

INTERFACES





IN TERE FASLS

Interfases

Revista de la Carrera de Ingeniería de Sistemas de la Facultad de Ingeniería
de la Universidad de Lima

N.º 20, diciembre, 2024

doi: <https://doi.org/10.26439/interfases2024.n020>

Lima, Perú

© Universidad de Lima

Fondo Editorial

Av. Javier Prado Este 4600

Urb. Fundo Monterrico Chico

Santiago de Surco, Lima, Perú

Código postal 15023

Teléfono (511) 437-6767, anexo 30131

fondoeditorial@ulima.edu.pe

www.ulima.edu.pe

Edición, diseño y diagramación: Fondo Editorial de la Universidad de Lima.

Correspondencia:

interfases@ulima.edu.pe

Las opiniones expresadas en los artículos firmados son de exclusiva responsabilidad de los autores. Los contenidos de la revista *Interfases* son de acceso abierto y se publican bajo los términos de la licencia Creative Commons Attribution 4.0 International (CC BY 4.0).

Periodicidad: semestral

Arbitraje editorial: revisión por pares doble ciego

Directorios y catálogos: Redalyc, CrossRef, Dialnet, Latindex y DOAJ

ISSN (en línea): 1993-4912

Hecho el depósito legal en la Biblioteca Nacional del Perú n.º 2020-09967

DIRECTORA

Dra. Nadia Katherine Rodríguez Rodríguez
Universidad de Lima, Perú

EDITOR

Dr. Hernán Nina Hanco
Universidad de Lima, Perú

EDITOR ASOCIADO

Dr. Juan Gutiérrez-Cárdenas
Universidad de Lima, Perú

ASISTENTE DE GESTIÓN EDITORIAL

Erick Dmitri Valderrama Urbay
Universidad de Lima, Perú

COMITÉ EDITORIAL

Dr. Cristiano Maciel, Universidade Federal de Mato Grosso, Brasil
Dra. Effie Lai-Chong Law, Durham University, Inglaterra
Dr. Enrique Arias Antúnez, Universidad de Castilla - La Mancha, España
Dr. Guillermo Antonio Dávila Calle, Universidad de Lima, Perú
Dra. Indira Guzman, California State Polytechnic University, Estados Unidos
Dr. Marco Antonio Sotelo Monge, Indra, España
Dra. Maria Florencia Pollo Cattaneo, Universidad Tecnológica Nacional, Argentina
Dr. Michael Dorin, University of St. Thomas, Estados Unidos
Dra. Nelly Condori Fernández, Universidad Santiago de Compostela, España
Dra. Ruth María Reátegui Rojas, Universidad Técnica Particular de Loja, Ecuador

REVISORES CIENTÍFICOS

Dra. Irene Aguilar Juárez, Universidad Autónoma del Estado de México, México
Mg. William Alberto Chávez Espinoza, Universidad Pública de Navarra, España
Dr. Josimar Chire-Saire, Universidade de São Paulo, Brasil
Dr. Michael Dorin, University of St. Thomas, Estados Unidos
Dr. Edwin Jonathan Escobedo Cárdenas, Universidad de Lima, Perú
Mg. Hugo Espetia Huamanga, Universidad Andina del Cusco, Perú
Mg. Valeria González Angeletti, Universidad Nacional de Córdoba, Argentina
Dr. Juan Gutiérrez Cárdenas, Universidad de Lima, Perú
Mg. Angela Mayhua Quispe, Universidad de Lima, Perú

Dr. Henry William Merino Acuña, Universidad Peruana de Ciencias Aplicadas, Perú

Mg. Javier More Sanchez, Universidad de Lima, Perú

Mg. Lourdes Ramirez Cerna, Universidade Federal de Ouro Preto, Brasil

Dr. Edwaldo Soares Rodrigues, Universidade Federal de Ouro Preto, Ouro Preto, Brasil

Mg. Miguel Adolfo Rodriguez Cuadros, Freie Universität Berlin, Alemania

Dr. José Antonio Rodriguez Melquiades, Universidad Nacional de Trujillo, Perú

Dra. Aurea Soriano-Vargas, Universidade de Campinas, Brasil

Dra. Nadia Yoza Mitsuishi, University of Colorado, Boulder, Estados Unidos

ÍNDICE

PRESENTACIÓN	9
<i>Dra. Nadia Katherine Rodríguez Rodríguez</i>	
ARTÍCULOS DE INVESTIGACIÓN	
Análisis del éxito académico mediante aprendizaje automático: adicción y ChatGPT	15
<i>Juan Carlos Torres-Díaz</i>	
<i>Ruth María Reátegui Rojas</i>	
Análisis clúster de información sobre infecciones urinarias	
<i>Ruth María Reátegui Rojas</i>	
<i>María Irene Carrillo Mayanquer</i>	
Red de conectividad en la cuenca del río Santiago: un modelo innovador para contribuir al cierre de la brecha digital en el marco de las Alianzas Multiactor	47
<i>Juan Antonio Paco Fernández</i>	
<i>River Quispe Tacas</i>	
<i>Joel Aragón Valladares</i>	
Deep Generative AI Based on Denoising Diffusion Probabilistic Models for Applications in Image Processing	69
<i>Emili Silva Bezerra</i>	
<i>Quefren Oliveira Leher</i>	
<i>Uendel Diego da Silva Alves</i>	
<i>Thuanne Paixão</i>	
<i>Ana Beatriz Alvarez</i>	

Perspectivas para la educación en IA: importancia de la inclusión de habilidades y competencias técnicas de IA en los planes de estudio	93
<i>Olda Bustillos Ortega</i>	
<i>Jorge Murillo Gamboa</i>	
<i>Olman Núñez Peralta</i>	
<i>Fabián Rodríguez Sibaja</i>	
Diseño e implementación de un convertidor elevador DC/DC con control PID para aplicaciones de frenado regenerativo	117
<i>Jorge Cristhofer Alcántara Vásquez</i>	
<i>René Ronaldo Gutiérrez Córdova</i>	
<i>Angie Tatiana Recuenco Tapia</i>	
<i>Luis Alberto Yovera Suárez</i>	
<i>Edgar André Manzano Ramos</i>	
Hacia una normativa sobre la Inteligencia Artificial (IA): consideraciones claves y regulaciones internacionales	137
<i>Olda Bustillos Ortega</i>	
<i>Jorge Murillo Gamboa</i>	
<i>Olman Núñez Peralta</i>	
<i>Fabián Rodríguez Sibaja</i>	
Lattice-Based Cryptography: Development and Analysis of a New Variant of the Crystals-Kyber Algorithm	163
<i>Mauricio Sebastian Cisneros Laule</i>	
<i>Javier Enrique Olazabal Silva</i>	
Prediction of PM2.5 and PM10 Concentrations Using XGBoost and LightGBM Algorithms: A Case Study in Lima, Peru	183
<i>Johan Andrés Oblitas Mantilla</i>	
<i>Edwin Jhonatan Escobedo Cárdenas</i>	
ARTÍCULOS DE REVISIÓN	
Análisis de características en proyectos de <i>big data</i> : revisión sistemática de literatura	209
<i>Mariel Liliana Ojeda</i>	
<i>Cinthia Vegega</i>	
<i>María F. Pollo Cattaneo</i>	
DATOS DE LOS AUTORES	229

PRESENTACIÓN

doi: <https://doi.org/10.26439/interfases2024.n19.7294>

La revista *Interfases*, en su edición número 20, presenta diez artículos destacados en áreas como ciencias de la computación, ingeniería de *software*, sistemas de información, tecnologías de la información, ciberseguridad, ciencia de datos, entre otros. Los artículos seleccionados son el resultado de un proceso riguroso de revisión por pares ciegos, en el cual se evaluó que los trabajos estuvieran dentro del alcance de la revista y cumplieran con los criterios establecidos en cuanto al tipo de investigación y que su contenido resultara significativo para el avance del campo científico, además de seguir el formato requerido por la revista, correspondiente a las normas APA, versión 7. Durante todo el proceso editorial, todos los involucrados nos hemos guiado por la ética de las publicaciones, claramente establecida en los lineamientos de la revista expuestos en el portal de revistas de la Universidad de Lima (<https://revistas.ulima.edu.pe/index.php/Interfases/eted>).

En esta edición, contamos con importantes contribuciones de investigadores del Perú, Ecuador, Argentina, Brasil y Costa Rica, así como tres artículos presentados en inglés. Las principales aportaciones se enmarcan en el ámbito de la inteligencia artificial y la educación. Los investigadores de la Universidad Técnica Particular de Loja, Ecuador, Dr. Juan Carlos Torres-Díaz, Dra. Ruth María Reátegui Rojas y María Irene Carrillo Mayanquer, han contribuido con destacados trabajos en sus respectivas áreas. El Dr. Torres-Díaz y la Dra. Reátegui Rojas presentan el artículo titulado "Análisis del éxito académico mediante aprendizaje automático: adicción y ChatGPT". Por otro lado, la Dra. Reátegui Rojas y la investigadora Carrillo Mayanquer colaboran con el estudio "Análisis clúster basado en información relacionada a infecciones urinarias".

Los investigadores de la Pontificia Universidad Católica del Perú, Juan Antonio Paco Fernández, River Quispe Tacas y Joel Aragón Valladares, presentan el trabajo titulado "Red de conectividad en la cuenca del río Santiago: un modelo innovador para contribuir al cierre de la brecha digital en el marco de las Alianzas Multiactor". Este es un tema de gran relevancia que refleja el trabajo académico en apoyo a zonas de difícil acceso en la selva peruana con necesidades de conectividad.

Asimismo, se observa un avance significativo en el *deep learning*, que está proporcionando soluciones a problemas que antes no tenían una solución tangible. Investigadores como Emili Silva Bezerra, Quefren Oliveira Leher, Uendel Diego da Silva Alves, Thuanne Paixão y Ana Beatriz Alvarez, del PAVIC Laboratory, University of Acre (UFAC), Brasil, presentan el trabajo en inglés titulado *Deep Generative AI Based on Denoising Diffusion Probabilistic Models for Applications in Image Processing*. Este trabajo será una gran contribución para los estudios sobre el uso de la IA en el procesamiento de imágenes.

En esta misma línea, los investigadores de la Escuela de Ingeniería Informática de la Universidad Internacional de las Américas de San José, Costa Rica, Olda Bustillos Ortega, Jorge Murillo Gamboa, Olman Núñez Peralta y Fabián Rodríguez Sibaja presentan dos contribuciones importantes para el campo académico, específicamente en el ámbito de la inteligencia artificial. Uno de los trabajos se titula "Perspectivas para la educación en IA: importancia de la inclusión de habilidades y competencias técnicas de IA en los planes de estudio, y el segundo, "Hacia una normativa sobre la inteligencia artificial (IA): consideraciones clave y regulaciones internacionales". Ambos trabajos son altamente significativos para la aplicación de la IA y su impacto, tanto en el ámbito académico como en la sociedad, pues abordan, también, cómo afrontar sus potencialidades y riesgos.

Por otro lado, autores de la Universidad Nacional de Trujillo, Perú, presentan una investigación en el campo del diseño de dispositivos electrónicos que describe aspectos clave en su etapa de diseño; ellos son Jorge Cristhofer Alcántara Vásquez, René Ronaldo Gutiérrez Córdova, Angie Tatiana Recuenco Tapia, Luis Alberto Yovera Suárez y Edgar André Manzano Ramos y su trabajo se titula "Diseño e implementación de un convertidor elevador DC/DC con control PID para aplicaciones de frenado regenerativo".

Es importante destacar los trabajos de investigadores noveles, quienes han demostrado su destreza en la investigación presentando importantes artículos en inglés en los campos de la criptografía y los algoritmos de aprendizaje automático. Por ello, merecen una mención especial Mauricio Sebastian Cisneros Laule y Javier Enrique Olazabal Silva, quienes presentan un artículo titulado "Lattice-Based Cryptography: Development and Analysis of a New Variant of the Crystals-Kyber Algorithm". Se trata de un estudio profundo sobre las propiedades matemáticas de un algoritmo criptográfico que contribuirá al campo de la ciberseguridad. Por otro lado, Johan Andrés Oblitas Mantilla y Edwin Jhonatan Escobedo Cárdenas presentan una investigación sobre la predicción de la contaminación mediante el uso de algoritmos de aprendizaje automático titulada "Prediction of PM2.5 and PM10 Concentrations Using XGBoost and LightGBM Algorithms: A Case Study in Lima, Peru".

Las investigadoras de la Facultad Regional de Buenos Aires de la Universidad Tecnológica Nacional de Argentina, Mariel Liliana Ojeda, Cinthia Vegega y María F. Pollo Cattaneo, presentan una importante contribución en el ámbito del *big data*, titulada "Análisis de características en proyectos de *big data*: revisión sistemática de literatura".

Esta investigación contiene datos muy relevantes para las aplicaciones de la nueva generación de tecnologías que actualmente se requieren en este ámbito.

Como se puede apreciar, estas contribuciones de autores latinoamericanos reflejan importantes avances que, creemos, tendrán tienen implicaciones de alcance global, ya que todas ellas se basan en investigaciones de relevancia internacional.

Finalmente, queremos agradecer enormemente el apoyo de nuestros revisores, quienes, de manera desinteresada y con vocación de investigadores, han logrado generar un valioso diálogo científico con los autores, con el único fin de mejorar la calidad de los trabajos y, por ende, beneficiar a los lectores de la revista. También agradecemos al Fondo Editorial y al Área de Colecciones de la Biblioteca de la Universidad de Lima, que desempeñan un rol esencial para llevar a cabo la revisión de estilo, diagramado y publicación de esta vigésima edición. Estamos profundamente motivados por esta publicación y sentimos gran entusiasmo por presentar la próxima edición de *Interfases* a nuestros lectores.

Dra. Nadia Katherine Rodríguez Rodríguez
Directora de *Interfases*

ARTÍCULOS DE INVESTIGACIÓN

ANÁLISIS DEL ÉXITO ACADÉMICO MEDIANTE APRENDIZAJE AUTOMÁTICO: ADICCIÓN Y CHATGPT

JUAN CARLOS TORRES-DIAZ

jctorres@utpl.edu.ec

<https://orcid.org/0000-0003-1503-0379>

Universidad Técnica Particular de Loja, Ecuador

RUTH MARÍA REÁTEGUI ROJAS

rmreategui@utpl.edu.ec

<https://orcid.org/0000-0002-7304-4413>

Universidad Técnica Particular de Loja, Ecuador

Recibido: 12 de setiembre del 2024 / Aceptado: 2 de octubre del 2024

doi: <https://doi.org/10.26439/interfases2024.n020.7390>

RESUMEN. En este trabajo, se analiza la incidencia de las variables adicción al teléfono, a la pornografía, número de veces que se desbloquea el teléfono a cada hora y nivel de confianza en ChatGPT sobre el éxito académico de un grupo de 4278 estudiantes de ocho universidades de Ecuador. Se emplean los siguientes métodos: árboles de decisión (DT), *random forest* (RF) y *support vector machine* (SVM). Los resultados obtenidos señalan niveles similares en la precisión alcanzada en los tres algoritmos, respecto a la exactitud, en caso de SMOTE, los DT son el algoritmo que presenta mayor exactitud (*accuracy* = 0,64); y, en el caso de RandomOverSampler, el algoritmo SVM muestra mayor exactitud (*accuracy* = 0,59).

PALABRAS CLAVE: ChatGPT / adicción / aprendizaje automático

ANALYSIS OF ACADEMIC SUCCESS USING MACHINE LEARNING: ADDICTION AND CHATGPT

ABSTRACT. This paper analyzes the impact of the variables phone addiction, pornography addiction, number of times the phone is unlocked per hour, and level of confidence in ChatGPT on the academic success of a group of 4278 students from eight universities in Ecuador. The decision trees (DT), random forest (RF), and support vector machine (SVM) methods are used. The results obtained indicate similar levels of precision achieved in the three algorithms; in terms of accuracy, in the case of SMOTE, DT is the algorithm that presents the highest accuracy (*accuracy* = 0,64); and, in the case of RandomOverSampler, the SVM algorithm had the highest accuracy (*accuracy* = 0,59).

KEYWORDS: ChatGPT / addiction / machine learning

INTRODUCCIÓN

La predicción del éxito o reprobación académica, así como del comportamiento general de los estudiantes dentro de los sistemas educativos, es un tema de gran relevancia que ha sido investigado de manera continua durante décadas. A lo largo de los años, se han identificado múltiples factores que influyen en los resultados académicos, lo que ha llevado a la implementación de diversos enfoques para tratar de comprender mejor este fenómeno. Entre los predictores más destacados se encuentran las variables demográficas, como el género, la edad, el nivel socioeconómico y la ubicación geográfica de los estudiantes, que han sido objeto de análisis en múltiples estudios recientes (Batool et al., 2023; Nayak et al., 2023). Estas variables proporcionan un contexto básico, pero necesario, para entender las diferencias en el rendimiento académico entre distintos grupos de estudiantes.

Otro conjunto clave de predictores incluye las calificaciones previas de los estudiantes y el contexto educativo en el que se desenvuelven, que abarca factores como la calidad de la enseñanza, los recursos disponibles y el ambiente escolar (Beaulac & Rosenthal, 2019; Cui et al., 2024; Nachouki et al., 2023). Estos elementos no solo reflejan el desempeño pasado, sino que también ofrecen un marco para predecir el éxito futuro, ya que un adecuado entorno educativo tiende a facilitar mejores resultados. Asimismo, los factores motivacionales y psicológicos juegan un papel importante en la predicción del rendimiento académico. Aspectos como la motivación intrínseca, el manejo del estrés y las habilidades de autorregulación influyen directamente en la capacidad de los estudiantes para cumplir con las exigencias académicas (Hellás et al., 2018). La combinación de estos factores puede variar significativamente entre individuos, lo que añade una capa de complejidad a la predicción del éxito académico.

Los predictores mencionados sirven como datos de entrada para diversos algoritmos de aprendizaje automático, los cuales se utilizan para analizar grandes cantidades de información y generar modelos predictivos. La precisión de estos modelos depende en gran medida del contexto en el que se aplican, así como de la naturaleza específica del fenómeno que se está estudiando. En cualquier caso, los resultados obtenidos permiten tanto a los profesores como a las instituciones educativas ajustar sus programas y enfoques de enseñanza, con el fin de mejorar la calidad del aprendizaje de sus estudiantes (Chen, 2006).

Otros predictores que usualmente no son considerados son la adicción al teléfono (Chaudhury & Tripathy, 2018; Hong et al., 2024) y el uso de ChatGPT, que muestra incidencia positiva sobre el rendimiento académico (Gutiérrez-Aguilar et al., 2024). Los estudiantes perciben esta herramienta como útil, puesto que mejoran su capacidad para buscar información, analizar datos (Elkhodr et al., 2023) y autorregular su ritmo y estilo de aprendizaje (Cai et al., 2023); sin embargo, estamos aún en etapas tempranas en la investigación del efecto de esta tecnología en el aprendizaje. Por ese motivo, en

este estudio se analiza el efecto de estas variables y, de manera específica, se aplican distintos algoritmos de aprendizaje automático en la predicción del éxito académico motivado por la adicción a la pornografía, la adicción al teléfono y la confianza en la herramienta ChatGPT; y, por último, se comparan sus resultados de ejecución.

