió la línea base mediante un pretest y se validó la homogeneidad inicial intergrupo e intragrupo a través de las pruebas de Shapiro-Wilk y t de Student, tanto para muestras independientes como pareadas. En segundo lugar, tras registrar las notas finales del curso, se verificaron los supuestos matemáticos de normalidad y homocedasticidad mediante las pruebas de Shapiro-Wilk y Levene. Finalmente, se analizaron los efectos globales e internos mediante pruebas t de Student, determinando además el tamaño del efecto mediante la d de Cohen. Complementariamente, se modeló un ANOVA de dos vías para examinar los efectos principales y de interacción de segundo orden entre los factores "Entorno de aprendizaje" y "Materia" sobre el éxito académico.

C. Análisis cualitativo

Se aplicó una encuesta Likert de 5 puntos, compuesta por 12 reactivos y basada en el modelo TAM, con el propósito de evaluar cinco dimensiones: calidad de experiencia (QoE), facilidad de uso del sistema, carga cognitiva percibida, autoeficacia y transferencia de competencias, y motivación y compromiso. La confiabilidad del instrumento se validó mediante el alfa de Cronbach. Posteriormente, se realizó estadística descriptiva por dimensiones y se aplicó la prueba no paramétrica U de Mann-Whitney para comparar las medianas de satisfacción entre grupos.

D. Consideraciones éticas

Todos los estudiantes participantes en este estudio técnico-pedagógico otorgaron su consentimiento informado por escrito antes del inicio del experimento, autorizando el uso académico de sus calificaciones y respuestas. La información fue tratada de manera confidencial y utilizada exclusivamente con fines investigativos.

IV. RESULTADOS

A. Análisis de la calidad de servicio (QoS) residencial

La viabilidad operativa de la plataforma ciber-física (CPS) de tres robots para la enseñanza de IoT y visión artificial se validó midiendo la calidad de servicio (QoS) en la capa de aplicación, específicamente en el puerto TCP 1883, tras 250 iteraciones residenciales. Los resultados se presentan en la Tabla 1.

Tabla 1. Resultados consolidados de las métricas de QoS por tecnología de acceso residencial.

Entorno de conectividad	Ancho de banda	Latencia (RTT)	Desviación estándar (SD)	Jitter promedio (σ_J)	Throughput real medido	Tasa de pérdida de paquetes
Red móvil celular (4G/LTE)	1,0 Mbps	124,4 ms	$\pm 12,1$ ms	4,3 ms	42,5 kbps	1,20%
Red privada doméstica de cobre (ADSL/HFC)	6,0 Mbps	234,2 ms	$\pm 28,5$ ms	9,1 ms	48,1 kbps	4,85%
Fibra óptica de hogar (FTTH)	50,0 Mbps	45,8 ms	$\pm 3,2$ ms	1,1 ms	31,2 kbps	0,05%

La Tabla 1 muestra que la red móvil 4G/LTE registró una latencia eficiente de 124,4 ms y un bajo *jitter* de 4,3 ms, debido a su enrutamiento directo, que evita colisiones locales. Esto permitió que MQTT mitigara el bajo ancho de banda y que la escasa pérdida de paquetes, equivalente al 1,20%, previniera la saturación del bróker. Por el contrario, la red de cobre exhibió una latencia elevada de 234,2 ms y un *jitter* de 9,1 ms, debido a la atenuación y congestión doméstica, que causaron un 4,85% de pérdida de paquetes e indujeron el fenómeno de bloqueo de cabecera en la capa TCP, sin colapsar el bróker.

Finalmente, la fibra óptica ofreció un escenario ideal, con 45,8 ms de latencia e inmunidad a ruidos. De este modo, se demuestra que incluso en el peor escenario, correspondiente a la red de cobre, el retardo no supera el umbral psicofisiológico humano de los 300 ms. El protocolo ligero MQTT permitió la viabilidad de las prácticas en la plataforma multirrobot utilizada, sin degradar la experiencia por retardos perceptibles.