1. ESTADO DEL ARTE

Estudios de revisión bibliográfica muestran de manera general variables, métodos y resultados que señalan el camino recorrido en la investigación en este ámbito. En el estudio de Hellas et al. (2018), se analizan investigaciones que utilizan una amplia gama de métodos para la predicción, incluidos DT, regresiones y en general técnicas de aprendizaje automático. En cuanto a los factores predictores, se identifican diversas categorías, como el historial educativo, datos demográficos y factores motivacionales y psicológicos. Sin embargo, se observa que muchos estudios tienden a usar un número limitado de factores a menudo relacionados con el rendimiento previo en asignaturas. La mayoría de estas investigaciones se enfocan en predecir variables, como las calificaciones finales de los cursos, el promedio de calificaciones (GPA) y la retención en los programas académicos. Al respecto, un trabajo acerca de la predicción del rendimiento de los estudiantes comparó aproximadamente 260 estudios en un rango de 20 años mediante un análisis de los principales factores que afectan la predicción del rendimiento de los estudiantes, los tipos de técnicas de minería de datos que incluyen algoritmos de predicción y selección de características, y las herramientas que más frecuentemente se utilizan. Los hallazgos muestran que ANN y RF son los algoritmos de minería de datos más utilizados, mientras que WEKA es la herramienta que cuenta con mayor aceptación para procesar este tipo de estudios. Este trabajo tiene una gran relevancia debido a que arrojó una clasificación de los predictores de la deserción, cuyo orden de importancia es el siguiente: calificaciones obtenidas, variables demográficas, actividades académicas, asistencia, inteligencia/personalidad y actividades sociales o extracurriculares (Batool et al., 2023).

El estudio de Chen y Zhai (2023) proporciona una visión exhaustiva de cómo las técnicas de aprendizaje automático pueden aplicarse eficazmente en la educación y destaca la importancia de adaptar los métodos a las características específicas de los datos. En ese sentido, se aplicaron siete técnicas de aprendizaje automático sobre tres conjuntos de datos. A través de cuatro métricas de evaluación, los resultados señalaron al algoritmo RF como superior.

En los algoritmos de aprendizaje automático empleados para predecir, su principal característica está en los altos niveles de precisión que alcanzan. En el estudio de Alghamdi y Rahman (2023), para predecir el rendimiento académico de estudiantes de secundaria se construyeron tres modelos predictivos con los algoritmos Naïve Bayes (NB), RF y J48. Además, se aplicó la técnica Synthetic Minority Over-sampling Technique (SMOTE) para equilibrar los datos. El rendimiento de los modelos se comprobó mediante

la validación cruzada de diez pasos y partición directa, los resultados mostraron que el modelo NB alcanzó una precisión de predicción del 99,34 %, seguido por el modelo RF con un 98,7 %.

En la misma línea, el estudio de Nachouki et al. (2023) busca predecir las calificaciones de los estudiantes en cursos universitarios con el algoritmo RF. El objetivo es identificar los factores que influyen en el rendimiento académico. Utilizan un *dataset* de 650 registros con datos como tipo de escuela secundaria, calificación de la escuela secundaria, género, categoría del curso, porcentaje de asistencia a clase, GPA y modo de entrega del curso (presencial, en línea o híbrido). Los resultados del modelo indicaron que el GPA y la escuela secundaria fueron los predictores más significativos. La categoría del curso y el porcentaje de asistencia a clase también mostraron una importancia considerable, mientras que el modo de entrega del curso y género no tuvieron un efecto significativo.

Nayak et al. (2023) realizaron un estudio para predecir el rendimiento académico en entornos de aprendizaje en línea mediante características demográficas, académicas y conductuales. Analizaron dos conjuntos de datos y emplearon modelos de clasificación como DT, NB, RF y perceptrón multicapa (MLP). El modelo MLP demostró ser superior, con una precisión del 90,74 % en el conjunto de datos GRIET y 97,08 % en Kalboard 360 tras optimización y selección de características. Sin embargo, al incluir las características conductuales, el modelo RF alcanzó una precisión perfecta del 100 %, resultado que fue superior a los otros métodos.

El estudio de Cui et al. (2024) se centra en la aplicación de modelos de regresión a datos de estudiantes universitarios, se aplicaron las regresiones: lineal, Ridge, Lasso, Huber, regresión de vectores de soporte (SVR), K-Nearest Neighbors (KNN), DT y redes neuronales (NN). Se utilizaron los puntajes de 21 cursos y la métrica de GPA. La regresión Lasso y las NN fueron los modelos más precisos en las tres configuraciones de predicción (con el uso de puntajes de cursos de los primeros dos o tres años, o GPA de semestre). La regresión Lasso, en particular, se destacó con valores de correlación (R) superiores a 0,99 y errores mínimos (RMSE y MAE).

Beaulac y Rosenthal (2019) estudiaron la capacidad de predecir si un estudiante completará su licenciatura y qué especialización elegirá mediante el uso de datos de los primeros semestres. De este modo, analizaron diez años de registros de la Universidad de Toronto, con más de 1,6 millones de calificaciones de 65 000 estudiantes. Emplearon el algoritmo RF para predecir el éxito académico y la elección de especialización. En consecuencia, este alcanzó un 91,19 % de precisión en predecir si un estudiante terminará su programa, lo que superó a la regresión lineal. Para la especialización, logró un 47,41 % de precisión, lo cual es relevante dado el número de opciones (71 especializaciones).

En el estudio de Sharma et al. (2023), se utilizaron modelos de aprendizaje automático para predecir el rendimiento académico de los estudiantes en función de la cantidad

de tiempo que dedicaron a participar en actividades extracurriculares. En este trabajo se implementaron tres algoritmos: RF, KNN y árboles de decisión. Con base en la precisión y las puntuaciones F1, se descubrió que los árboles de decisión con índice de Gini son el mejor algoritmo para predecir el éxito académico de los estudiantes logrando F1 0,84 y una precisión del 85 %.

El trabajo de Albaloooshi et al. (2019) extrae los logros de aprendizaje individualizados de los estudiantes a partir de datos de entrada (información del curso y resultados de las evaluaciones). De esta forma, predice el desempeño esperado en cursos futuros con base en los logros existentes en un conjunto de resultados estudiantiles. Se emplea regresión lineal simple y regresión lineal múltiple para determinar el desempeño esperado de los estudiantes en cursos futuros.

Musso et al. (2020) desarrollaron modelos NN para clasificar los promedios de calificaciones, retención académica y resultados de finalización del título. Las variables predictoras fueron las estrategias de aprendizaje y las estrategias para afrontar el proceso de estudios. La primera predijo mejor el GPA, mientras que la segunda fue determinante en la predicción de la finalización del grado. El mejor modelo para analizar estas variables resultó ser el de NN.

ElSharkawy et al. (2022) analizaron la empleabilidad en TI a partir de variables predictoras: la capacitación, habilidades blandas y habilidades técnicas. Asimismo, utilizaron algoritmos de árboles de decisión, NB, regresión logística, RF y SVM. Los árboles de decisión alcanzaron la mayor precisión con un 100 %, seguido de regresión logística y SVM, ambos con un 98 %. RF obtuvo una precisión del 97 %, mientras que NB obtuvo un 92 %. Los árboles de decisión también obtuvieron los mejores resultados en términos de *precision, recall* y *F1-score* (100 %).

Se han empleado técnicas de aprendizaje automático para analizar el tema de adicción en estudiantes universitarios mediante modelos predictivos (Hong et al., 2024). El estudio identifica el nivel de adicción del estudiante y, para ello, utiliza distintas variables predictoras: perfeccionismo, procrastinación, sentido de la vida, ansiedad, autocontrol, género y grado académico. Los métodos empleados son RF, SVM y la regresión logística. Los resultados señalan que el modelo RF alcanzó una precisión del 76,68 % en la predicción de la adicción al teléfono móvil en estudiantes universitarios. Perfeccionismo y procrastinación fueron los factores más influyentes. El modelo superó a otros como SVM y NB. En un estudio que utilizó técnicas de minería de datos, se analizó el impacto de la adicción al teléfono móvil sobre el desempeño académico, donde se emplearon métodos como SVM, NN y clasificadores NB (Chaudhury & Tripathy, 2018). El desempeño académico estuvo categorizado en tres niveles: bajo, medio y alto; se encontró correlación negativa significativa.

2. METODOLOGÍA

En este trabajo, se aplican tres métodos de aprendizaje automático para predecir el éxito académico de un estudiante que se matricula en un determinado número de asignaturas. Como predictores intervienen las siguientes variables: nivel de adicción a la pornografía, nivel de adicción al teléfono, la frecuencia con que se desbloquea el teléfono y el nivel de confianza en la herramienta ChatGPT.

2.1. Data

Se ha considerado un *dataset* de 4278 registros con información relacionada al uso de la tecnología y redes sociales en estudiantes de ocho universidades del Ecuador.

Para este experimento se seleccionaron las variables presentadas en la Tabla 1. Además, se creó una nueva variable que considera la diferencia entre la asignatura matriculado (P14_a) y asignatura aprobada (P14_b).

Tabla 1

Descripción de variables utilizadas

Código de la variable	Descripción	Valores
P06_a	Adicción al teléfono	0 a 9
P06_b	Pornografía	0 a 9
P08	Desbloqueo del teléfono	1 a 52
P12_b	Confianza en ChatGPT	0 a 9
Diff	Variable creada que resta la cantidad de asignaturas matriculadas (P14_a) y asignaturas aprobadas (P14_b)	0 a 7

Nota. Variables levantadas a través de encuesta.

En este trabajo se utilizó el lenguaje Python y Google Colab como entorno de programación.

2.2. Preprocesamiento

Luego de realizar una limpieza para eliminar registros que no presentaban algún valor o un valor negativo en las variables descritas en la parte superior, se obtuvo un total de 4223 registros.

Diff será la variable a predecir mediante el uso de clasificadores binarios. Se procedió a transformar los valores 1 a 7 (cantidad de materias reprobadas) a un valor de 1. De esta forma, se convierte en una variable dicotómica, donde el valor 0 representa a los alumnos que aprobaron todas las materias matriculadas y el valor 1 simboliza si ha reprobado una o más asignaturas.

Se realizó la división de la data y, para la etapa de entrenamiento, se utilizó el 70 % de la data y el 30 % se reservó para la evaluación.

Debido a que la variable a predecir Diff tiene 2437 registros para la clase 0 y 519 registros para la clase 1 (con respecto a la cantidad de datos de entrenamiento), es necesario balancear la data (ver la Tabla 2). Se ha considerado trabajar con la técnica *oversampling* que permite a la clase minoritaria igualarse en la cantidad de registros o de observaciones a la clase mayoritaria, de esta forma aumentaremos los datos en lugar de eliminar registros. En Python, el paquete *imbalanced-learn* contiene una serie de algoritmos para realizar *oversampling*, entre ellos SMOTE y RandomOverSampler.

Cabe recalcar que no hay un criterio certero que permita seleccionar si se trabajará con técnicas de *oversampling* o *undersampling* (Estabrooks et al., 2004), incluso la evaluación del desempeño de las técnicas varía de acuerdo con la métrica utilizada (Wainer, 2024). No obstante, se ha demostrado que las técnicas de *oversampling* son superiores con respecto a las de *undersampling* (García et al., 2020) e inclusive se ha demostrado que SMOTE trabaja mejor con datos que presentan una baja dimensionalidad (Blagus & Lusa, 2013), como es el caso del *dataset* utilizado en nuestro trabajo. Por lo antes expuesto, se ha decidido trabajar con SMOTE y considerar RandomOverSampler como otra posibilidad para la comparación. Este último se ha considerado, pues en el trabajo de Wongvorachan et al. (2023) se utilizó esta técnica con buenos resultados. Sobre estos algoritmos, por un lado, SMOTE es una técnica que genera observaciones sintéticas (Chawla et al., 2022), mientras que, por otro lado, RandomOverSampler forma nuevas muestras mediante una selección aleatoria con sustitución de las actuales disponibles (Imbalanced learn, 2014).

La Tabla 2 explica mejor el proceso:

Tabla 2

Registros por clase

Descripción de clases	Cantidad de registros
Variable Diff	Clase 0 = 3456 Clase 1 = 767
Variable Diff para entrenamiento	Clase 0 = 2437 Clase 1 = 519
Variable Diff para evaluación	Clase 0 = 1019 Clase 1 = 248
Variable Diff luego del balanceo con las dos técnicas de <i>oversampling</i>	Clase 0 = 2437 Clase 1 = 2437

Cabe recalcar que para el algoritmo *support vector machine* también se procedió a normalizar la data balanceada y de entrenamiento a través del uso de StandardScaler de Python.

2.3. Experimentación

Para el presente trabajo se consideraron tres algoritmos: DT, RF y SVM. Estos han sido ampliamente utilizados en trabajos que realizan clasificación, previo a realizar un balanceo de los datos (Kovács, 2019; Blagus & Lusa, 2013; Wongvorachan et al., 2023). Los árboles de decisión y RF fueron entrenados con la data original balanceada, mientras que SVM se entrenó con la data estandarizada luego del balanceo con StandardScaler de Python.

Para buscar los mejores parámetros se utilizó GridSearchCV de 5. La Tabla 3 muestra algunos de los parámetros considerados los mejores para cada uno de los algoritmos utilizados.

Tabla 3

Parámetros seleccionados con GridSearchCV

Algoritmo	Mejores parámetros
Balanceo con SMOTE	
Árbol de decisión	{'criterion': 'entropy', 'max_depth': 5}
Random forest	{'bootstrap': True, 'criterion': 'gini', 'max_depth': 5, 'max_features': 3, 'min_samples_leaf': 3, 'min_samples_split': 7, 'n_estimators': 100}
Support vector machine	{'C': 5, 'kernel': 'linear'}
Balanceo con RandomOverSampler	
Árbol de decisión	{'criterion': 'gini', 'max_depth': 5}
Random forest	{'bootstrap': True, 'criterion': 'gini', 'max_depth': 5, 'max_features': 3, 'min_samples_leaf': 3, 'min_samples_split': 5, 'n_estimators': 100}
Support vector machine	{'C': 5, 'kernel': 'linear'}

2.4. Evaluación

Para evaluar los modelos obtenidos con los tres algoritmos, se utilizaron las siguientes métricas: *precision*, *accuracy*, *recall* y *F1-score*; las fórmulas se muestran en la Tabla 4. Además, se crearon la matriz de confusión y el reporte de clasificación con ayuda de la librería sklearn.metrics.

Tabla 4

Métricas de evaluación

Métrica	Fórmula
<i>Precision</i>	$\frac{VP}{VP + FP}$
<i>Accuracy</i>	$\frac{VP + VN}{VP + FP + FN + VN}$
<i>Recall</i>	$\frac{VP}{VP + FN}$
<i>F1-score</i>	$2 * \frac{precision * recall}{precision + recall}$
VP: Verdaderos positivos, VN: Verdaderos negativos, FN: Falsos positivos, FN: Falsos negativos	

3. RESULTADOS

La Tabla 5 muestra los resultados obtenidos con los tres algoritmos anteriormente descritos.

Tabla 5

Métricas resultantes

Algoritmo	Precision	Accuracy	Recall	F1-score
SMOTE				
Árbol de decisión	0,52	0,64	0,53	0,52
Random forest	0,52	0,61	0,53	0,51
SVM	0,51	0,51	0,52	0,46
RandomOverSampler				
Árbol de decisión	0,53	0,54	0,55	0,49
Random forest	0,52	0,56	0,54	0,49
SVM	0,54	0,59	0,56	0,52

Como se puede observar, existen pequeñas diferencias entre los valores obtenidos en *precision*, *recall* y *F1-score* para los experimentos realizados con SMOTE y RandomOverSampler. Prácticamente, estas métricas se mantienen muy similares en todos los experimentos que se realizan con algoritmos basados en árboles. La gran diferencia se puede observar en los resultados obtenidos en *accuracy*, el cual muestra 0,64, el mejor resultado obtenido con SMOTE y con el algoritmo árbol de decisión. Cuando se aplica RandomOverSampler, SVM se destaca con un *accuracy* de 0,59.

Un punto importante a considerar con la métrica *accuracy* es que en datos no balanceados solo consideran esta métrica como desempeño de los algoritmos, lo cual puede

ser una estrategia errónea. Si el algoritmo predice correctamente la mayoría de los datos de la clase mayoritaria y se equivoca en la clase minoritaria, el valor de *accuracy* podría seguir siendo alto. Este tipo de métrica no considera los falsos negativos ni los falsos positivos; por el contrario, *recall* y *precision* trabajan con FN y FP, por lo que con mayor razón han sido utilizados.

Para aclarar la variedad en los resultados y considerando los aciertos (VP y VN) según la matriz de confusión, es posible observar que con SMOTE la clase mayoritaria consiguió mayores aciertos (71 %) con árboles de decisión, pero la clase minoritaria consiguió la mayoría de aciertos (54 %) con SVM. Con la técnica de RandomOverSampler, los resultados fueron contrarios, la clase mayoritaria obtuvo mayores aciertos (61 %) con SVM, pero la clase minoritaria (clase 1) consiguió la mayoría de aciertos (57 %) con árboles de decisión. Estos porcentajes se los puede obtener en base a las matrices de confusión que se presentan en la Tabla 6.

Tabla 6
Matriz de confusión e informe de clasificación

Algoritmo	Matriz de confusión	Informe de clasificación				
		precision	recall	F1-score	support	
Árbol de decisión	[728 291] [162 86]	SMOTE				
		0	0,82	0,71	0,76	1019
		1	0,23	0,35	0,28	248
		accuracy			0,64	1267
		macro avg.	0,52	0,53	0,52	1267
		weighted avg.	0,70	0,64	0,67	1267
		Random forest	[670 349] [148 100]	precision	recall	F1-score
0	0,82	0,66	0,73	1019		
1	0,22	0,40	0,29	248		
	accuracy			0,61	1267	
	macro avg.	0,52	0,53	0,51	1267	
	weighted avg.	0,70	0,61	0,64	1267	

SVM	[516 503] [114 134]	precision	recall	F1-score	support	
		0	0,82	0,51	0,63	1019
		1	0,21	0,54	0,30	248
		accuracy			0,51	1267
		macro avg.	0,51	0,52	0,46	1267
		weighted avg.	0,70	0,51	0,56	1267
RandomOverSampler						
Árbol de decisión	[545 474] [107 141]	precision	recall	F1-score	support	
		0	0,84	0,53	0,65	1019
		1	0,23	0,57	0,33	248
		accuracy			0,54	1267
		macro avg.	0,53	0,55	0,49	1267
		weighted avg.	0,72	0,54	0,59	1267
Random forest	[582 437] [123 125]	precision	recall	F1-score	support	
		0	0,83	0,57	0,68	1019
		1	0,22	0,50	0,31	248
		accuracy			0,56	1267
		macro avg.	0,52	0,54	0,49	1267
		weighted avg.	0,71	0,56	0,60	1267
SVM	[626 393] [124 124]	precision	recall	F1-score	support	
		0	0,83	0,61	0,71	1019
		1	0,24	0,50	0,32	248
		accuracy			0,59	1267
		macro avg.	0,54	0,56	0,52	1267
		weighted avg.	0,72	0,59	0,63	1267

Considerando las otras métricas, con RandomOverSampler se logran los valores más altos para *precision* y *recall*. Ahora, al igual que la métrica *accuracy*, es importante saber el comportamiento de los algoritmos con respecto a la clase minoritaria (ver la Tabla 6). Basados en el informe de clasificación, para la clase minoritaria *precision* tiene un valor de 0,24 con SVM y para *recall* esta misma clase presenta el valor más alto

de 0,57 para el árbol de decisión. Con este análisis se puede corroborar que los valores de las métricas varían dependiendo del algoritmo y de la técnica de balanceo, tal y como lo demuestra Wainer (2024).

4. CONCLUSIONES

Basados en los resultados obtenidos, se concluye que la elección del método de sobremuestreo puede tener un impacto significativo en el rendimiento de los algoritmos, especialmente en términos de *accuracy*. Los modelos basados en árboles parecen beneficiarse del uso de SMOTE, mientras que SVM muestra mejor desempeño con RandomOverSampler. En cuanto a las otras métricas, con RandomOverSampler se obtuvieron mejores resultados para *precision* y *recall*.

Con estos experimentos podemos corroborar lo que menciona Wainer (2024), que la evaluación del desempeño varía de acuerdo con la métrica utilizada. Además, hay que considerar que los resultados del balanceo dependen mucho del tipo de datos que se utiliza, del volumen de los datos, del porcentaje de desbalanceo de la data y de las técnicas de balanceo utilizadas (Newaz et al., 2022). En nuestro caso, hemos utilizado SMOTE y RandomOverSampler para balancear la data, pero hay trabajos cuyo objetivo ha sido demostrar el funcionamiento de varias técnicas (Estabrooks et al., 2004; Kovács, 2019) y que presentan una lista amplia de posibles técnicas a utilizar.

En investigaciones futuras, se plantea realizar más experimentos con otros algoritmos de clasificación, como aquellos basados en árboles. Además, se podría tratar con otras técnicas de balanceo como los híbridos (SMOTE-Tomek y SMOTE-ENN) o métodos basados en ensamblaje (UnderBagging, SMOTE-Bagging). También se propone la inclusión de otro tipo de variables que puedan ayudar a mejorar la clasificación.

REFERENCIAS

- Albalooshi, F., AlObaidy, H., & Ghanim, A. (2019). Mining students outcomes: An empirical study. *International Journal of Computing and Digital Systems*, 8(3), 229-241. <https://doi.org/10.12785/ijcnds/080303>
- Alghamdi, A. S., & Rahman, A. (2023). Data mining approach to predict success of secondary school students: A Saudi Arabian case study. *Education Sciences*, 13(3), 293. <https://doi.org/10.3390/educsci13030293>
- Batool, S., Rashid, J., Nisar, M. W., Kim, J., Kwon, H. Y., & Hussain, A. (2023). Educational data mining to predict students' academic performance: A survey study. *Education and Information Technologies*, 28, 905-971. <https://doi.org/10.1007/s10639-022-11152-y>

- Beaulac, C., & Rosenthal, J. S. (2019). Predicting university students' academic success and major using random forests. *Research in Higher Education*, 60, 1048-1064. <https://doi.org/10.1007/s11162-019-09546-y>
- Blagus, R., & Lusa, L. (2013). SMOTE for high-dimensional class-imbalanced data. *BMC Bioinformatics*, 14(106), 1-16. <https://doi.org/10.1186/1471-2105-14-106>
- Cai, Q., Lin, Y., & Yu, Z. (2023). Factors influencing learner attitudes towards ChatGPT-assisted language learning in higher education. *International Journal of Human-Computer Interaction*. Publicación anticipada en línea. <https://doi.org/10.1080/10447318.2023.2261725>
- Chaudhury, P., & Tripathy, H. K. (2018). A study on impact of smartphone addiction on academic performance. *International Journal of Engineering and Technology*, 7(2.6), 50-53. <https://doi.org/10.14419/ijet.v7i2.6.10066>
- Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, 16, 321-357. <https://doi.org/10.1613/jair.953>
- Chen, Y.-C. (2006). A study of comparing the use of augmented reality and physical models in chemistry education. *VRCIA'06: Virtual Reality Continuum and Its Applications 2006*, 1, 369-372. <https://doi.org/10.1145/1128923.1128990>
- Chen, Y., & Zhai, L. (2023). A comparative study on student performance prediction using machine learning. *Education and Information Technologies*, 28, 12039-12057. <https://doi.org/10.1007/s10639-023-11672-1>
- Cui, W., Sangsongfar, A., & Amdee, N. (2024). A comparative study of the applicability of regression models in predicting student academic performance. *Naresuan University Engineering Journal*, 19(1), 39-49. <https://ph01.tci-thaijo.org/index.php/nuej/article/view/255799>
- Elkhodr, M., Gide, E., Wu, R., & Darwish, O. (2023). ICT students' perceptions towards ChatGPT: An experimental reflective lab analysis. *STEM Education*, 3(2), 70-88. <https://doi.org/10.3934/steme.2023006>
- ElSharkawy, G., Helmy, Y., & Yehia, E. (2022). Employability prediction of information technology graduates using machine learning algorithms. *International Journal of Advanced Computer Science and Applications*, 13(10), 359-367. <https://doi.org/10.14569/IJACSA.2022.0131043>
- Estabrooks, A., Jo, T., & Japkowicz, N. (2004). A multiple resampling method for learning from imbalanced data sets. *Computational Intelligence*, 20(1), 18-36. <https://doi.org/10.1111/j.0824-7935.2004.t01-1-00228.x>
- García, V., Sánchez, J. S., Marqués, A. I., Florencia, R., & Rivera, G. (2020). Understanding the apparent superiority of over-sampling through an analysis of local

- information for class-imbalanced data. *Expert Systems with Applications*, 158, artículo 113026. <https://doi.org/10.1016/j.eswa.2019.113026>
- Gutiérrez-Aguilar, O., Huarsaya-Rodríguez, E., & Duche-Pérez, A. (2024). The mediating effect of academic performance on ChatGPT satisfaction in university students. En G. F. Olmedo Cifuentes, D. G. Arcos Avilés y H. V. Lara Padilla (Eds.), *Emerging research in intelligent systems – Proceedings of the CIT 2023* (v. 2, pp. 353-365). Springer Science and Business Media Deutschland GmbH. https://doi.org/10.1007/978-3-031-52258-1_26
- Hellas, A., Ihtantola, P., Petersen, A., Ajanovski, V. V., Gutica, M., Hynninen, T., Knutas, A., Leinonen, J., Messom, C., & Liao, S. N. (2018). Predicting academic performance: A systematic literature review. En G. Rößling y B. Scharlau (Eds.), *ITiCSE 2018 companion: Proceedings companion of the 23rd Annual ACM Conference on Innovation and Technology in Computer Science Education* (pp. 175-199). Association for Computing Machinery. <https://doi.org/10.1145/3293881.3295783>
- Hong, Y., Rong, X., & Liu, W. (2024). Construction of influencing factor segmentation and intelligent prediction model of college students' cell phone addiction model based on machine learning algorithm. *Heliyon*, 10(8), e29245. <https://doi.org/10.1016/j.heliyon.2024.e29245>
- Kovács, G. (2019). An empirical comparison and evaluation of minority oversampling techniques on a large number of imbalanced datasets. *Applied Soft Computing*, 83, artículo 105662. <https://doi.org/10.1016/j.asoc.2019.105662>
- Musso, M. F., Rodríguez, C. F., & Cascallar, E. C. (2020). Predicting key educational outcomes in academic trajectories: A machine-learning approach. *Higher Education*, 80, 875-894. <https://doi.org/10.1007/s10734-020-00520-7>
- Nachouki, M., Mohamed, E. A., Mehdi, R., & Abou Naaj, M. (2023). Student course grade prediction using the random forest algorithm: Analysis of predictors' importance. *Trends in Neuroscience and Education*, 33, 100214. <https://doi.org/10.1016/j.tine.2023.100214>
- Nayak, P., Vaheed, S., Gupta, S., & Mohan, N. (2023). Predicting students' academic performance by mining the educational data through machine learning-based classification model. *Education and Information Technologies*, 28, 14611-14637. <https://doi.org/10.1007/s10639-023-11706-8>
- Newaz, A., Hassan, S., & Haq, F. S. (2022). An empirical analysis of the efficacy of different sampling techniques for imbalanced classification. *arXiv*. Publicación anticipada en línea. <https://doi.org/10.48550/arXiv.2208.11852>
- Sharma, N., Appukutti, S., Garg, U., Mukherjee, J., & Mishra, S. (2023). Analysis of student's academic performance based on their time spent on extra-curricular activities

using machine learning techniques. *International Journal of Modern Education and Computer Science*, 15(1), 46-57. <https://doi.org/10.5815/ijmecs.2023.01.04>

Imbalanced learn. (2014). *RandomOverSampler*. https://imbalanced-learn.org/stable/references/generated/imblearn.over_sampling.RandomOverSampler.html#imblearn.over_sampling.RandomOverSampler

Wainer, J. (2024). An empirical evaluation of imbalanced data strategies from a practitioner's point of view. *Expert Systems with Applications*, 256, 124863. <https://doi.org/10.1016/j.eswa.2024.124863>

Wongvorachan, T., He, S., & Bulut, O. (2023). A comparison of undersampling, oversampling, and SMOTE methods for dealing with imbalanced classification in educational data mining. *Information*, 14(1), 54. <https://doi.org/10.3390/info14010054>

ANÁLISIS CLÚSTER DE INFORMACIÓN SOBRE INFECCIONES URINARIAS

RUTH MARÍA REÁTEGUI ROJAS

rmreategui@utpl.edu.ec

<https://orcid.org/0000-0002-7304-4413>

Universidad Técnica Particular de Loja, Ecuador

MARÍA IRENE CARRILLO MAYANQUER

micarrillo@utpl.edu.ec

<https://orcid.org/0000-0001-9968-2539>

Universidad Técnica Particular de Loja, Ecuador

Recibido: 2 de agosto del 2024 / Aceptado: 14 de octubre del 2024

doi: <https://doi.org/10.26439/interfases2024.n020.7327>

RESUMEN. Las infecciones urinarias constituyen el principal motivo de consulta en el servicio de urgencias pediátricas en el mundo, por lo que merecen ser analizadas con técnicas de inteligencia artificial que permitan descubrir patrones basados en información médica y de laboratorio. El análisis clúster es una técnica no supervisada de aprendizaje de máquina que permite identificar grupos de pacientes con características similares. En este trabajo, se analizó información anonimizada de pacientes extraída de un sistema informático, donde todos sufren de infecciones urinarias. Se aplicó inicialmente el análisis de correspondencia múltiple (ACM) para luego utilizar de forma separada los algoritmos K-means y DBSCAN. Se obtuvo el valor de *silhouette* de cada grupo obtenido con los dos algoritmos. Se logró diferenciar a los pacientes de acuerdo con los porcentajes de prevalencia de sensibilidad/resistencia a ciertos antibióticos y a la presencia de los gérmenes que provocan las infecciones.

PALABRAS CLAVE: inteligencia artificial / aprendizaje de máquina / salud

CLUSTER ANALYSIS OF INFORMATION ON URINARY TRACT INFECTIONS

ABSTRACT. Urinary tract infections are the main reason for consultation in the pediatric emergency department worldwide, so it deserves to be analyzed with artificial intelligence techniques to discover patterns based on medical and laboratory information. Cluster analysis is an unsupervised machine learning technique that allows the identification of groups of patients with similar characteristics. In this work we analyzed information from patients whose anonymized information was extracted from a computer system, all of them are patients suffering from urinary tract infections.

Multiple Correspondence Analysis was initially applied and then K-means and DBSCAN algorithms were used separately. The silhouette value of each group identified with the two algorithms was obtained. Patients were differentiated according to the prevalence percentages of sensitivity/resistance to certain antibiotics and the presence of the germs causing the infections.

KEYWORDS: artificial intelligence / machine learning / health

INTRODUCCIÓN

La infección del tracto urinario (ITU) se produce por la colonización de bacterias en esa zona (Hevia et al., 2020). Este es el principal motivo de consulta en el servicio de urgencia pediátrica a nivel mundial, pues representa el 14 % de visitas al año (Ardila et al., 2015). Además, es una de las principales causas de fiebre sin foco en lactantes (Leung et al., 2019). La ITU tiene una prevalencia general de aproximadamente el 7 % en los lactantes que presentan fiebre, pero esta prevalencia varía según la edad, el sexo y el estado de circuncisión. Las niñas tienen una prevalencia de infecciones urinarias entre dos y cuatro veces mayor que los hombres circuncidados; sin embargo, esta prevalencia se iguala en los niños no circuncidados, especialmente en menores de 3 meses (Shaikh & Hoberman, 2022). La ITU alta o pielonefritis a repetición puede causar cicatrización renal, hipertensión arterial y enfermedad renal crónica, de allí que un diagnóstico precoz y un tratamiento adecuado son de importancia para prevenir complicaciones a futuro (Shaikh & Hoberman, 2022).

Los microorganismos más comunes provienen de la flora intestinal. Por ejemplo, la *Escherichia coli* es responsable del 80 % al 90 % de las infecciones urinarias en niños (Leung et al., 2019). En los últimos años, se ha detectado una disminución progresiva en la sensibilidad de este microorganismo frente a los antimicrobianos (Betrán et al., 2020). En particular, los mecanismos subyacentes de virulencia y resistencia a los antibióticos en niños no son bien conocidos (Salazade et al., 2023). Según Cavagnaro Santa María (2014), la resistencia antibiótica frecuentemente está relacionada con el uso prolongado y, a veces, inapropiado de estos fármacos, de modo que considera necesaria una evaluación periódica de la prevalencia y la resistencia bacteriana de estos microorganismos.

Actualmente, con mayor fuerza se busca implementar la inteligencia artificial (IA) en varios campos del conocimiento, entre los cuales la salud es uno de los más destacados. El análisis clúster es una de las técnicas de IA que permite descubrir patrones y segmentar a los pacientes en grupos homogéneos, basados en características como las demográficas, clínicas y de laboratorio. Además, según la información proveniente de sistemas informáticos médicos, son varios trabajos los que se han desarrollado con análisis clúster. Por ejemplo, en análisis de enfermedades relacionadas con el corazón, Martins et al. (2014), Wazzan et al. (2024), Banerjee et al. (2023) y Hobensack et al. (2023) aplicaron algoritmos jerárquicos, K-medias y K-modas. Otros trabajos, que utilizaron los mismos algoritmos, se han enfocado en analizar información de la columna vertebral (Mohanty et al., 2024), de la lesión renal (Bolt et al., 2023) y de la epilepsia (Josephson et al., 2023). Además, Chacaguasay et al. (2024) analizaron infecciones urinarias en mujeres y compararon los resultados con tres algoritmos: K-means, DBSCAN y jerárquico. La desnutrición en niños también ha sido estudiada por Hadikurniawati et al. (2023), estos autores aplicaron K-means y DBSCAN. También, varios de estos trabajos aplicaron técnicas para la reducción de la dimensionalidad y algunas métricas para el cálculo de la similitud como Gower y Jaccard.

Entre los trabajos más cercanos al análisis de resistencia/sensibilidad a antibióticos e incluso al análisis de las bacterias que causan enfermedades en niños, se encuentra el trabajo de Krueger et al. (2024), donde utilizaron K-means para analizar 10 609 prescripciones de antibióticos en tres diferentes enfermedades: infección del tracto urinario, neumonía adquirida en la comunidad y otitis media aguda. El resultado arrojó dos grupos de pacientes, cuya diferencia radica en el tiempo de prescripción de los antibióticos. Las mismas enfermedades fueron analizadas por Elgoibar et al. (2020) en 291 niños infectados con *E. coli*, donde identificaron cuatro grupos de pacientes claramente diferenciados por su condición médica. Por otro lado, Suwono et al. (2021) utilizaron información de la resistencia a los antibióticos en *E. coli* procedentes de diferentes sistemas de vigilancia y monitoreo para humanos y diferentes poblaciones animales. Utilizaron el algoritmo jerárquico e identificaron varios clústeres diferenciados por las combinaciones de resistencia a los antibióticos.

Por lo antes expuesto, el análisis clúster es una técnica que no solo facilita la comprensión de la variabilidad de las enfermedades, sino que también puede informar estrategias de tratamiento personalizadas y la gestión de la enfermedad. Por tal razón, el presente estudio se enfoca en aplicar K-means y DBSCAN, algoritmos ampliamente utilizados en el ámbito médico, como se ha demostrado en los párrafos anteriores, para explorar y caracterizar subgrupos de niñas con infecciones urinarias. Se ha utilizado un conjunto de datos que incluye variables clínicas, demográficas y de laboratorio.

En el presente trabajo, primero se brinda una introducción al tema a tratar; luego, se describe la metodología utilizada; y, finalmente, se ofrecen los resultados y las conclusiones.

1. METODOLOGÍA

En este apartado, se explicarán las fases que se llevaron a cabo para el proceso de experimentación.

1.1 Dataset

Para el presente estudio, se utilizó una base de 133 niñas cuyo diagnóstico ha sido codificado como "infección de vías urinarias en sitio no especificado". Esta base incluye información sobre la sensibilidad y resistencia a ciertos antibióticos, así como datos de los gérmenes identificados en los exámenes de laboratorio.

1.2 Preprocesamiento

Las variables fueron configuradas para que el valor 1 indique la presencia de sensibilidad o resistencia a determinado antibiótico, y 0 para el caso contrario. Además, la variable germen fue codificada para que cada patógeno sea una variable; es decir, se

crearon variables *dummy*, donde el valor 1 corresponde a la presencia de un germen específico y 0 para el caso contrario.

Se procedió a crear las variables *SOtro* (abreviación para sensibilidad_otros), *ROtro* (abreviación para resistencia_otros) y *GermenOtro* para agrupar las variables de sensibilidad, resistencia y gérmenes que estaban presentes en uno o dos pacientes. Por ejemplo, de las pacientes analizadas solo una presentó sensibilidad a amoxicilina + ácido clavulánico, por ende, esta variable se añadió a *SOtro*. Con esto, se tuvo un corpus de 133 pacientes y 48 variables dicotómicas, de las cuales 24 están relacionadas a sensibilidad, 19 a resistencia y 5 a gérmenes. La Tabla 1 muestra el listado de las 48 variables.

1.3 Análisis clúster

Para el proceso de experimentación, se trabajó con los algoritmos no supervisados K-means y DBSCAN. Previo a la utilización de estos algoritmos, se realizó la reducción de variables mediante el método MCA. A continuación, se brinda una breve explicación de las técnicas utilizadas y la justificación de su uso en este trabajo.

MCA

Existen varias técnicas de reducción de dimensionalidad, uno de los más populares es el análisis de componentes principales (PCA) que trabaja con datos numéricos. Nuestro *dataset* contiene variables categóricas (binarias), por lo que se requiere una técnica que permita tratar este tipo de dato. El análisis de correspondencia múltiple (MCA, por sus siglas en inglés) es una técnica de reducción de dimensionalidad que trabaja con datos categóricos. Para la reducción de la dimensionalidad, se selecciona un número determinado de componentes principales (eigenvectores) que explican la mayor parte de la variabilidad en los datos, similar a como trabaja el PCA. Así, el MCA captura la mayor parte de la variabilidad en los datos categóricos, lo que permite que los algoritmos de agrupamiento operen de manera más eficiente y efectiva. Es importante recalcar que luego de aplicar este método se obtendrá una matriz con dos componentes y con valores numéricos, por tanto, los algoritmos para el análisis clúster deben ser aptos para *data-sets* numéricos.

K-means

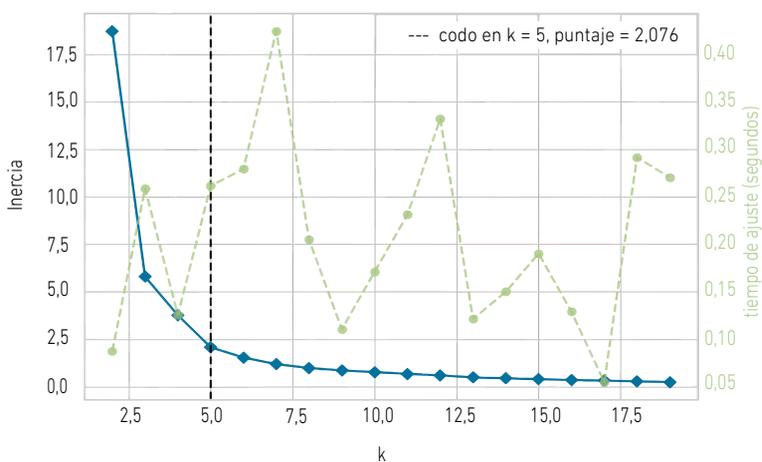
El algoritmo K-means es un método no supervisado que se utiliza para dividir un conjunto de datos en un número predeterminado de clústeres (k) basados en similitudes en las características de los datos. La elección de este algoritmo se basa en que, aparte de ser ampliamente utilizado en el ámbito médico, es un algoritmo simple, computacionalmente eficiente y que converge rápidamente hacia un resultado, lo cual es beneficioso para análisis preliminares o cuando se requiere celeridad en los resultados.