B. Análisis cuantitativo

La prueba de Shapiro-Wilk confirmó la distribución normal de las calificaciones del pretest, tanto en la ESPE ($p > 0,100$) como en el ISUCT ($p > 0,100$). Posteriormente, el contraste de hipótesis mediante una prueba t de Student para muestras independientes, con corrección de Welch, determinó que no existieron diferencias estadísticamente significativas entre los conocimientos previos de ambas instituciones ($t_{53} = 0,66$; $p = 0,513$) en IoT y visión artificial. Por tanto, los promedios del pretest para los estudiantes de la ESPE ($\bar{X} = 26,07$) y del ISUCT ($\bar{X} = 24,64$) representan un punto de partida cognitivo equivalente antes del experimento.

Adicionalmente, se evaluó mediante una prueba t pareada la existencia de brechas cognitivas entre las disciplinas antes del curso. Los análisis intragrupo determinaron que el nivel de conocimiento diagnóstico entre IoT y visión artificial fue estadísticamente equivalente tanto en los estudiantes de la ESPE ($\bar{X}_{IoT} = 27,86$; $\bar{X}_{Visión\ Artificial} = 24,29$; $t_{27} = 1,22$; $p = 0,232$) como en los estudiantes del ISUCT ($\bar{X}_{IoT} = 25,71$; $\bar{X}_{Visión\ Artificial} = 23,57$; $t_{27} = 0,68$; $p = 0,501$).

Luego de impartir el curso de robótica, se evaluó la normalidad de las calificaciones de los estudiantes del ISUCT y de la ESPE mediante la prueba de Shapiro-Wilk. Con un nivel de significancia del 95% y un valor de $p > 0,100$ para ambos grupos, se confirmó que los datos de las notas en ambas instituciones siguen una distribución normal.

La prueba de Levene confirmó la homogeneidad de varianzas en las calificaciones ($Levene(3, 108) = 0,30$; $p = 0,587$). Desde una perspectiva didáctica, esta igualdad de varianzas evidencia que la variabilidad del rendimiento académico se mantuvo uniforme y controlada. Esto confirma que ni la naturaleza abstracta de los simuladores basados en *software*, como Python/OpenCV y Node-RED, utilizados en el ISUCT, ni la complejidad de la teleoperación y la latencia de red de la plataforma ciber-física (CPS) utilizada en la ESPE introdujeron dispersiones anómalas o descontroladas en el proceso de evaluación.

La prueba t de Student para muestras independientes confirmó una diferencia estadísticamente significativa en el rendimiento global ($t_{53} = -8,42$; $p < 0,001$; $d = -2,25$). Los estudiantes de la ESPE, potenciados por la plataforma ciber-física, alcanzaron un promedio final superior ($\bar{X} = 86,45$; $SD = 6,75$; 60,38% de mejora respecto al pretest), frente a los estudiantes del ISUCT, limitados al uso de simuladores ($\bar{X} = 71,61$; $SD = 6,44$; 46,97% de mejora). Esto representa un rendimiento académico neto 14,84% mayor a favor de los estudiantes de la ESPE, como se muestra en la Fig. 2.




Fig. 2. Gráfica de cajas de las notas promedio de ESPE e ISUCT.

Dado que los estudiantes de ambas instituciones recibieron la misma formación, impartida por el mismo equipo docente, con idénticos contenidos curriculares, carga horaria y criterios de evaluación, la diferencia observada en el rendimiento puede atribuirse con alto grado de confianza al entorno de aprendizaje empleado. Aunque ambos grupos mejoraron su desempeño, lo que confirma la efectividad del módulo teórico común, los estudiantes de la ESPE alcanzaron resultados significativamente superiores, evidenciando los beneficios pedagógicos de la plataforma multirrobot ciber-física.