Método del codo

Este método se basa en calcular y visualizar los valores de la inercia obtenidos al calcular el algoritmo K-means para un rango determinado de valores de k . Se grafica la inercia en función del número de clústeres k ; en el eje x se coloca el número de clústeres y en el eje y , la inercia calculada. Aplicando este método, el k recomendado para trabajar con el algoritmo K-means es de cinco grupos; esto se puede observar en la Figura 1.

Figura 1

Método del codo para determinar el número de clústeres (k)



Nota. En la gráfica, se puede observar que el valor del codo en k es igual a 5.

DBSCAN

Este algoritmo DBSCAN (siglas en inglés de density-based spatial clustering of applications with noise) utiliza la densidad para la identificación de los clústeres o grupos. Trabaja con dos parámetros: ϵ (eps), que es la distancia máxima para que dos objetos sean reconocidos como vecinos, y el número mínimo de puntos (minPts) requeridos para que una región se considere densa. Este algoritmo también ha sido ampliamente utilizado en datos médicos. A diferencia de K-means, este algoritmo no necesita previamente conocer el número de clústeres a identificar. También es importante recalcar que DBSCAN puede identificar valores atípicos, la cual es una de sus fortalezas con respecto a K-means.

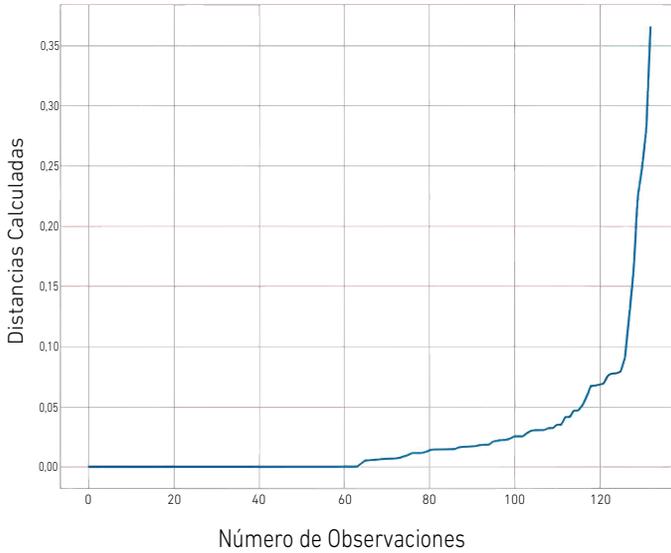
Gráfico de distancia basado en k vecinos más cercanos (KNN)

Siendo ϵ uno de los parámetros relevantes para DBSCAN, se puede recurrir al gráfico de distancia basados en vecinos para identificar un valor aproximado de ϵ . En la

Figura 2, se puede observar el gráfico de las distancias calculado para cinco vecinos, el valor que tomaremos es de 0,06.

Figura 2

Gráfica de distancias para cinco vecinos



2. DISCUSIÓN DE RESULTADOS

Luego de aplicar K-means con un k igual a 5, se obtuvieron los resultados que se muestran en la Tabla 1; se puede observar los cinco grupos nombrados de 0 a 4. Cada uno de los grupos tiene 52, 36, 5, 35 y 5 pacientes, respectivamente.

Tabla 1

Resultados del análisis clúster con K-means

Clústeres	Grupo 0	Grupo 1	Grupo 2	Grupo 3	Grupo 4
Número de pacientes	52	36	5	35	5
<i>Silhouette</i>	0,35	0,87	0,81	0,66	0,43
SENSIBILIDAD					
Amikacina	62	0	80	100	80
Fosfomicina	54	0	40	86	20
Nitrofurantóina	60	3	100	89	20
Gentamicina	69	3	40	89	60
Trimetoprima-sulfametoxazol	35	0	40	40	20
Ciprofloxacina	17	0	20	26	20

(continúa)

(continuación)

Clústeres	Grupo 0	Grupo 1	Grupo 2	Grupo 3	Grupo 4
SENSIBILIDAD					
Cefuroxima	62	0	0	97	20
Ampicilina + sulbactam	42	0	0	37	20
Cefepima	4	0	0	34	40
Ampicilina	10	0	0	11	20
Norfloxacin	29	0	0	3	0
Ácido Nalidíxico	21	0	0	14	0
Ceftazidima	17	0	0	34	20
Cefazolina	12	0	0	97	0
Cefalexina	15	0	0	63	0
Cefotaxima	31	0	0	60	20
Amoxicilina + ácido clavulánico	19	3	0	40	0
Ceftriaxona	56	0	0	34	20
Levofloxacin	6	3	0	3	20
Ertapenem	0	0	100	0	60
Meropenem	0	0	40	0	100
Imipenem	0	0	80	0	80
Piperacilina-tazobactam	0	0	80	0	60
S0tro	8	3	0	0	0
RESISTENCIA					
Trimetoprima-sulfametoxazol	46	3	20	49	80
Amoxicilina + ácido clavulánico	13	0	20	23	20
Fosfomicina	19	0	40	6	40
Ciprofloxacina	4	0	80	9	40
Ampicilina + sulbactam	10	0	100	3	40
Gentamicina	8	0	0	6	40
Ampicilina	63	0	0	49	20
Cefalexina	15	3	0	0	0
Nitrofurantoína	15	3	0	3	0
Norfloxacin	6	0	20	3	0
Aztreonam	0	0	100	0	0
Ceftriaxona	0	0	100	0	80
Cefepima	0	0	100	0	20
Ceftazidima	2	0	100	0	40
Cefotaxima	0	0	100	0	60
Cefazolina	13	0	100	0	20
Cefuroxima	4	0	100	0	80

(continúa)

(continuación)

Clústeres	Grupo 0	Grupo 1	Grupo 2	Grupo 3	Grupo 4
RESISTENCIA					
Ácido nalidíxico	12	0	80	0	0
ROtro	17	0	0	6	60
GERMEN					
Germen_ <i>E. Coli</i>	81	6	0	94	40
Germen_ <i>E. Coli BLEE</i>	0	0	80	0	0
Germen_ <i>Enterobacter cloacae</i>	6	0	0	6	0
Germen_ Flora mixta	0	25	0	0	0
Germen Otro	12	3	0	0	20

Nota. Los resultados incluyen la cantidad de pacientes por clúster y los porcentajes de pacientes que presentan sensibilidad/resistencia a los antibióticos o gérmenes.

En todos los grupos, excepto el grupo 1, se encontraron pacientes con sensibilidad a antibióticos como amikacina, fosfomicina, nitrofurantoína, gentamicina, trimetoprima-sulfametoxazol, ciprofloxacina, y resistencia a trimetoprima-sulfametoxazol, amoxicilina + ácido clavulánico, fosfomicina, ciprofloxacina y ampicilina + sulbactam. Hay ciertos antibióticos que sobresalen por el porcentaje de pacientes que presentan resistencia o sensibilidad. A continuación, se brinda mayor detalle de los grupos encontrados.

El grupo 1 está conformado por 36 pacientes. Este grupo se destaca porque el 25 % de las pacientes presenta flora mixta. Respecto a la sensibilidad y resistencia a antibióticos, no hay mayor relevancia de la cantidad de pacientes que presentan este tipo de condiciones.

El grupo 2 está compuesto por cinco pacientes, de los cuales el 80 % (4) presenta la bacteria *E. Coli BLEE*. Además de la resistencia y sensibilidad a los antibióticos comunes en todos los grupos, este grupo tiene un alto porcentaje de pacientes con sensibilidad al imipenem (80 %), piperacilina-tazobactam (80 %) y ertapenem (100 %). Asimismo, hay un alto porcentaje de resistencia al ácido nalidíxico (80 %) y todas las pacientes son resistentes a la ceftriaxona, cefepima, ceftazidima, cefotaxima, cefazolina, cefuroxima y aztreonam.

El grupo 4 está conformado por cinco pacientes que no presentan algún germen en especial. Este grupo tiene pocos pacientes (uno o dos) con sensibilidad y resistencia a varios antibióticos; sin embargo, al igual que el grupo 2, el 80 % de las pacientes muestra sensibilidad a imipenem. Además, todas son sensibles a meropenem. En cuanto a la resistencia, el 80 % es resistente a ceftriaxona y cefuroxima.

Los grupos 0 y 3 tienen 52 y 35 pacientes cada uno, respectivamente. La mayoría presenta el germen *E. Coli*, el 81 % en el grupo 0 y el 94 % en el grupo 3. Estos grupos son diferentes a los grupos 2 y 4 por la presencia de pacientes con resistencia a ciertos

antibióticos. Los grupos 0 y 3 presentan un 63 % y 49 % de pacientes, respectivamente, con resistencia a la ampicilina. El grupo 3 se destaca por contar con un mayor porcentaje de pacientes con sensibilidad a la amoxicilina + ácido clavulánico (40 %), cefazolina (97 %), cefalexina (63 %) y cefotaxima (60 %). Por el contrario, el grupo 0 posee el mayor porcentaje de pacientes con sensibilidad a la ceftriaxona (56 %). Ambos grupos también presentan alto porcentaje de pacientes con sensibilidad a la cefuroxima: 62 % en el grupo 0 y 97 % en el grupo 3.

Se realizó otro experimento con el algoritmo DBSCAN, para el cual se eligió trabajar con una eps de 0,06 y minPts de 5, valores tomados de acuerdo con la Figura 2. Los resultados se muestran en la Tabla 2. Los cuatro grupos identificados son nombrados de 0 a 3; además, por motivos de comparación con el experimento anterior, en la Tabla 2 se decidió ubicar el grupo 1, que corresponde a los valores atípicos. Cada uno de los grupos tiene 62, 7, 24, 9 y 31 pacientes, respectivamente. Este nuevo experimento separa notablemente, en los grupos 2 y 3, a las pacientes que no presentan ninguna de las condiciones consideradas como variables de análisis. La gran diferencia entre estos grupos es que, en el grupo 3, las nueve personas que forman parte de este grupo cuentan con el Germen_Flora mixta.

Además, podemos observar que en este experimento se pierden los clústeres que permiten identificar a las pacientes con resistencia a ciertos antibióticos, como son los casos de los grupos 2 y 4 de K-means. De este modo, quienes los conformaban ahora fueron identificadas como atípicas en el grupo -1 de DBSCAN.

En los grupos 0 y 1, se hallan las pacientes con características muy similares respecto a la sensibilidad y resistencia a ciertos antibióticos; la diferencia entre ellos radica en los porcentajes de pacientes que presentan cierta condición. Por ejemplo, el grupo 0 cuenta con porcentajes sobre 69 para la sensibilidad a la amikacina, fosfomicina, nitrofurantoína y gentamicina, y para el grupo 1 los porcentajes son menores a 43.

Tabla 2

Resultados del análisis clúster con DBSCAN

Clústeres	Grupo 0	Grupo 1	Grupo 2	Grupo 3	Grupo -1
Número de pacientes	62	7	24	9	31
<i>Silhouette</i>	0,33	0,78	0,99	1,00	
	SENSIBILIDAD				
Amikacina	89	14	0	0	61
Fosfomicina	69	14	0	0	55
Nitrofurantoína	82	43	0	0	48
Gentamicina	87	43	0	0	52
Trimetoprima-sulfametoxazol	39	71	0	0	19

(continúa)

(cotinuación)

Clústeres	Grupo 0	Grupo 1	Grupo 2	Grupo 3	Grupo -1
SENSIBILIDAD					
Ciprofloxacina	26	0	0	0	13
Cefuroxima	84	100	0	0	26
Ampicilina + sulbactam	34	71	0	0	32
Cefepima	19	0	0	0	13
Ampicilina	10	43	0	0	3
Norfloxacina	21	0	0	0	10
Ácido Nalidíxico	23	29	0	0	0
Ceftazidima	23	0	0	0	26
Cefazolina	56	14	0	0	13
Cefalexina	42	29	0	0	6
Cefotaxima	40	71	0	0	26
Amoxicilina + ácido clavulánico	34	14	0	0	10
Ceftriaxona	40	57	0	0	42
Levofloxacina	3	0	0	0	13
Ertapenem	0	0	0	0	26
Meropenem	0	0	0	0	23
Imipenem	0	0	0	0	26
Piperacilina-tazobactam	0	0	0	0	23
RESISTENCIA					
Trimetoprima-sulfametoxazol	44	14	0	0	61
Amoxicilina + ácido clavulánico	18	0	0	0	19
Fosfomicina	15	14	0	0	19
Ciprofloxacina	5	0	0	0	26
Ampicilina + sulbactam	2	0	0	0	39
Gentamicina	5	14	0	0	13
Ampicilina	58	14	0	0	45
Cefalexina	8	14	0	0	10
Nitrofurantoína	10	14	0	0	10
Norfloxacina	0	0	0	0	16
Aztreonam	0	0	0	0	16
Ceftriaxona	0	0	0	0	29
Cefepima	0	0	0	0	19
Ceftazidima	0	0	0	0	26
Cefotaxima	0	0	0	0	26

(cotinúa)

(continuación)

Clústeres	Grupo 0	Grupo 1	Grupo 2	Grupo 3	Grupo -1
RESISTENCIA					
Cefazolina	6	0	0	0	29
Cefuroxima	0	0	0	0	35
Ácido nalidíxico	3	0	0	0	26
GERMEN					
Germen_ <i>E. Coli</i>	90	71	0	0	58
Germen_ <i>E. Coli BLEE</i>	0	0	0	0	13
Germen_ <i>Enterobacter cloacae</i>	6	14	0	0	0
Germen_ Flora mixta	0	0	0	100	0
R0tro	8	0	0	0	29
S0tro	5	0	0	0	6
GermenOtro	2	14	0	0	19

3. CONCLUSIONES

El análisis clúster permitió identificar varios subgrupos clínicos entre las niñas con infecciones urinarias, en donde el germen presente con mayor frecuencia fue la *E. coli*; cada uno presentaba características de sensibilidad y resistencia diferentes a los antibióticos. Aquí se puede destacar uno de los grupos K-means (grupo 2), donde se observa al germen *E. coli*, productora de betalactamasa de ESPECTRO extendido (BLEE). A pesar de ser un grupo pequeño, se distingue a causa de la gran cantidad de antibióticos a los cuales las niñas son resistentes, como son todas las cefalosporinas (ceftriaxona, cefepima, ceftazidima, cefotaxima, cefazolina y cefuroxima). El tratamiento indicado de acuerdo con el resultado del antibiograma son los carbapenémicos (imipenem y ertapenem) y la piperacilina-tazobactam. Toda esta información se refleja en el grupo identificado por el algoritmo.

Los resultados son una evidencia de lo que está ocurriendo a nivel internacional sobre la resistencia bacteriana a los antibióticos comúnmente utilizados en el tratamiento empírico en las infecciones urinarias, así como de la generación de cepas productoras de betalactamasa de espectro extendido (BLEE). Con esto se puede facilitar la toma de decisiones en el tratamiento de infecciones urinarias de acuerdo con la evidencia y la epidemiología local, la misma que hasta el momento no se dispone. Por lo tanto, este estudio es un aporte para el tratamiento de infecciones urinarias en la región sur del Ecuador.

Los resultados de los algoritmos presentaron algunas semejanzas en ciertos grupos. El grupo 0, de ambos experimentos, agrupa a pacientes con sensibilidad y resistencia a ciertos antibióticos. El grupo 1 de K-means y 2 de DBSCAN son muy semejantes al presentar porcentajes bajos de pacientes en algunas de las condiciones de análisis. Si bien los dos algoritmos se caracterizan por contar con formas diferentes de identificar

los grupos, K-means se basa en distancias y DBSCAN, en densidad; en este experimento, DBSCAN tuvo valores más altos para *silhouette* en cada uno de los grupos identificados. Este algoritmo se destaca por identificar grupos más limpios, en el sentido de que todos los pacientes de un grupo comparten las mismas características, como es el caso de los grupos 2 y 3. En el grupo 2, ninguna de las pacientes presenta alguna condición de las analizadas. En el grupo 3, todas las pacientes presentan una única condición, que es el Germen_Flora mixta. Si bien este algoritmo no identifica a un grupo de pacientes con resistencia a ciertos antibióticos, DBSCAN los reconoce como atípicos.

Una de las principales limitantes de este trabajo fue la cantidad de registros a los que se tuvo acceso. Igualmente, solo se trabajó con información de los urocultivos con resultados infecciosos, el cual brindó la información del tipo de germen, la resistencia y sensibilidad antimicrobiana. Con respecto a la edad, se trabajó con niñas de 3 meses a 5 años; esta variable fue eliminada, ya que el rango de edad no se consideró relevante para este experimento. Asimismo, variables como lugar de nacimiento o residencia no fueron entregadas por cuestiones de anonimato; no obstante, cabe recalcar que, al tratarse de una muestra pequeña de un hospital local, las pacientes generalmente provienen del mismo lugar o lugares cercanos. Los resultados fueron obtenidos de una data de diez años, que podría justificar la variabilidad de la resistencia y la sensibilidad antimicrobiana, como se puede observar en otros estudios realizados (Whelan et al., 2024). Con esta limitante, también se presenta una oportunidad para que en un trabajo futuro se considere ampliar el número de registros y obtener otro tipo de información tanto clínica como demográfica.

A nivel técnico, para próximas investigaciones se podría ampliar la cantidad de algoritmos a utilizar o incluso hacer una combinación de los ya utilizados en este proyecto. También se podría comparar los resultados con otras técnicas de reducción de dimensionalidad, como el PCA logístico.

REFERENCIAS

- Ardila, M., Rojas, M., Santisteban, G., Gamero, A., & Torres, A. (2015). Infección urinaria en pediatría. *Repertorio de Medicina y Cirugía*, 24(2), 113-122. <https://doi.org/10.31260/RepertMedCir.v24.n2.2015.632>
- Banerjee, A., Dashtban, A., Chen, S., Pasea, L., Thygesen, J. H., Fatemifar, G., Tyl, B., Dyszynski, T., Asselbergs, F. W., Lund, L. H., Lumbers, T., Denaxas, S., & Hemingway, H. (2023). Identifying subtypes of heart failure from three electronic health record sources with machine learning: An external, prognostic, and genetic validation study. *The Lancet Digital Health*, 5(6), e370-e379. [https://doi.org/10.1016/s2589-7500\(23\)00065-1](https://doi.org/10.1016/s2589-7500(23)00065-1)
- Betrán, A., Lavilla, M. J., Cebollada, R., Calderón, J. M., & Torres, L. (2020). Resistencia antibiótica de *Escherichia coli* en infecciones urinarias nosocomiales y

- adquiridas en la comunidad del Sector Sanitario de Huesca 2016-2018. *Revista Clínica de Medicina de Familia*, 13(3), 198-202. <https://scielo.isciii.es/pdf/albacete/v13n3/1699-695X-albacete-13-03-198.pdf>
- Bolt, H., Suffel, A., Matthewman, J., Sandmann, F., Tomlinson, L., & Eggo, R. (2023). Seasonality of acute kidney injury phenotypes in England: An unsupervised machine learning classification study of electronic health records. *BMC Nephrology*, 24(1), 234. <https://doi.org/10.1186/s12882-023-03269-0>
- Cavagnaro Santa María, F. (2014). Resistencia antibiótica en la infección urinaria: la historia sin fin. *Boletín Médico del Hospital Infantil de México*, 71(6), 329-331. <https://doi.org/10.1016/j.bmhmx.2014.12.001>
- Chacaguasay, M., Reátegui, R., Valdiviezo-Díaz, P., & Chicaiza, J. (2024). Unsupervised techniques to identify patterns in gynecologic information. En G. Li, J. Filipe y Z. Xu (Eds.), *Communications in Computer and Information Science* (pp. 31-43). https://doi.org/10.1007/978-3-031-58956-0_3
- Elgoibar, B., Gangoiti, I., Garcia-Garcia, J. J., Hernandez-Bou, S., Gomez, B., Martinez, L., & Mintegi, S. (2020). Paediatric *Escherichia coli* bacteraemia presentations and high-risk factors in the emergency department. *Acta Paediatrica*, 110(3), 1032-1037. <https://doi.org/10.1111/apa.15549>
- Hadikurniawati W., Hartomo K. D., & Sembiring, I. (2023, 24 de noviembre). Spatial clustering of child malnutrition in central Java: A comparative analysis using k-means and DBSCAN. En *2023 International Conference on Modeling & E-Information Research, Artificial Learning and Digital Applications (ICMERALDA)* (pp. 242-247). Institute of Electrical and Electronics Engineers (IEEE). <https://doi.org/10.1109/icmeralda60125.2023.10458202>
- Hevia, P., Alarcón, C., Gonzalez, C., Nazal, V., & Rosati, M. P. (2020). Recomendaciones sobre diagnóstico, manejo y estudio de la infección del tracto urinario en pediatría. Rama de Nefrología de la Sociedad Chilena de Pediatría. Parte 1. *Revista Chilena de Pediatría*, 91(2), 281-288. <https://doi.org/10.32641/rchped.v91i2.1267>
- Hobensack, M., Zhao, Y., Scharp, D., Volodarskiy, A., Slotwiner, D., & Reading, M. (2023). Characterising symptom clusters in patients with atrial fibrillation undergoing catheter ablation. *Open Heart*, 10(2), e002385. <https://doi.org/10.1136/openhrt-2023-002385>
- Josephson, C. B., Gonzalez-Izquierdo, A., Engbers, J. D., Denaxas, S., Delgado-Garcia, G., Sajobi, T. T., Wang, M., Keezer, M. R., & Wiebe, S. (2023). Association of comorbid-socioeconomic clusters with mortality in late onset epilepsy derived through unsupervised machine learning. *Seizure: European Journal of Epilepsy*, 111, 58-67. <https://doi.org/10.1016/j.seizure.2023.07.016>

- Krueger, C., Alqurashi, W., Barrowman, N., Litwinska, M., & Le Saux, N. (2024). The long and the short of pediatric emergency department antibiotic prescribing: A retrospective observational study. *The American Journal of Emergency Medicine*, 75, 131-136. <https://doi.org/10.1016/j.ajem.2023.10.052>
- Leung, A. K. C., Wong, A. H. C., Leung, A. A. M., & Hon, K. L. (2019). Urinary tract infection in children. *Recent Patents on Inflammation & Allergy Drug Discovery*, 13(1), 2-18. <https://doi.org/10.2174/1872213X13666181228154940>
- Martins, C., Neves, B., Teixeira, A. S., Froes, M., Sarmiento, P., Machado, J., Magalhães, C. A., Silva, N. A., Silva, M. J., & Leite, F. (2024). Identifying subgroups in heart failure patients with multimorbidity by clustering and network analysis. *BMC Medical Informatics and Decision Making*, 24(1), artículo 95. <https://doi.org/10.1186/s12911-024-02497-0>
- Mohanty, S., Hassan, F. M., Lenke, L. G., Lewerenz, E., Passias, P. G., Klineberg, E. O., Lafage, V., Smith, J. S., Hamilton, D. K., Gum, J. L., Lafage, R., Mullin, J., Diebo, B., Buell, T. J., Kim, H. J., Kebaish, K., Eastlack, R., Daniels, A. H., Mundis, G., ... Bess, S. (2024). Machine learning clustering of adult spinal deformity patients identifies four prognostic phenotypes: A multicenter prospective cohort analysis with single surgeon external validation. *The Spine Journal*, 24(6), 1095-1108. <https://doi.org/10.1016/j.spinee.2024.02.010>
- Salamzade, R., McElheny, C. L., Manson, A. L., Earl, A. M., Shaikh, N., & Doi, Y. (2023). Genomic epidemiology and antibiotic susceptibility profiling of uropathogenic *Escherichia coli* among children in the United States. *mSphere*, 8(5), e00184-23. <https://doi.org/10.1128/msphere.00184-23>
- Shaikh, N., & Hoberman, A. (2022). *Urinary tract infections in children: Epidemiology and risk factors*. UpToDate. https://www.uptodate.com/contents/urinary-tract-infections-in-children-epidemiology-and-risk-factors?search=infection%20urinary%20children&source=search_result&selectedTitle=2~150&usage_type=default&display_rank=2#H2
- Suwono, B., Eckmanns, T., Kaspar, H., Merle, R., Zacher, B., Kollas, C., Weiser, A. A., Noll, I., Feig, M., & Tenhagen, B. (2021). Cluster analysis of resistance combinations in *Escherichia coli* from different human and animal populations in Germany 2014-2017. *PLoS ONE*, 16(1), e0244413. <https://doi.org/10.1371/journal.pone.0244413>
- Wazzan, A., Taconne, M., Le Rolle, V., Inngjerdingen, M., Hermann, K., Galli, E., Hernandez, A., Edvardsen, T., & Donal, E. (2024). Risk profiles for ventricular arrhythmias in hypertrophic cardiomyopathy through clustering analysis including left ventricular strain. *International Journal of Cardiology*, 409, 132167. <https://doi.org/10.1016/j.ijcard.2024.132167>

Whelan, S. O., Kyne, S., Dore, A., Glynn, M., Higgins, F., Hanahoe, B., Moriarty, F., Moylett, E., & Cormican, M. (2024). Paediatric *Escherichia coli* urinary tract infection: Susceptibility trends and clinical management. A retrospective analysis of a 10-year period. *Irish Journal of Medical Science*, 193, 1891-1900. <https://doi.org/10.1007/s11845-024-03670-0>

RED DE CONECTIVIDAD EN LA CUENCA DEL RÍO SANTIAGO: UN MODELO INNOVADOR PARA CONTRIBUIR AL CIERRE DE LA BRECHA DIGITAL EN EL MARCO DE LAS ALIANZAS MULTIACTOR

JUAN ANTONIO PACO FERNÁNDEZ

jpaco@pucp.edu.pe

<https://orcid.org/0000-0002-0584-8751>

Pontificia Universidad Católica del Perú

RIVER QUISPE TACAS

riquispe@pucp.edu.pe

<https://orcid.org/0000-0002-8434-2512>

Pontificia Universidad Católica del Perú

JOEL ARAGÓN VALLADARES

joel.aragon@pucp.edu.pe

<https://orcid.org/0009-0009-7613-4922>

Pontificia Universidad Católica del Perú

Recibido: 15 de setiembre del 2024 / Aceptado: 16 de octubre del 2024

doi: <https://doi.org/10.26439/interfases2024.n020.7401>

RESUMEN. Este artículo describe las características técnicas y las pruebas de desempeño de la red inalámbrica de banda ancha implementada en la cuenca del río Santiago (región Amazonas, Perú); además, detalla el contexto y el proceso de articulación interinstitucional en el que se ha desarrollado este proyecto. En el marco de una iniciativa amplia liderada por el Gobierno del Perú, se llevó a cabo un proceso de colaboración entre actores públicos, privados y la academia para el desarrollo de la provincia de Condorcanqui (región Amazonas, Perú); de este proceso surgieron diversos estudios y proyectos, entre ellos el diseño y la implementación de una solución de conectividad para la cuenca del río Santiago. El establecimiento de la red busca complementar los planes y proyectos que tiene el Estado en cuanto a la ampliación de la conectividad y los servicios de telecomunicaciones para cerrar la brecha digital en el Perú mediante una propuesta técnica no convencional. El principal resultado de la ejecución de este proyecto y del proceso seguido es la validación de una prueba de concepto sobre un modelo innovador de articulación, que busca combinar los esfuerzos de actores públicos y privados para reducir la brecha digital en comunidades rurales aisladas, con población escasa y dispersa. Además, la sostenibilidad de este despliegue también sigue un modelo innovador, que involucra a un operador de servicios de telecomunicaciones y promueve

el uso del acceso a internet por parte de las instituciones públicas de los sectores de salud y educación presentes en la cuenca del río Santiago. De ello se obtienen resultados complementarios como la capacitación de empleados públicos y el fortalecimiento de los servicios brindados por las instituciones públicas mediante la entrega de equipamiento médico e informático.

PALABRAS CLAVE: brecha digital / redes inalámbricas / áreas rurales / *backhaul* inalámbrico / diseño de red de datos / Alianzas Multiactor

ABSTRACT. This article describes the technical characteristics and performance tests of the broadband wireless network implemented in the Santiago River basin (Amazon Region - Peru). It also details the context and the process of inter-institutional coordination in which this project has been developed. Within the framework of a broad initiative led by the Peruvian National Government, a collaboration process was carried out between public and private actors and academia for the development of the province of Condorcanqui (Amazon Region - Peru). From this process, various studies and projects emerged, including the design and implementation of a connectivity solution for the Santiago River basin (Amazon Region - Peru). The implementation of the network seeks to complement the plans and projects that the State has regarding the expansion of connectivity and telecommunications services to close the digital divide in Peru, through an unconventional technical proposal. The main result of this project's execution, and the corresponding process, is the validation of a proof of concept for an innovative articulation model that seeks to combine the efforts of public and private actors to reduce the digital divide in isolated rural communities with sparse and dispersed populations. Furthermore, the sustainability of this deployment also follows an innovative model involving a telecommunications service operator and promoting Internet access by public institutions in the Health and Education sectors present in the Santiago River basin. It yields complementary results, such as the training of public employees and the strengthening of the services provided by public institutions through the delivery of medical and computer equipment.

KEYWORDS: digital divide / wireless networks / rural areas / wireless backhaul / data network design / multi-stakeholder partnerships

INTRODUCCIÓN

Actualmente, en el Perú, al igual que en varios países de Latinoamérica, siguen existiendo centros poblados rurales sin conexión a internet o con un servicio lento e intermitente. Lo mismo se puede decir, aunque en menor medida, sobre otros servicios de telecomunicaciones como la telefonía móvil. En el Perú, solo el 11 % de los centros poblados rurales dispone de internet fijo, en tanto que alrededor del 20 % cuenta con internet móvil 4G (Pronatel, 2022, p. 25). Por otro lado, la alta dispersión de los centros poblados y lo amplio del territorio dificultan que las empresas operadoras de servicios de telecomunicaciones y el propio Gobierno inviertan en redes terrenas tradicionales (microondas o fibra óptica) para brindar cobertura a estas poblaciones.

En el caso peruano, la mayoría de estos centros poblados tiene una población menor a 300 habitantes (Pronatel, 2021, p. 35), por lo que, en general, no son de interés para las empresas de telecomunicaciones por la baja demanda esperada. Para atender esta problemática, el Gobierno peruano ha creado el Programa Nacional de Telecomunicaciones (Pronatel), el cual es la institución gubernamental encargada de reducir la brecha de conectividad en las zonas rurales, objetivo que, a la fecha, aún se encuentra en proceso.

La falta de acceso a servicios de telecomunicaciones limita el desarrollo económico y la calidad de vida (MTC, 2023, p. 9). Es necesario diseñar nuevos modelos de financiamiento y cooperación para colaborar con el Gobierno en el despliegue de infraestructura y la promoción del uso de la tecnología y los recursos de banda ancha.

Frente a esta problemática, el Gobierno Regional de Amazonas, el Capítulo Perú del Plan Binacional Perú-Ecuador, la Secretaría de Gobierno y Transformación Digital de la Presidencia del Consejo de Ministros del Perú (SGTD-PCM), la Municipalidad Provincial de Condorcanqui, la Pontificia Universidad Católica del Perú (PUCP) y otras instituciones han colaborado para diseñar e implementar una solución de conectividad de banda ancha para la cuenca del río Santiago con el fin de permitir el acceso a internet a instituciones públicas de los sectores salud y educación de cinco centros poblados de esta zona. La PUCP ha realizado el diseño e implementación de esta red en tanto que la gestión y el financiamiento se ha efectuado en el marco de una Alianza Multiactor liderada por el propio Gobierno.

Este artículo describe tanto el modelo innovador de asociación multiactor que permitió la implementación de la red, así como el plan para su sostenibilidad y la descripción técnica de la propia red de telecomunicaciones. Esta red se encuentra operando y ha podido demostrar que sí existen vías alternativas para desplegar infraestructura de telecomunicaciones y reducir la denominada "brecha residual" (Ramírez García & Blanco Romero, 2021).

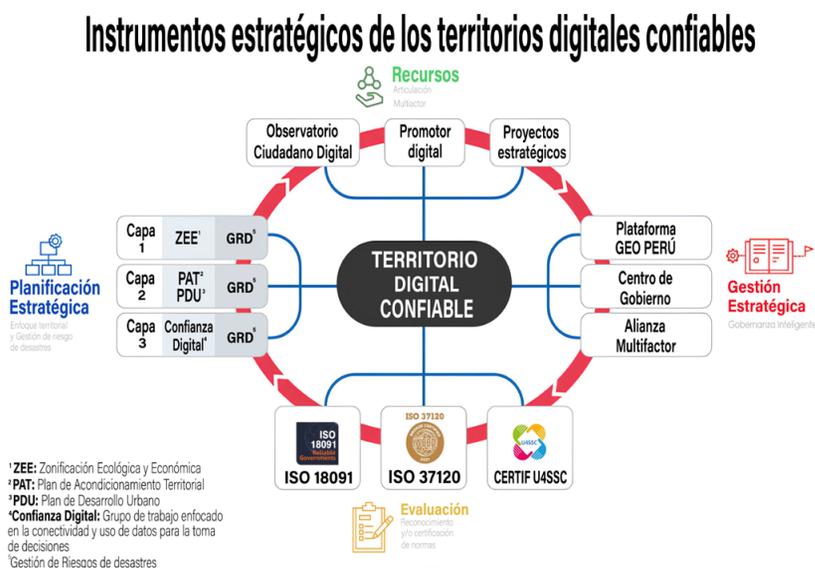
1. ALIANZA MULTIACTOR EN LA PROVINCIA DE CONDORCANQUI

En setiembre del 2015, la Organización de las Naciones Unidas (ONU) definió y aprobó 17 objetivos de desarrollo sostenible y 169 metas para la implementación de la denominada Agenda 2030. Esta propuesta de desarrollo es “un plan de acción en favor de las personas, el planeta y la prosperidad que también tiene por objeto fortalecer la paz universal dentro de un concepto más amplio de la libertad” (ONU, 2015, párr. 1).

En este marco, la SGT-D-PCM ha venido impulsando dos iniciativas importantes. Por un lado, la primera es la plataforma web Geo Perú, de acceso libre, la cual es una “plataforma digital de datos georreferenciados que integra información de fuentes oficiales del Estado. Permite identificar las brechas sociales, económicas, de infraestructura, entre otras, para la toma de decisiones a nivel territorial” (PCM, 2024, párr. 1). Por otro lado, la segunda iniciativa se denomina Alianzas Multiactor para el Desarrollo de Territorios Digitales Confiables, que, en la práctica, es un “proceso de articulación interinstitucional enmarcado en el Enfoque Territorial y las Alianzas Multiactor” (PCM, 2022, párr. 1). En base a ambas herramientas y a la concepción y visión de la SGT-D-PCM (ver Figura 1), se desarrolló y promovió un conjunto de iniciativas en colaboración con otras instituciones públicas como ministerios, gobiernos regionales y municipalidades.

Figura 1

Instrumentos estratégicos de los territorios digitales confiables



Nota. De Plataforma Nacional de Datos Georreferenciados Geo Perú por PCM, 2022 (<https://www.geoperu.gob.pe/alianza-multiactor/>).

Estas iniciativas se implementan con una metodología de intervención que se basa en el ordenamiento territorial para la realización de un conjunto articulado de proyectos que, como en el caso de Condorcanqui, han incluido:

- I. Zonificación ecológica y económica
- II. Plan de Acondicionamiento Territorial, Plan de Desarrollo Urbano y Esquemas de Ordenamiento Urbano
- III. Carga de información provincial a la plataforma Geo Perú
- IV. Estudio hidromorfológico para la cuenca del río Santiago
- V. Diseño e implementación de la red de conectividad digital de la cuenca del río Santiago

En forma específica y como parte de este proceso, se han desarrollado diversas actividades y coordinaciones con instituciones públicas y privadas para el desarrollo sostenible de la provincia de Condorcanqui y, por extensión, de la región Amazonas. Para ello se han implementado un conjunto de mesas de trabajo con carácter multiactor que gestionan estos proyectos específicos en el territorio.

Debe indicarse que la evolución estratégica de la amplia iniciativa se ha organizado en etapas cuyos hitos coinciden con la realización de talleres multiactor, liderados por la PCM, en donde se articulan las diferentes mesas de trabajo para integrar propuestas y proyectos en forma sinérgica. Desde esta perspectiva, en octubre de 2018 se realizó el 1.º Taller de Coordinación Interinstitucional en la Universidad ESAN, donde se organizaron mesas de trabajo para abordar la problemática local enfocada en tres temas: conectividad digital, capacidades y agua y saneamiento. Asimismo, el 14 de marzo de 2019 se realizó en la PUCP el segundo taller con la presencia del viceministro de Gobernanza, representantes de la PCM, del Plan Binacional y de más de veinte instituciones públicas y privadas, donde la mesa de conectividad digital fue dirigida por el Grupo de Telecomunicaciones Rurales (GTR). En forma más reciente, el 15 de octubre de 2020, se realizó un quinto taller en modalidad virtual, en el cual se firmaron acuerdos de los diferentes actores con los gobiernos regionales de Amazonas, Tumbes y Cajamarca, con el fin de consolidar los compromisos de los involucrados. Finalmente, en abril de 2023, se realizó el séptimo taller, el cual abrió una nueva etapa en la que se buscó consolidar el escalamiento de la iniciativa hacia otras regiones como Tumbes y Piura; además, amplió la cantidad de gobiernos regionales y locales que aplicasen a la obtención de la certificación ISO 18091.

1.1. Mesa de conectividad digital para la provincia de Condorcanqui

La mesa se centró en utilizar la tecnología de manera eficiente para mejorar la calidad de vida de la población del Condorcanqui, con pleno respeto a la sostenibilidad y la

interculturalidad. Se destacó la importancia de incorporar proyectos de investigación, desarrollo e innovación (I+D+i) y otros mecanismos para crear modelos replicables que puedan resolver problemas complejos, especialmente en la Amazonía.

En 2019, se realizó un estudio sobre una solución de conectividad digital para la Cuenca del río Santiago, financiado por el Capítulo Perú del Plan Binacional Perú-Ecuador y ejecutado por el GTR-PUCP. Los resultados se entregaron en noviembre de ese año y, precisamente, durante el quinto taller multiactor (octubre de 2020), el Gobierno Regional de Amazonas, la Municipalidad Provincial de Condorcanqui y el Capítulo Perú del Plan Binacional Perú-Ecuador se comprometieron a financiar la implementación del primer tramo de esta red, con el apoyo de la SGT-D-PCM y la colaboración de las instituciones de la mesa de trabajo. Nuevamente, la PUCP a través del GTR se hizo cargo de la ejecución del proyecto.

Para su ejecución fue necesaria la elaboración de un proyecto de inversión pública, el cual fue aprobado en 2021. Luego de este hito, se realizaron las compras, trámites administrativos y actividades preparatorias que permitieron iniciar las actividades en sitio en agosto de 2022. Debe mencionarse que, a pesar de la pandemia por COVID-19, los episodios de convulsión social y los problemas de acceso derivados del sismo ocurrido a finales del año 2021 en Amazonas, se concluyó la instalación de la red de conectividad a mediados del año 2023 y se continuó con las actividades de fortalecimiento de los sectores salud y educación, y las coordinaciones con los distintos actores para el aseguramiento de su sostenibilidad.

2. RELEVANCIA Y SOSTENIBILIDAD

El proyecto es significativo porque es la primera iniciativa completada bajo la propuesta gubernamental Alianzas Multiactor para el Desarrollo de Territorios Digitales Confiables. Sirve como prueba de concepto y valida la metodología aplicada (como modelo de negocio). Por lo tanto, el siguiente paso es formalizar una política pública. Además, se está replicando esta experiencia en Tumbes y se están coordinando intervenciones similares en otras regiones. Es importante resaltar, según se observa, que el actor principal de este modelo de asociación es el Gobierno en sus tres niveles (nacional, regional y local) mientras que la academia, las empresas y las fuentes cooperantes son socios alineados con los objetivos nacionales.