A diferencia de los simuladores, que permiten validar algoritmos en entornos controlados y reproducibles, la plataforma proporcionó experiencias de aprendizaje sobre sistemas físicos reales, enfrentando a los estudiantes a desafíos característicos de aplicaciones de IoT y visión artificial, como variaciones en la iluminación, procesamiento de imágenes en tiempo real, latencias de comunicación y comportamiento dinámico de sensores y actuadores. Estas condiciones enriquecieron la experiencia formativa, fortalecieron las competencias prácticas y favorecieron una comprensión más profunda de la integración entre *hardware* y *software*, respaldando la plataforma como una estrategia pedagógica más efectiva para el aprendizaje de la robótica.

El análisis intragrupo realizado mediante la prueba t de Student para muestras pareadas evidenció diferencias significativas entre los módulos de IoT y visión artificial en ambas instituciones. En el ISUCT, los estudiantes obtuvieron un mejor desempeño en IoT ($\bar{X} = 77,01$; $SD = 6,03$) que en visión artificial ($\bar{X} = 66,21$; $SD = 9,82$), con una diferencia estadísticamente significativa ($t_{27} = -5,73$; $p < 0,001$; $d = 1,08$). De manera similar, en la ESPE se observaron diferencias significativas a favor de IoT ($\bar{X} = 92,77$; $SD = 5,26$) frente a visión artificial ($\bar{X} = 80,13$; $SD = 12,36$), con $t_{27} = -5,00$, $p < 0,001$ y $d = -0,94$.

Estos resultados sugieren que la asignatura de visión artificial implicó mayores exigencias cognitivas, asociadas al procesamiento digital de imágenes, la selección y configuración de dispositivos de captura, la extracción de características y la interpretación de resultados visuales. Adicionalmente, el uso exclusivo de simuladores pudo haber limitado la comprensión práctica de algunos fenómenos visuales. Por otro lado, la mejora observada en la ESPE indica que el uso de laboratorios remotos basados en sistemas ciber-físicos puede mitigar parcialmente estas dificultades y favorecer una mayor transferencia entre teoría y práctica. En conjunto, los resultados sugieren que las diferencias de rendimiento estuvieron determinadas principalmente por la complejidad inherente de la disciplina y por las características del entorno de aprendizaje, más que por diferencias en los conocimientos previos de los estudiantes.

El análisis ANOVA de dos factores evidenció un efecto altamente significativo del entorno de aprendizaje sobre el rendimiento académico ($F(1, 108) = 78,81$; $p < 0,001$). Los estudiantes que realizaron las prácticas mediante la plataforma multirrobot centralizada, correspondiente a la ESPE, obtuvieron calificaciones superiores a aquellos que trabajaron exclusivamente con simuladores, correspondientes al ISUCT, lo que indica que la interacción con sistemas ciber-físicos reales favorece la comprensión y

aplicación de los contenidos abordados.

Asimismo, el factor asignatura presentó un efecto significativo ($F(1, 108) = 49,12; p < 0,001$), observándose un mejor desempeño en IoT que en visión artificial, independientemente del entorno de aprendizaje práctico utilizado. Este comportamiento puede atribuirse a la mayor complejidad cognitiva asociada al procesamiento de imágenes, la calibración de parámetros y la interpretación de información visual en tiempo real. Por otra parte, la interacción entre el entorno de aprendizaje y la asignatura no fue significativa ($F(1, 108) = 0,30; p = 0,585$), indicando que ambos factores actuaron de manera independiente. En consecuencia, la ventaja proporcionada por la plataforma multirrobot se mantuvo de forma consistente tanto para IoT como para visión artificial, evidenciando que los beneficios del laboratorio remoto basado en sistemas ciber-físicos son aplicables a distintas áreas de formación en robótica.

C. Análisis cualitativo

La consistencia interna del instrumento de satisfacción fue evaluada mediante el coeficiente alfa de Cronbach, obteniendo un valor de $\alpha = 0,8059$, lo que demuestra una alta confiabilidad y validez de la encuesta para el análisis de percepción del curso de robótica, cuyos módulos fueron visión artificial e IoT.

Se realizó el cálculo de medias y desviaciones estándar indexadas por institución educativa y dimensión académica. Los resultados se muestran en la Tabla 2.

Tabla 2. Análisis descriptivo de la percepción de satisfacción estudiantil por dimensiones.

Dimensión Académica	Institución	Entorno de Aprendizaje Práctico	Muestra (n)	Media ($\bar{X}$)	Desviación Estándar (SD)
Calidad de Experiencia	ESPE	Plataforma multirrobot	28	4,1667	0,5092
	ISUCT	Simulador	28	4,8810	0,2600
Facilidad de uso del sistema	ESPE	Plataforma multirrobot	28	4,6310	0,4567
	ISUCT	Simulador	28	4,6905	0,4344
Carga cognitiva percibida	ESPE	Plataforma multirrobot	28	4,464	0,543
	ISUCT	Simulador	28	3,268	0,700
Autoeficacia y Transferencia de competencias	ESPE	Plataforma multirrobot	28	4,8929	0,2842
	ISUCT	Simulador	28	3,036	0,607
Motivación y Compromiso	ESPE	Plataforma multirrobot	28	4,7857	0,3951
	ISUCT	Simulador	28	4,071	0,703

El análisis descriptivo de la encuesta, presentado en la Tabla 2, reveló la mejora pedagógica en la enseñanza de la robótica mediante la plataforma multirrobot centralizada aplicada en la ESPE, en comparación con el uso de simuladores en el ISUCT. En la dimensión calidad de la experiencia (QoE), el ISUCT obtuvo una puntuación superior frente a la ESPE. Este comportamiento se debe a que los programas de simulación carecen de la latencia y las fluctuaciones de red intrínsecas en la teleoperación de la arquitectura real, aunque la plataforma se mantuvo con éxito dentro del umbral de aceptación.

Por el contrario, la dimensión facilidad de uso del sistema demostró una homogeneidad estadística

entre el entorno multirrobot utilizado en la ESPE y el manejo de programas de simulación empleados en el ISUCT, lo que confirma que el panel de control de la plataforma multirrobot es tan intuitivo y ergonómico como los programas comerciales consolidados.

En el análisis de carga cognitiva percibida, la ESPE superó al ISUCT, indicando una mayor capacidad de los estudiantes para mitigar el estrés y facilitar la depuración de errores. Asimismo, la autoeficacia y transferencia de competencias fue superior en la ESPE con relación al ISUCT, demostrando que interactuar con restricciones físicas reales prepara mejor para la industria que el uso exclusivo de un programa comercial.

La última dimensión analizada fue la motivación y compromiso, la cual validó la preferencia por el uso de la plataforma multirrobot sobre el enfoque tradicional de simulación en pantalla, demostrando que el uso de agentes físicos incrementa el interés de los estudiantes por la investigación en el área de la robótica y la automatización.

El análisis inferencial de la percepción estudiantil global, ejecutado mediante la prueba no paramétrica U de Mann-Whitney, demostró una diferencia estadísticamente significativa entre instituciones que utilizaron diferente entorno de aprendizaje práctico ($W = 1043,00$; $p < 0,001$). Los estudiantes de la ESPE que operaron la plataforma multirrobot ciber-física registraron una mediana de satisfacción global superior ($Me = 4,5000$), en comparación con aquellos que utilizaron entornos de simulación en el ISUCT ($Me = 4,20833$).

Este hallazgo cualitativo se alinea de manera simétrica con los resultados cuantitativos de rendimiento académico obtenidos en el ANOVA de dos vías ($p < 0,001$). La convergencia de ambos análisis demuestra que el modelo de despliegue tecnológico no solo afecta la capacidad del estudiante para obtener mejores calificaciones, sino que transforma de manera integral su experiencia y aceptación de la plataforma multirrobot.