Esta red de conectividad, desplegada por el Proyecto Río Santiago, está operativa desde junio de 2023. Alrededor de esta solución, se ha logrado desarrollar otros planes relacionados a salud y educación en cinco comunidades rurales. Así, la PUCP y la Fundación Enlace Hispano Americano de Salud (EHAS) obtuvieron financiamiento de la Agencia Española de Cooperación Internacional para el Desarrollo (AECID) y la Comunidad de Madrid para mejorar estos servicios mediante equipamiento multimedia,

teleservicios y capacitación. También se busca coordinar con operadores para ofrecer telefonía móvil 4G. La información sobre estos financiamientos fue compartida con los socios de la Alianza Multiactor y gestionada en la mesa de conectividad.

El proyecto de conectividad en la cuenca del río Santiago no solo contempló el diseño y despliegue de una red de telecomunicaciones de banda ancha, sino también contempló un modelo de sostenibilidad para la red. Esta condición podría hacerse viable con la participación de una empresa operadora que brinde servicios móviles 4G con el uso de la infraestructura de la red. De este modo, su sostenibilidad ha sido gestionada en una mesa de coordinación multiactor, la cual logró un compromiso formal del Gobierno Regional de Amazonas y otras instituciones públicas para garantizar su desarrollo. Para ello se ha previsto la contratación de un operador rural de telecomunicaciones para el mantenimiento de la red; el Gobierno Regional ha asignado fondos para la operación y conservación durante el proceso de coordinación con el operador, que ya está en curso.

Finalmente, como parte de la réplica y continuidad del proyecto, las instituciones del comité de coordinación, lideradas por el gobierno regional, se han comprometido a una segunda fase del proyecto. Esta fase busca completar la red de telecomunicaciones desde Puerto Galilea hasta la comunidad de Cahuide, cerca de la frontera con Ecuador. Los estudios preliminares están en curso y se espera que concluyan al final del presente año 2024.

3. DESCRIPCIÓN TÉCNICA DE LA RED DE CONECTIVIDAD

El río Santiago está ubicado en la región de Amazonas en Perú, tiene unos 200 km de longitud y alberga comunidades nativas awajún y wampís sin servicios básicos como electricidad, agua potable y teléfono; incluso, el acceso a estos pueblos es solo por vía fluvial. Santa María de Nieva es el poblado más desarrollado, pero también tiene muchas carencias y está a unos 300 km por carretera de Chachapoyas, la capital del departamento.

Según se aprecia en la Figura 2, la red del río Santiago se implementó en la cuenca de este río y en parte de la cuenca del río Marañón, ubicadas en la zona norte del departamento de Amazonas en Perú. La red de datos cubre los poblados de Santa María de Nieva, Pagkintsa, Belén, Guayabal, Yutupis y Galilea, donde se implementó principalmente para brindar acceso a internet a centros educativos y de salud. Adicionalmente, dentro de la red se han implementado servicios de telefonía VolP, videoconferencia (IETF, 2022), telesalud y acceso a repositorios educativos.

Figura 2

Pueblos pertenecientes a la red del río Santiago

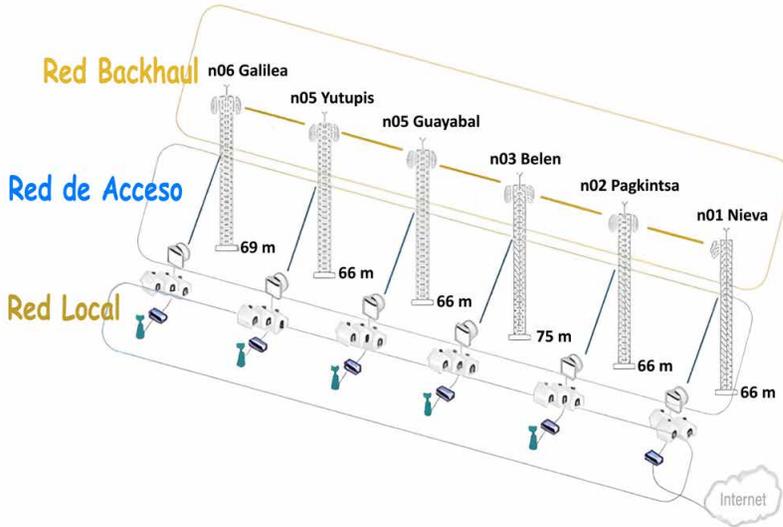


Nota. Pueblos que involucra a la red Río Santiago.

La red de datos del río Santiago se ha dividido en tres partes: la red *backhaul*, la red de acceso y la red local (Martínez-Fernández et al., 2016; Ting et al., 2012; Quispe Tacas et al., 2021; Simo-Reigadas et al., 2015). En la Figura 3, se muestra un diagrama general de la red, así como la altura de las torres (m) y la distancia (km) de los enlaces. La infraestructura también se ha dispuesto en la torre de telecomunicaciones, el sistema de energía y el sistema de protección eléctrica. Además, esta red de datos se ha implementado con el uso principalmente de enlaces inalámbricos en banda libre (MTC, 2013a, 2013b).

Figura 3

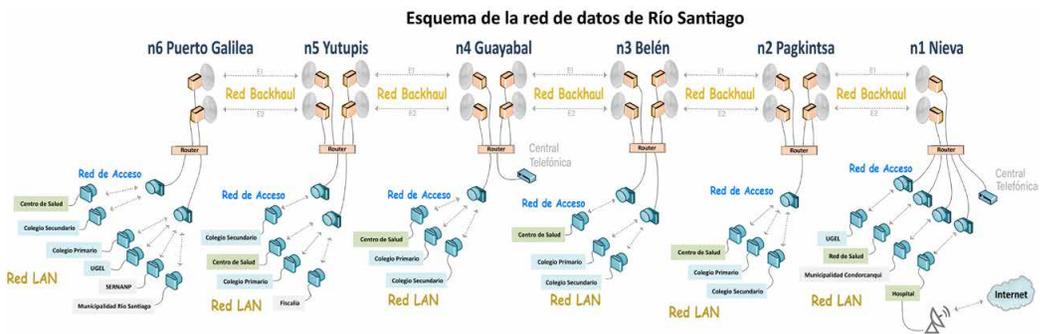
Topología de la red del río Santiago



La red *backhaul* está compuesta por enlaces inalámbricos de larga distancia y se utiliza para interconectar todas las localidades que conforman el proyecto; está diseñada con un doble enlace inalámbrico paralelo entre cada localidad. La red de acceso está compuesta por enlaces inalámbricos de corta distancia para conectar a las instituciones beneficiarias con la red *backhaul*; estos enlaces van desde la torre hasta las instituciones. La red local está compuesta por los equipos de red que utilizará el usuario en cada institución para acceder a los servicios que ofrece la red. En la Figura 4, se muestra un diagrama de las tres redes.

Figura 4

Diagrama de la red del río Santiago



3.1. Red *backhaul*

La red *backhaul* está compuesta por diez enlaces inalámbricos punto a punto de larga distancia que se extienden desde el poblado de Nieva hasta Puerto Galilea; sin embargo, entre cada localidad se ha instalado un doble enlace inalámbrico en paralelo (ver Tabla 1). La distancia de los enlaces inalámbricos va desde los 5 km hasta los 30 km, los cuales están configurados en la banda libre de 5 GHz y cumplen con las restricciones establecidas por el Ministerio de Transportes y Comunicaciones (MTC). Para redirigir el tráfico de datos entre las instituciones beneficiarias, se utiliza un *router* Mikrotik 4011 en cada nodo del *backhaul* (Mikrotik, 2024a). El equipo utilizado para implementar los enlaces inalámbricos es el Cambium PTP 670 (Cambium Networks, 2018), y en los enlaces críticos se utilizan antenas tipo UHPX (Ultra High Performance Extreme) para minimizar las posibles interferencias.

Tabla 1
Enlaces inalámbricos de backhaul

Enlace inalámbrico del <i>backhaul</i> punto a punto	Zona que atraviesa el enlace	Enlace	Frecuencia (MHz)	Distancia (km)
Yutupis (M1) – Galilea (S1)	Zona rural	E1	5805	5
Yutupis (M2) – Galilea (S2)		E2	5320	
Guayabal (M1) – Yutupis (S1)	Zona rural	E1	5250	13
Guayabal (M2) – Yutupis (S2)		E2	5805	
Belén (M1) – Guayabal (S1)	Zona rural	E1	5825	9
Belén (M2) – Guayabal (S2)		E2	5765	
Pagkintsa (M1) – Belén (S1)	Zona rural	E1	5320	30
Pagkintsa (M2) – Belén (S2)		E2	5250	
Nieva (M1) – Pagkintsa (S1)	Zona rural urbano	E1	5280	16
Nieva (M2) – Pagkintsa (S2)		E2	5320	

3.2. Red de acceso

La red de acceso permite la interconexión de la red local de las instituciones beneficiarias con el *backhaul*. Esta red está implementada mediante doce enlaces inalámbricos del tipo punto a punto y punto a multipunto, la distancia de estos enlaces es menor a 2 km, están configurados en la banda libre de 5 GHz y cumplen las restricciones establecidas por el MTC. En la Tabla 2, se muestran los doce enlaces de acceso que se han implementado en cada localidad, los doce máster de acceso y 23 clientes de acceso que lo conforman. Los equipos de telecomunicaciones son Disk Lite (Mikrotik, 2024b), MantBox (Mikrotik, 2024c) y DynaDish Mikrotik (Mikrotik, 2024d).

Tabla 2*Enlaces de inalámbricos de la red de acceso*

Pueblos	Número de máster de acceso	Número de clientes de acceso	Frecuencia (MHz)	Cantidad y tipo de enlaces de acceso
Nieva	4	4	5745	4 PtP ^a links (1 cliente) de 800 m
			5745	
			5745	
			5765	
Pagkintsa	1	3	5745	1 PtM ^b link (3 clientes) de 1,5 km
Belén	2	3	5320	1 PtM link (2 clientes) de 300 m
			5280	1 PtP link (1 cliente) de 1,7 km
Guayabal	1	3	5745	1 PtM link (3 clientes) de 400 m
Yutupis	2	4	5745	1 PtM link (3 clientes) de 1 km
			5825	1 PtP link (1 cliente) de 900 m
Galilea	2	6	5745	1 PtM link (2 clientes) de 700 m
			5825	1 PtM link (4 clientes) de 1,1 km

Nota. ^a PtP: Punto a punto. ^b PtM: Punto a multipunto

3.3. La red local de usuarios

En cada institución se ha implementado un *router* y un punto de acceso wifi BaseBox 2 (Mikrotik, 2024e), el cual permite a todos los usuarios conectarse a los servicios de red.

3.4. Acceso a internet

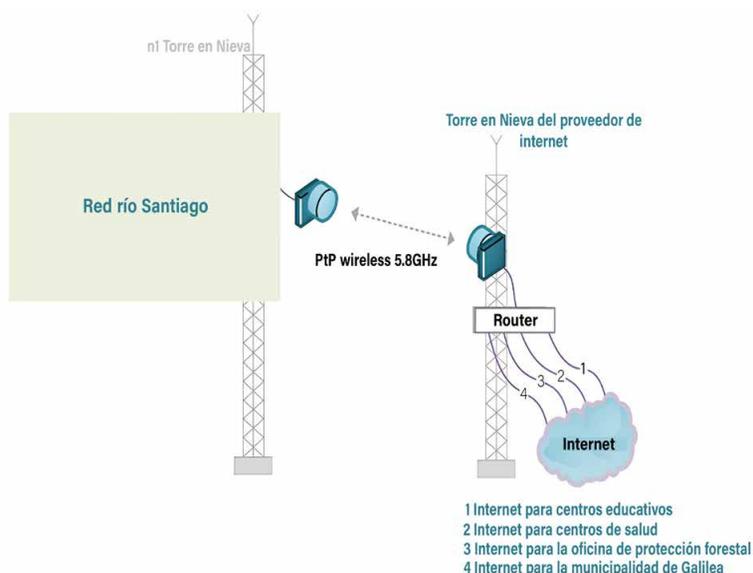
Para conectar la red al servicio de acceso a internet, se ha instalado temporalmente en Nieva, específicamente en el Hospital Santa María de Nieva, un módulo Starlink (Starlink, 2024a, 2024b). Los usuarios hacen uso de este sistema, pero posteriormente las instituciones de salud y educación deberán contratar su propio servicio de internet a través de una empresa operadora ubicada en Nieva (ver Figura 5). Actualmente, la capacidad de acceso a internet con Starlink se asigna de acuerdo con la demanda de cada institución; sin embargo, ello no garantiza una capacidad o disponibilidad específica para su conexión. Por ese motivo, se realizaron mediciones de ancho de banda de manera continua mediante Speedtest durante aproximadamente dos semanas y se obtuvo un promedio de 40/28 MB/s (*downlink/uplink*), que representó una disponibilidad de 99,5 %.

3.5. Acceso a internet cuando la red sea entregada al Gobierno Regional de Amazonas

El servicio de internet que se brinda actualmente a las instituciones es temporal. La meta es que los titulares de las instituciones de salud y educación contraten este servicio en Nieva; la red del río Santiago será el medio para llevar internet a estas instituciones ubicadas en la cuenca del río Santiago. Una empresa de telecomunicaciones en Nieva ya está empezando a brindar el servicio de internet, por lo que el siguiente paso es que las instituciones se pongan de acuerdo para contratarlo. La Figura 5 muestra la futura interconexión de la red del río Santiago con el operador de internet que estará iniciando sus servicios en los próximos meses.

Figura 5

Interconexión entre la red del río Santiago y la empresa proveedora de internet



3.6. Alimentación eléctrica de los equipos

En estas poblaciones no existe servicio público de electricidad y si lo hay es muy inestable. Por ello, se ha optado por utilizar sistemas fotovoltaicos para abastecer de electricidad a los equipos de la red.

4. PRUEBAS DE DESEMPEÑO DE LA RED DE CONECTIVIDAD

4.1. Capacidad de la red *backhaul*

Para determinar el desempeño de la red, se realizaron pruebas de medición de *throughput* tanto en la red de *backhaul* como en la red de acceso. La red de *backhaul* ha sido

diseñada para proporcionar 10 MB/s (descarga)/3 MB/s (carga) a cada institución para el acceso a internet si todos acceden de manera simultánea; por lo tanto, el enlace crítico para soportar este tráfico es el de Nieva-Pagkintsa, que debería soportar alrededor de 210 MB/s en total. En la Tabla 3, observamos que, de acuerdo con las pruebas, en el mejor de los casos, se tiene 260 MB/s en el enlace Nieva-Pagkintsa, lo que cumple así con el plan de diseño. Los datos fueron obtenidos del mismo equipo Cambium.

Tabla 3*Capacidad de la red backhaul*

Enlaces inalámbricos	Throughput agregado y potencia de recepción	
E1 M1-S2 5805 MHz	Nieva M1	Pagkintsa S1
	-59 dBm	-59 dBm
	280 MB/s	280 MB/s
E2 M2-S2 5320 MHz	Nieva M2	Pagkintsa S2
	-65 dBm	-65 dBm
	260 MB/s	260 MB/s
E1 M1-S2 5250 MHz	Pagkintsa M1	Belén S1
	-59 dBm	-59 dBm
	280 MB/s	280 MB/s
E2 M2-S2 5320 MHz	Pagkintsa M2	Belén S2
	-51 dBm	-50 dBm
	210 MB/s	210 MB/s
E1 M1-S2 5825 MHz	Belén M1	Guayabal S1
	-46 dBm	-45 dBm
	310 MB/s	310 MB/s
E2 M2-S2 5785 MHz	Belén M2	Guayabal S2
	-47 dBm	-46 dBm
	260 MB/s	260 MB/s
E1 M1-S2 5320 MHz	Guayabal M1	Yutupis S1
	-49 dBm	-48 dBm
	270 MB/s	270 MB/s
E2 M2-S2 5260MHz	Guayabal M2	Yutupis S2
	-52 dBm	-53 dBm
	210 MB/s	210 MB/s

(continúa)

(continuación)

Enlaces inalámbricos	Throughput agregado y potencia de recepción	
E1 M1-S2 5280 MHz	Yutupis M1	Galilea S1
	-52 dBm	-52 dBm
	350 MB/s	350 MB/s
E2 M2-S2 5320 MHz	Yutupis M2	Galilea S2
	-49 dBm	-48 dBm
	309 MB/s	310 MB/s

4.2. Capacidad de la red de acceso

Los enlaces inalámbricos no presentan problemas de capacidad para cada institución. En la Tabla 4, se muestra como ejemplo la capacidad obtenida en el enlace Galilea para sus seis clientes, que tiene garantizado alrededor de 50 MB/s para cada institución.

Tabla 4

Capacidad de la red de acceso de Galilea

Máximo throughput agregado	
Máster de acceso 1	Colegio secundario 150 MB/s máximo, garantizado 75 MB/s
Máster de acceso 1	Municipalidad 150 MB/s máximo, garantizado 75 MB/s
Máster de acceso 2	Centro de salud 150 MB/s máximo, garantizado 50 MB/s
Máster de acceso 2	Escuela primaria 220 MB/s máximo, garantizado 50 MB/s
Máster de acceso 2	UGEL 220 MB/s máximo, garantizado 50 MB/s
Máster de acceso 2	Sernanp 200 MB/s máximo, garantizado 50 MB/s

4.3. Capacidad de la red local

En cada institución, los puntos de acceso (AP, del inglés *Access Point*) wifi (IEEE 802.11n) podrán controlar hasta treinta usuarios y su capacidad será de 200 MB/s.

4.4. Latencia y disponibilidad de la red *backhaul*

La red *backhaul* es la red más crítica para el correcto funcionamiento de todo el sistema, por lo que se le realizan mediciones de latencia y disponibilidad (Osiptel, 2018, 2023). Se han desarrollado pruebas durante dos semanas y se ha obtenido que la red muestra una latencia de 6 ms (tiempo de ida y vuelta) y una disponibilidad del 99,53 % (esto representa alrededor de 4 horas de inactividad al año). La medición se efectuó desde el borde de la red *backhaul* con el comando *ping*, con un tamaño de paquete de 1500 bytes. Los resultados de disponibilidad y latencia obtenidos cumplen con los parámetros de calidad sugeridos por Osiptel (2018, 2023) para este tipo de red, por lo que cualquier empresa de telecomunicaciones puede estar interesada en utilizar esta red.

5. RESULTADOS DE LA CAPACIDAD DE LA RED DE CONECTIVIDAD

La red del río Santiago se encuentra operativa desde hace 16 meses y permite que cinco centros de salud y diez centros educativos dispongan de internet. El 17 de junio, la red del río Santiago contaba con 230 usuarios que utilizaban la red. También permitía conectar a los centros de salud con el Hospital Santa María de Nieva para realizar teleconsultas, y a los centros educativos con su respectiva Unidad de Gestión Educativa Local (UGEL). Incluso, posteriormente permitirá que la Municipalidad de Galilea y la Oficina de Protección Forestal de Galilea accedan a internet. En las Figuras 6 al 9, se muestran las torres de telecomunicaciones de la red y el uso que los beneficiarios hacen de la red. En la Figura 6, se muestra el doble enlace inalámbrico del *backhaul* con antenas UHPX de MIMO 2x2 (del inglés *Multiple Input Multiple Output*).

Figura 6

Torre en el pueblo de Nieva



Figura 7

Torre en el pueblo de Galilea



Figura 8

Uso de internet y repositorios digitales en la escuela de Belén



Figura 9

Inducción a la plataforma Telesalud para el personal de salud de Yutupis, Galilea y Belén



5.1. Tráfico global hacia internet

La Figura 10 presenta el tráfico de descargas de internet durante siete días, generado por todos los usuarios de la red. Se puede observar que el mayor volumen de descargas ocurre entre las 6 y las 15 h, que corresponde aproximadamente a 40 MB/s. Por otro lado, la Figura 11 muestra el tráfico de subida a internet durante el mismo periodo, el cual se limita solo a unos 15 MB/s.

Figura 10

Tráfico global de descargas desde internet

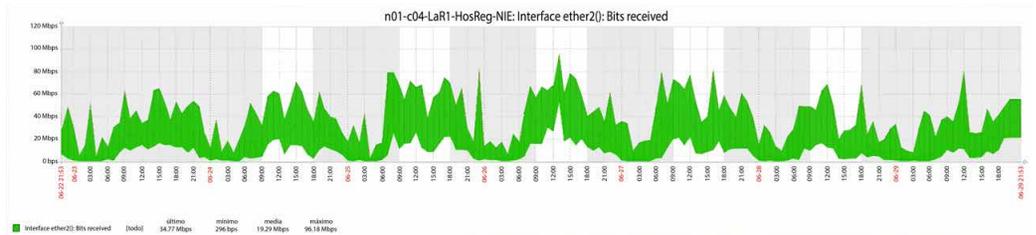
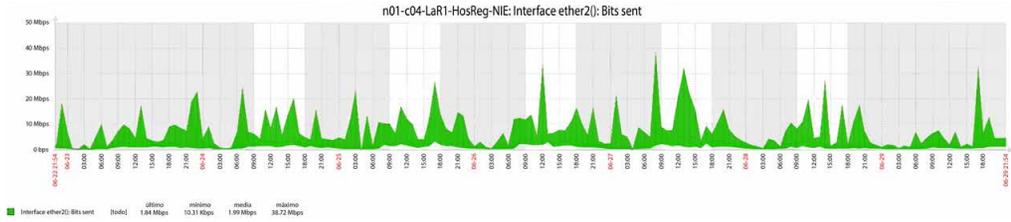


Figura 11

Tráfico de carga global a internet

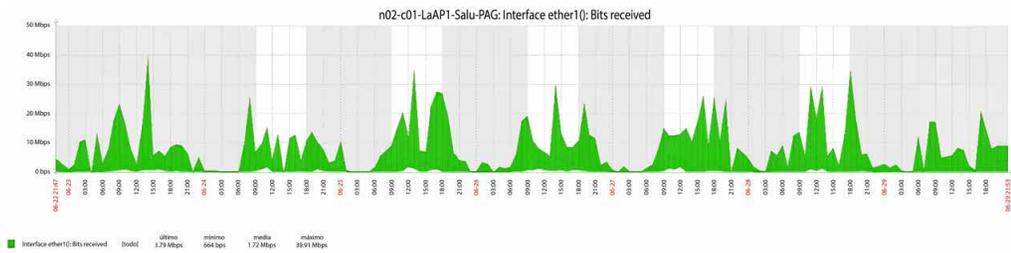


5.2. Tráfico de internet de cada institución

En la Figura 12, se presenta el tráfico de descarga del centro de salud de Pagkintsa durante los siete días. En horas pico se observa un promedio de 10 MB/s.

Figura 12

Tráfico de internet del centro de salud y Pagkintsa

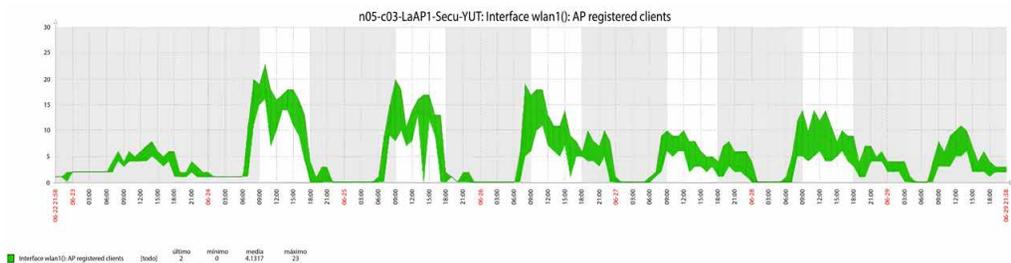


5.3. Número de usuarios que utilizan la red

En la Figura 13, se muestra el número de usuarios de un colegio en Yutupis que utiliza la red en siete días. Se observa que hay un máximo de 23 usuarios que utilizan la red simultáneamente en un día específico.

Figura 13

Número de usuarios que utiliza la red en una escuela secundaria en Yutupis



6. ANÁLISIS PARA LA IMPLEMENTACIÓN DEL SERVICIO MÓVIL 4G EN LA RED DE CONECTIVIDAD

Uno de los problemas de la red es su mantenimiento. Para solucionarlo, la red podría ser cedida a una empresa privada de telecomunicaciones para ofrecer el servicio móvil 4G, pero antes se debe demostrar que el *backhaul* de la red puede ser usado también como *backhaul* del servicio móvil. Para ofrecer el servicio móvil 4G, se necesitan estaciones base en cada pueblo, los cuales deberán estar conectados al *router* del *backhaul* y uno de sus enlaces se podrá usar como el *backhaul* del servicio móvil.

En Perú, la banda más baja para el servicio móvil es la de 700 MHz (B28), adjudicada en 2016 a tres operadores. Esta banda ofrece mayor cobertura y mejor penetración, de modo que optimiza la cantidad de estaciones base necesarias y proporciona servicios móviles adecuados para zonas rurales. Los valores pico en una estación base 4G con MIMO 2x2 y un ancho de canal de 15 MHz son 110,1 MB/s de descarga y 37,9 MB/s de carga, aunque en condiciones promedio se logran 25,5 MB/s de descarga y 10,5 MB/s de carga (Metsälä & Salmelin, 2015).

A continuación, se calculan los requisitos de capacidad de ancho de banda para atender cada centro poblado con servicio móvil 4G, ya que este servicio se agregará a la red inalámbrica del *backhaul*. Las consideraciones por cada centro poblado son las siguientes:

- Cantidad de estaciones base: 1
- Banda: 700 Mhz
- Diversidad: MIMO 2x2
- Operador móvil de red: 1
- Tipo de antena: Omnidireccional
- Población promedio: 300 habitantes
- Penetración móvil en la región Amazonas al 2022 (Observatorio Nacional de Prospectiva, 2024, Fig. 5): 53,9 %
- Concurrencia: 6 %
- Cantidad de sectores: 1
- Velocidad de descarga por usuario: 2 MB/s
- Velocidad de carga por usuario: 1 MB/s

$$\text{Capacidad DL por nodo de 1 sector} = 300 \times 53,9 \% \times 6 \% \times 1 \times 1 = 19,4 \text{ MB/s} \quad (1)$$

$$\text{Capacidad UL por nodo de 1 sector} = 300 \times 53,9 \% \times 6 \% \times 1 \times 1 = 9,7 \text{ MB/s} \quad (2)$$

Los valores obtenidos están dentro del rango esperado (Metsälä & Salmelin, 2015); se requieren 29,1 MB/s por cada centro poblado. En el enlace crítico del *backhaul* (Pagkintsa-Nieva), la capacidad agregada es 145,5 MB/s, menor al ancho de banda del enlace (210 MB/s), por lo que la red del río Santiago permite soportar el servicio 4G.

Respecto a las condiciones de latencia y pérdida de paquetes, de acuerdo con Metsälä y Salmelin (2015) y las especificaciones 3GPP TS23.203 para aplicaciones que no son de tiempo real, se requiere como máximo un *round-trip time* de extremo a extremo de 200 ms para el plano de control y de 600 ms para el plano de usuario, así como de 0,0001 % para la pérdida de paquete. Por lo tanto, en el *backhaul* de la red se deberá asegurar esta latencia y pérdida de paquetes; como se ha evidenciado, esto se cumple.

7. CONCLUSIONES

El proyecto ha demostrado que la colaboración entre actores públicos y privados puede reducir los plazos de ejecución y optimizar la inversión económica. Un ejemplo de lo anterior se puede encontrar en la obtención de la compatibilidad y la certificación ambiental (menos de ocho meses, cuando el periodo habitual es de más de un año), y en el propio proyecto de inversión pública. Por otro lado, este modelo de asociación, considerado como una innovación pública, tiene al Gobierno como actor principal y utiliza la coordinación y articulación como herramientas claves de gestión. La financiación y articulación de múltiples actores, la alineación con políticas gubernamentales, el uso de bandas no licenciadas, la participación de universidades, la implementación de teleservicios y el apoyo de la cooperación al desarrollo son elementos innovadores para aumentar el acceso a servicios de banda ancha en comunidades rurales aisladas y poco pobladas.

Técnicamente, el proyecto desarrollado para implementar una red de bajo costo ha sido viable, pues se ha logrado instalar una red funcional que brinda un servicio social a localidades rurales que carecían de acceso al servicio de internet. Además, en este proyecto se propuso utilizar redes inalámbricas en bandas libres para interconectar las localidades del río Santiago, las cuales, según el equipamiento, si bien tienen un límite de capacidad, permiten brindar servicios básicos de telecomunicaciones. Precisamente, el uso de bandas libres facilita la implementación de una red de estas características por parte de entidades, como la PUCP, que no son operadores y, si bien no son consideradas en general como una solución óptima, su uso en zonas sin servicio de telecomunicaciones presenta una mínima probabilidad de ser afectadas por posibles interferencias.

REFERENCIAS

Cambium Networks (2018). *User Guide PTP 670 Series System Release 670-02-67*. https://www.cambiumnetworks.com/wp-content/uploads/2018/11/PTP-670-Series-User-Guide_phn-4431_007v000.pdf

- Internet Engineering Task Force. (2022). *Operational Considerations for Streaming Media*. RFC 9317. <https://datatracker.ietf.org/doc/html/rfc9317#name-latency-considerations>
- Martínez-Fernández, A., Vidal, J., Simo-Reigadas, J., Prieto-Egido, I., Agustín, A., Paco, J. A., & Rendón, A. (2016). The TUCAN3G project: wireless technologies for isolated rural communities in developing countries based on 3G small cell deployments. *IEEE Communications Magazine*, 54, 36-43. <https://doi.org/10.1109/MCOM.2016.7509376>
- Metsälä, E., & Salmelin, J. (2015). *LTE backhaul: Planning and optimization*. Wiley Telecom. <https://doi.org/10.1002/9781118924655.ch2>
- Mikrotik. (2024a). *The 4011 series. Fuel your network*. https://i.mt.lv/cdn/product_files/RB4011-IN_240134.pdf
- Mikrotik. (2024b). *DISC Lite5 ac*. https://i.mt.lv/cdn/product_files/DISCplusLite5plusac_180227.pdf
- Mikrotik. (2024c). *mANTBox series*. https://i.mt.lv/cdn/product_files/mANTBox_series_170929.pdf
- Mikrotik. (2024d). *DynaDish 5*. https://i.mt.lv/cdn/product_files/DynaDish_5_170914.pdf
- Mikrotik. (2024e). *Base box*. https://i.mt.lv/cdn/product_files/basebox_out_220151.pdf
- Ministerio de Transporte y Comunicaciones. (2013a, 4 de abril). Modifican el TUO del Reglamento General de la Ley de Telecomunicaciones, el Marco Normativo General para la promoción del desarrollo de los servicios públicos de telecomunicaciones de áreas rurales y lugares de preferente interés social, y establecen disposiciones complementarias. Decreto Supremo N° 006-2013-MTC. *El Peruano*, 492144-492146. http://transparencia.mtc.gob.pe/idm_docs/normas_legales/1_0_4485.pdf
- Ministerio de Transporte y Comunicaciones. (2013b, 18 de abril). Modifican la R.M. N° 777-2005-MTC/03 y la Nota P57A del Plan Nacional de Atribución de Frecuencias - PNAF aprobado mediante R.M. N° 187-2005-MTC/03. Resolución Ministerial N° 199-2013-MTC/03. *El Peruano*, 493082-493086. https://cdn.www.gob.pe/uploads/document/file/358686/1_0_4486.pdf
- Ministerio de Transporte y Comunicaciones. (2023). *Innovar para conectar: Estrategias y medidas de regulación inteligente para reducir la brecha digital*. <https://cdn.www.gob.pe/uploads/document/file/4341442/Innovar%20para%20conectar.pdf>
- Organización de las Naciones Unidas. (2015). *Objetivos de Desarrollo Sostenible*. <https://www.un.org/sustainabledevelopment/es/2015/09/la-asamblea-general-adopta-la-agenda-2030-para-el-desarrollo-sostenible/>

- Organismo Supervisor de Inversión Privada en Telecomunicaciones. (2018). *Metodología para medir los indicadores de nivel de servicio (SLA) de la Red Dorsal Nacional de Fibra Óptica*. <https://cdn.www.gob.pe/uploads/document/file/1531963/%20Informe%20N%C2%B0%20247-GSF/2018.pdf?v=1609885242>
- Observatorio Nacional de Prospectiva (2024). *Cierre de la brecha digital*. CEPLAN. https://observatorio.ceplan.gob.pe/ficha/o10_ama
- Organismo Supervisor de Inversión Privada en Telecomunicaciones. (2023). *Resolución de Consejo Directivo N° 00014-2023-CD/OSIPTEL, Norma que aprueba los procedimientos de supervisión de indicadores de calidad de los servicios públicos de telecomunicaciones*. <https://cdn.www.gob.pe/uploads/document/file/4084593/Resoluci%C3%B3n%20N%C2%B0%20014-2023-CD/OSIPTEL.pdf?v=1675286903>
- Presidencia del Consejo de Ministros. (2022). *Proceso de Alianza Multiactor rumbo al Bicentenario*. Plataforma Nacional de Datos Georreferenciados Geo Perú. <https://www.geoperu.gob.pe/alianza-multiactor/>
- Presidencia del Consejo de Ministros. (2024). *Sobre la Plataforma Digital Georreferenciada*. Plataforma Nacional de Datos Georreferenciados Geo Perú. <https://www.geoperu.gob.pe/marco-de-gobernanza-de-datos/>
- Programa Nacional de Telecomunicaciones. (2021). *Conectividad rural. Una mirada prospectiva del Programa Nacional de Telecomunicaciones*. https://cdn.www.gob.pe/uploads/document/file/2372567/Reporte%20Anual%20PRONATEL%20FINAL-DIGITAL3_compressed.pdf.pdf
- Programa Nacional de Telecomunicaciones. (2022). *Contribución de PRONATEL al cierre de la Brecha Digital en el Perú*. <https://cdn.www.gob.pe/uploads/document/file/4228612/Contribucio%CC%81n%20de%20Pronatel%20al%20cierre%20de%20brechasC.pdf.pdf>
- Quispe Tacas, R., Paco Fernandez, J. A., & Auccapuri Quispetupa, D. (2021). Design of a wireless network for the interconnection of the villages of the Santiago River. *2021 IEEE XXVIII International Conference on Electronics, Electrical Engineering and Computing (INTERCON)*, 1-4. <https://doi.org/10.1109/INTERCON52678.2021.9532828>
- Ramírez García, A., & Blanco Romero, G. (2021). Rediseño institucional para el cierre de brecha residual de telecomunicaciones en Perú: Una tercera vía de intervención para la emergencia de redes comunitarias sostenibles. *Revista Latinoamericana de Economía y Sociedad Digital*, 2, 1-32. <https://doi.org/10.53857/DGVB4810>
- Simo-Reigadas, J., Municio, E., Morgado, E., Castro, E. M., & Martinez, A. (2015). Sharing low-cost wireless infrastructures with telecommunications operators for

backhauling 3G services in deprived rural areas. *2015 IEEE 16th International Symposium on A World of Wireless, Mobile and Multimedia Networks (WoWMoM)*, 1-8. <https://doi.org/10.1109/WoWMoM.2015.7158164>

Starlink. (2024a). *Planes de servicio*. <https://www.starlink.com/service-plans>

Starlink. (2024b). *Especificaciones*. <https://www.starlink.com/legal/documents/DOC-1470-99699-90?regionCode=PE>

Ting, A., Chieng, D., Kae Hsiang, K., & Andonovic, I. (2012). Optimization of heterogeneous multi-radio multi-hop rural wireless network. *2012 IEEE 14th International Conference on Communication Technology*, 1159-1165. <https://doi.org/10.1109/ICCT.2012.6511372>

DEEP GENERATIVE AI BASED ON DENOISING DIFFUSION PROBABILISTIC MODELS FOR APPLICATIONS IN IMAGE PROCESSING

EMILI SILVA BEZERRA

emili.bezerra@sou.ufac.br

<https://orcid.org/0000-0003-4519-8332>

PAVIC Laboratory, University of Acre (UFAC), Brazil

QUEFREN OLIVEIRA LEHER

quefren.leher@sou.ufac.br

<https://orcid.org/0009-0005-6678-1131>

PAVIC Laboratory, University of Acre (UFAC), Brazil

UENDEL DIEGO DA SILVA ALVES

uendel.alves@sou.ufac.br

<https://orcid.org/0009-0009-3357-4979>

PAVIC Laboratory, University of Acre (UFAC), Brazil

THUANNE PAIXÃO

thuanne.paixao@sou.ufac.br

<https://orcid.org/0000-0002-5563-8971>

PAVIC Laboratory, University of Acre (UFAC), Brazil

ANA BEATRIZ ALVAREZ

ana.alvarez@ufac.br

<https://orcid.org/0000-0003-3403-8261>

PAVIC Laboratory, University of Acre (UFAC), Brazil

Received: September 9th, 2024 Accepted: October 8th, 2024

doi: <https://doi.org/10.26439/interfases2024.n020.7389>

ABSTRACT. Denoising diffusion probabilistic models (DDPMs) have demonstrated significant potential in addressing complex image processing challenges. This paper explores the application of DDPMs in three different areas: reconstruction of remote sensing imagery affected by cloud cover, reconstruction of facial images with occluded areas, and segmentation of bodies of water from remote sensing imagery. Inpainting involves filling in missing regions in images, while DDPMs act as data generators capable of synthesizing information that aligns coherently with the context of the original data. Inspired by the inpainting technique, the RePaint approach was adapted and applied to

reconstruction tasks. The WaterSegDiff approach, which uses a diffusion model as a backbone, was employed for the segmentation task. To illustrate the model's behavior and provide examples of the tasks, experiments were carried out with both qualitative and quantitative evaluations. The qualitative results show the model's ability to generate data for reconstruction and segmentation. Quantitatively, metrics such as MSE, PSNR, SSIM, IoU, PA and F1 score highlight the model's proficient performance in image processing tasks. In this scenario, DDPMs have proved to be a promising tool for high-quality data reconstruction, enabling the hallucination of image regions with high visual coherence and facilitating applications in various areas, such as environmental monitoring, facial recognition, water resource mapping, among others.

KEYWORDS: machine learning / reconstruction / segmentation / face and gesture recognition / remote sensing.

IA GENERATIVA PROFUNDA BASADA EN MODELOS DE DIFUSIÓN DE DESENFUQUE PROBABILÍSTICO PARA APLICACIONES EN PROCESAMIENTO DE IMÁGENES

RESUMEN. Los *denoising diffusion probabilistic models* (DDPMs) han mostrado un potencial significativo en la resolución de problemas complejos de procesamiento de imágenes. Este estudio explora el uso de DDPMs en tres aplicaciones diferentes, incluyendo la reconstrucción de imágenes de teledetección en zonas con nubosidad, la reconstrucción de imágenes faciales con regiones ocluidas y la segmentación de masas de agua a partir de imágenes de teledetección. El *inpainting* consiste en rellenar las regiones omitidas en las imágenes, mientras que los DDPM actúan como generadores de datos capaces de sintetizar información coherente con el contexto de los datos originales. En este contexto, tomando la técnica de *inpainting* como inspiración, se adaptó el enfoque *RePaint* y se aplicó a tareas de reconstrucción. Para la tarea de segmentación se utilizó la técnica WaterSegDiff, que también utiliza un modelo de difusión como *backboner*. Para ilustrar el comportamiento del modelo y ejemplificar las tareas, se realizaron experimentos cuya performance se evaluó cualitativa y cuantitativamente. Los resultados de las evaluaciones cualitativas muestran la capacidad del modelo para generar datos para la reconstrucción y la segmentación. Cuantitativamente, las métricas MSE, PSNR, SSIM, IoU, PA y F1-Score indican un hábil desempeño de los modelos en tareas de procesamiento de imágenes. En este escenario, los DDPMs han demostrado ser una herramienta prometedora para la reconstrucción de datos de alta calidad, permitiendo la alucinación de regiones de imágenes con alta coherencia visual y aplicaciones en diversas áreas, tales como monitoreo ambiental, reconocimiento facial, mapeo de recursos hídricos, entre otros.