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] O. Peña Cáceres, H. Silva-Marchan, R. Espinoza-Nima, and M. More-More, "Sistemas ciber-físicos en la educación del siglo XXI," *European Public & Social Innovation Review*, vol. 10, pp. 1-19, 2024.
- [2] E. Jiménez López, L. A. García Velásquez, L. O. Amavizca Valdez, D. Y. Wong Pacheco, S. Valdez Tribolet, and M. d. R. Mafara Duarte, "Educación en ingeniería 4.0 y la mecatrónica," in *Kaizen Mecatrónica*, 2023, ch. 30, pp. 387-396.
- [3] D. E. Gonzalez Bonifaz, A. D. C. Verdugo Cabrera, L. F. Escobar Carvajal, and D. C. Loza Matovelle, "Implementation of an IoT architecture based on MQTT for a multi-robot system," in *2018 IEEE Third Ecuador Technical Chapters Meeting (ETCM)*. Cuenca, Ecuador: IEEE, 2018, pp. 1-6.
- [4] X. An, C. Wu, Y. Lin, M. Lin, T. Yoshinaga, and Y. Ji, "Multi-robot systems and cooperative object transport: Communications, platforms, and challenges," *IEEE Open Journal of the Computer Society*, vol. 4, pp. 23-36, 2023.
- [5] C. A. Jara, F. A. Candelas, S. T. Puente, and F. Torres, "Hands-on experiences of undergraduate students in automatics and robotics using a virtual and remote laboratory," *Computers & Education*, vol. 57, no. 4, pp. 2451-2461, 2011.
- [6] V. Potkonjak *et al.*, "Virtual laboratories for education in science, technology, and engineering: A review," *Computers & Education*, vol. 95, pp. 309-327, 2016.
- [7] J. Galarza, L. Escobar, and D. Loza, "6 DOF anthropomorphic robot as a platform for teaching robotics," in *2020 IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM)*, 2020, pp. 631-636.
- [8] L. Allauca and G. Aguirre, "Diseño e implementación de un sistema multirobot para trabajos colaborativos dotado de planificación de trayectoria con arquitectura IoT," Trabajo de grado, Universidad de las Fuerzas Armadas ESPE, Quito, Ecuador, 2020.
- [9] L. Escobar, C. Moyano, G. Aguirre, G. Guerra, L. Allauca, and D. Loza, "Multi-robot platform with features of cyber-physical systems for education applications," in *2020 IEEE ANDESCON*. Quito, Ecuador: IEEE, 2020, pp. 1-6.
- [10] O. Flor, M. Fuentes, and C. Toapanta, "Criteria for the design of an educational robotics platform," *Athenea Engineering Sciences Journal*, vol. 1, no. 1, pp. 29-40, 2020.
- [11] J. Ortiz-Mata and A. León-Batalla, "Diseño e implementación de un robot manipulador de cinco grados de libertad para una estación de trabajo didáctica," *Universidad, Ciencia y Tecnología*, vol. 22, no. 87, pp. 6-6, 2018.
- [12] —, "Diseño e implementación de un robot manipulador de cinco grados de libertad para una estación de trabajo didáctica," *Universidad, Ciencia y Tecnología*, vol. 22, no. 87, pp. 6-6, 2018.
- [13] E. J. Colonia Villarreal, "A systematic review of barriers and solutions in teacher training in artificial intelligence," *Minerva*, vol. 7, no. 20, pp. 13-24, 2026.


$$u(x, t) = \sum_{i=1}^n \phi_i(x) q_i(t)$$

$$\frac{\partial}{\partial t} (M(q)\dot{q}) + C(q, \dot{q})\dot{q} + K(q)q \\ = \tau_{ext}(t) + \tau_{ctrl}(t)$$



AutanaBooks