PALABRAS CLAVE: aprendizaje automático / reconstrucción / segmentación / reconocimiento facial y gestual / teledetección.

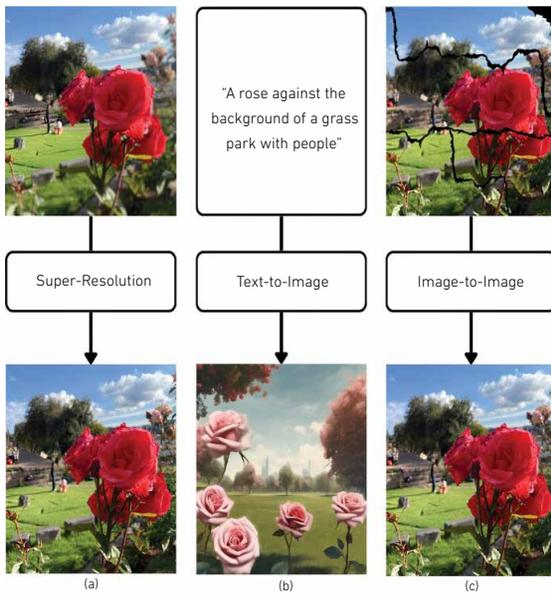
1. INTRODUCTION

In recent years, advancements in deep learning techniques, especially convolutional neural networks (CNNs), have boosted the emergence of artificial intelligence generated content (AIGC). This term refers to data generated by deep learning algorithms, which are capable of creating high-quality content in a variety of formats, such as texts, images and videos. The ability of AIGCs to create content that is nearly indistinguishable from human-made material has revolutionized various sectors, including entertainment, education and scientific research, opening up new possibilities for the content creation and information consumption (Wu et al., 2023; Cao et al., 2023).

According to Zhang et al. (2023), the core of content generation algorithms, also known as generative models, lies in their ability to learn the patterns within a dataset and, based on this knowledge, generate new similar content. Image synthesis is a key area where these models are used to create visually coherent images. Tasks such as super-resolution imaging (enhancing image resolution), image generation from textual descriptions (Text-to-Image) and image reconstruction (Image-to-Image) are examples of diffusion models applications, as illustrated in Figure 1.

Figure 1

Diffusion Model Applications: (a) Image Synthesis for Super-Resolution, (b) Text-to-Image, and (c) Image to Image



Within the field of generative models, diffusion models have proven capable of reversing degradation processes, by learning to recover lost information and generate realistic data (Rombach et al., 2022). These models, also known as denoising diffusion

probabilistic models (DDPMs), often simply referred to as diffusion models for brevity (Ho et al., 2020). DDPMs have demonstrated great potential across various image restoration tasks, including applications in computer vision, robust machine learning, natural language processing, temporal data modeling, multimodal modeling, medical image reconstruction. They have also found interdisciplinary applications in areas such as computational chemistry, image inpainting, image noise removal (denoising), remote sensing, face restoration with occluded areas—particularly in security applications—and image segmentation (Yang et al., 2023).

In remote sensing applications, Singh and Vyas (2022) emphasize the high homogeneity and geospatial accuracy of the data obtained by remote sensing, while underscoring the potential for occlusions in adverse conditions. These occlusions, often associated with cloud cover, can impair the quality of vegetation indices, which are mathematical models used to quantify characteristics of the Earth's surface. One notable example is land surface temperature (LST), an indicator sensitive to changes in resource and environmental conditions, especially in areas with high spatio-temporal variability. According to Awais et al. (2022), LST is influenced by multiple factors, such as human activities as well as vegetation and soil water conditions. García and Díaz (2021) further corroborate the importance of LST across various areas of knowledge, including hydrology, meteorology, surface energy balance and climate studies. Growing concern about the effects of climate change has led to the identification of certain ecosystems as key indicators of environmental impact. Lakes, for instance, are often sensitive and rapid sentinels of climate and hydrological changes in river basins, providing valuable tools for understanding environmental dynamics (Adrian et al. 2009). For example, Perez-Torres et al. (2024) developed automated and efficient methods to accurately capture lakes in high mountain environments, aiming to climate change challenges in these ecosystems, prevent and mitigate disasters and properly manage and protect water resources.

Simultaneously, the prevalence of images in modern society makes image restoration a critical research area in computer vision. The presence of artifacts, noise, or missing regions in images can compromise the quality of visual information and human interpretation. Inpainting, an image processing technique, aims to fill in these gaps coherently with the visual context, significantly improving the perceptual quality of images (Elharrouss et al., 2020; Li et al., 2023). Facial recognition, an intuitive task for humans, poses complex challenges for computational systems. Changes in capture conditions, such as lighting and angle, as well as individual variations, significantly impact the accuracy of algorithms (Kortli et al., 2020). The primary objective of facial recognition systems is to identify individuals from static images or video sequences (Ali et al. 2021; Taskiran et al., 2020). To deal with degraded images or occluded images, inpainting—especially when based on diffusion models—is emerging as a promising technique. This approach shows potential for improving the robustness of facial recognition systems, especially in challenging conditions.

Based on the works by Leher (2024), Alves (2024) and Perez-Torres et al. (2024), this paper presents the versatility of DDPMs. Expanding on the research by Lugmayr et al. (2022), it refines using DDPMs to recover lost information more precisely across various image modalities. Furthermore, integrating a segmentation model with DDPMs facilitates the extraction of bodies of water, this approach in multiple applications, opening up new possibilities for visual data analysis and interpretation.

2. RELATED STUDIES

Sohl-Dickstein et al. (2015) pioneered the application of diffusion models, introducing a new method for modelling complex data. They proposed a technique involving the gradual destruction of the data structure, followed by learning an inverse process for its reconstruction. This method resulted in a deep and versatile generative model that enabled rapid learning, efficient sampling and precise calculation of probabilities. Inspired by statistical physics, the approach offers a solution to the challenge of balancing flexibility and tractability in data modelling.

Various studies have since focused on diffusion model-based for image reconstruction. Avrahami and Fried (2022), in the work *Blended Diffusion for Text-driven Editing of Natural Images*, presented an inpainting solution to perform local (region-based) editing on generic natural images based on a natural language description together with a region of interest (ROI) mask. They combined a contrastive language-image pretrained (CLIP) model to direct editing to a user-supplied text prompt with a DDPM to generate natural-looking results.

Similarly, Lugmayr et al. (2022), in *RePaint: Inpainting using Denoising Diffusion Probabilistic Models*, proposed an inpainting approach based on a DDPM-type diffusion model, achieving high-quality results even with atypical masks. They used an unconditional DDPM pre-trained with generative priors, altering the reverse diffusion iterations by sampling the unmasked regions using the provided image information. As this technique does not modify or condition the original DDPM network itself, the model produces diverse, high-quality output images for any form of inpainting/filling.

Kawar et al. (2022) introduced denoising diffusion restoration models (DDRM), a diffusion model based on an unsupervised posterior sampling method, achieving efficient results in the fields of image restoration, super-resolution, deblurring, colorization and inpainting. DDRM proved to be an excellent solver of linear inverse problems through general sampling with an unconditional diffusion model.

Approaches based on diffusion models have proven effective in generating new data, which has motivated recent research into their application in remote sensing imagery. Liu et al. (2022) and Bandara et al. (2022) explored these models in different contexts. Liu et al. (2022) proposed the diffusion model with detail complement (DMDC),

a generative model specifically for super-resolution images. Rather than just optimizing existing images, DMDC generates high-resolution images from low-resolution inputs, allowing for a deeper understanding of the image and the recovery of fine and complex details that could be lost at lower resolutions. On the other hand, Bandara et al. (2022) applied DDPMs for feature extraction, to improve the accuracy of change detection in remote sensing images. The model, trained on a large set of unlabeled images, learned to generate images from noise. After training, DDPMs are able to extract relevant features such as texture, shape, and patterns, which were used to train a simple classifier that identifies changes in specific image areas.

In their study on cloud removal from satellite images, Jing et al. (2023) introduced the DDPM-CR model, which is notable for its ability to remove both thin and thick clouds from radar data. This model, based on the DDPM architecture, uses the SEN12MS-CR database to improve its results. DDPM-CR integrates cloud-contaminated optical images with synthetic aperture radar (SAR) images, where the information provided by the SAR images helps to accurately reconstruct the areas obscured by the clouds. The model incorporates a multi-scale attention mechanism for effective cloud identification and removal. In addition, the loss function developed for training the model is specifically designed for cloud removal, considering both high- and low-frequency information.

In parallel, Zhao and Ji (2023) proposed the sequential-based diffusion models (SeqDMs), which combine data from different sources, such as radar images (unaffected by clouds) and optical images (interfered by clouds). SeqDMs analyze temporal sequences of images to generate more precise information about cloud-covered areas. The model is adaptable to sequences of different lengths, which enhances its applicability across different situations.

Inspired by recent advancements in natural language processing, computer vision, and image synthesis from Gaussian noise, diffusion probabilistic models and transformer models have demonstrated a remarkable ability to capture complex spatial and contextual relationships, generating high-quality images. This makes them particularly suitable for image segmentation tasks. While traditionally used for image generation and inpainting, diffusion models have recently been applied to semantic segmentation. Amit et al. (2021) introduced an innovative technique that integrates the power of diffusion models, known for their ability to generate high-quality images, with image segmentation task. Unlike approaches that rely on pre-trained models in other tasks (backbones), their model is trained in an integrated way, combining the information from the original image with the current segmentation estimate by means of two encoders. Through additional coding layers and a decoder, the model iteratively refines the segmentation, using the probabilistic mechanism characteristic of diffusion models.

Semantic segmentation models, which divide images into different semantic regions, have difficulty identifying the exact boundaries between these regions. This

challenge arises because convolutional operators, common tools in these models, tend to smooth out fine details, making it difficult to clearly distinguish the boundaries. Tan et al. (2022) proposed a new technique called semantic diffusion network (SDN) to improve the ability of segmentation models to detect boundaries. SDN works as an anisotropic diffusion process that emphasizes edge and texture information relevant to semantic boundaries. SDN creates a mathematical mapping that transforms the original features into boundary-sensitive features.

Ayala et al. (2023) proposed a solution for semantic segmentation in remote sensing imagery conditioning the diffusion process to reduce noise in input images. This method aims to guide the generation of the segmentation mask, ensuring consistency with the elements present in the original image. By conditioning the diffusion process, the authors significantly improved the mask's accuracy, so that it adequately reflects the elements of the captured scene. The model was evaluated on a specific aerial images dataset and compared to state-of-the-art techniques. The results demonstrate the promising potential of this approach as a valuable tool in the field of remote sensing.

3. METHODOLOGY

3.1 DDPM

As outlined by Dhariwal and Nichol (2021), the diffusion process consists of two primary stages: forward diffusion and reverse diffusion.

3.2.1 Forward diffusion

In this stage, a Markov chain is used to progressively add small amounts of noise ϵ to a data sample x_0 , producing a sequence of increasingly noisy samples x_0, x_1, \dots, x_T . The amount of noise at each step is controlled by the variance $\{\beta_T \in (0, 1)\}_{t=1}^T$, as seen in Equation 1.

$$q(x_t|x_{t-1}) = \mathfrak{N}(x_t | \sqrt{1 - \beta_t}x_{t-1}, \beta_t I) \quad (1)$$

As t increases, the original data sample x_0 loses its distinctive characteristics and eventually becomes an isotropic Gaussian distribution x_T .

3.2.1 Reverse diffusion

In the reverse diffusion stage, the process uses a neural network with parameters denoted as θ to iteratively remove noise from the noisy sample x_T at each time step until a high-quality sample x_0 is obtained. A neural network predicts the mean $\mu_\theta(x_t, t)$ and variance $\Sigma_\theta(x_t, t)$ of the Gaussian distribution, calculated with Equation 2:

$$p_{\theta}(x_{t-1}|x_t) = \mathfrak{N}(x_{t-1}; \mu_{\theta}(x_t, t), \Sigma_{\theta}(x_t, t)) \quad (2)$$

The learning objective of the model is derived by considering the variational lower bound (VLB) between the prior and posterior distributions, as seen in Equation 3:

$$L_{VLB} = E_q \left[D_{KL}(q(x_t|x_0)||p_{\theta}(x_T)) + \sum_{t>1} \left(D_{KL}(q(x_{t-1}|x_t, x_0)||p_{\theta}(x_{t-1}|x_t)) - \log p_{\theta}(x_0|x_t) \right) \right]$$

$$L_{VLB} = E_q [L_T + \sum_{t>1}(L_{t-1}) - L_0] \quad (3)$$

After a series of derivations of the terms L_{t-1} , one simplified training objective L_{simple} is obtained, according to Equation 4:

$$L_{simple} = E_{t \sim [1, T], x_0, \varepsilon} [\|\varepsilon_t - \varepsilon_{\theta}(x_t, t)\|^2] \quad (4)$$

Since does not depend on the variance $\Sigma_{\theta}(x_t, t)$, a new hybrid object is defined according to Equation 5:

$$L_{hybrid} = L_{simple} + \lambda L_{VLB} \quad (5)$$

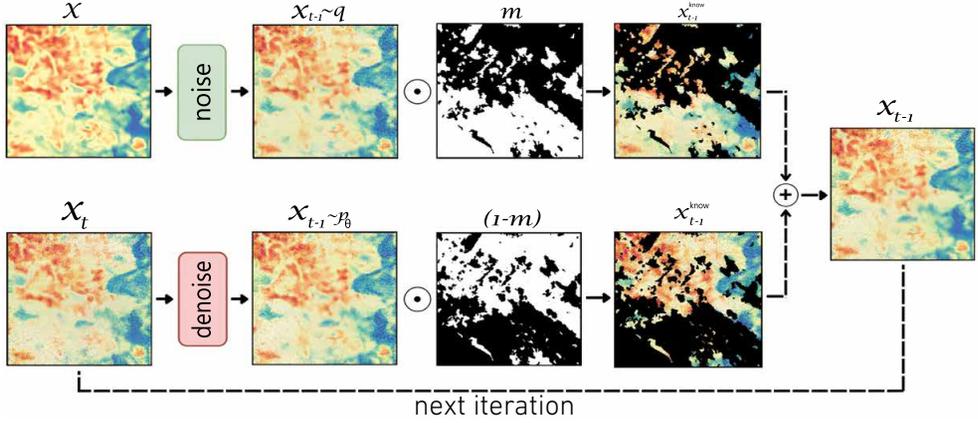
3.2 Image Reconstruction

After the consolidation of diffusion models (DMs), the inpainting task has been significantly optimized. Studies by Sohl-Dickstein et al. (2015) and Ho et al. (2020) demonstrated the potential of diffusion models. Since then, several authors, including Lugmayr et al. (2022), have introduced new frontiers in computational inpainting using diffusion models, achieving outstanding results.

Lugmayr et al. (2022) propose a robust free-form inpainting method called RePaint, which fills arbitrary regions of an image defined by a mask. The method uses a pre-trained DDPM-type (Ho et al., 2020), conditioning the generation process only in the reverse diffusion iterations by sampling the unmasked regions. Figure 2 illustrates RePaint's iterative process. The methodology proposes a reformulation of the traditional denoising process, aimed at conditioning the content of the input image. In each iteration, samples from the known region of the original image (upper sequence in Figure 2) and the already filled portion of the output generated by the DDPM (lower sequence in Figure 2) are used as input for the model. Preserving the DDPM's original architecture guarantees the diversity and high quality of the generated images, regardless of the shape of the inpainting mask. This feature gives the technique greater flexibility, allowing arbitrary masks to be applied and inpainting to be carried out more freely.

Figure 2

RePaint Process that Exemplifying the Reconstruction of an LST Image



Note. From "RePaint: Inpainting using denoising diffusion probabilistic models" by A. Lugmayr, M. Danelljan, A. Romero, F. Yu, R. Timofte, & L. Van Gool, 2022, 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), pp. 11461-11471 (https://openaccess.thecvf.com/content/CVPR2022/papers/Lugmayr_RePaint_Inpainting_Using_Denoising_Diffusion_Probabilistic_Models_CVPR_2022_paper.pdf).

Considering Figure 2, the original image (ground truth) is designated by x , the unknown pixels by $m \odot x$ and the known pixels by $(1 - m) \odot x$, where m represents the original mask region and $(1 - m)$ represents the inverse mask region. Therefore, the known regions x_{t-1}^{know} (unmasked pixels) are represented by the values 1 in the binary mask matrix, indicating an unmasked pixel, while the value 0 indicates a pixel covered by the mask. Thus, x_{t-1}^{know} is sampled from the input data by Equation 6:

$$x_{t-1}^{know} \sim \mathcal{N}(\sqrt{\alpha_t} x (1 - \alpha_t) I) \quad (6)$$

In this way, the unknown regions x_{t-1}^{unknow} (covered by the mask) by sampling from the neural model, shown in Equation 7:

$$x_{t-1}^{unknow} \sim \mathcal{N}(\mu_\theta(x_t, t), \Sigma_\theta(x_t, t)) \quad (7)$$

Finally, these samples are combined to obtain the next reverse intermediate step x_{t-1} , as shown in Equation 8:

$$m \odot x_{t-1}^{know} + (1 - m) \odot x_{t-1}^{unknow} \quad (8)$$

In this way, reconstruction of the occluded areas after applying the mask is carried out using the inpainting technique, generating a reconstructed image in the output. By

definition, the area to be reconstructed is delimited by a binary mask m , which is filled in based on information from the surrounding pixels according to the pre-trained DDPM.

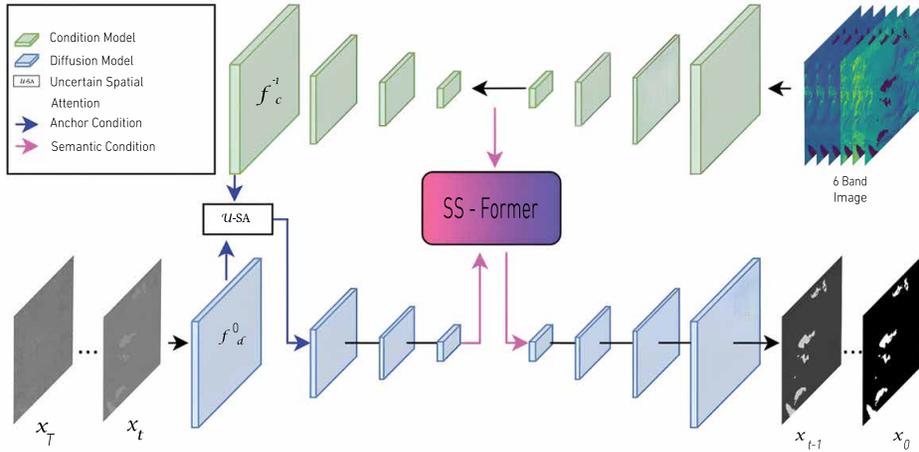
3.3 Image Segmentation

Diffusion probabilistic models with noise reduction have shown remarkable results in generative image modeling. Studies by Amit et al. (2021), Tan et al. (2022), and Ayala et al. (2023) highlight the potential of these models in semantic segmentation tasks, particularly in remote sensing. However, the main challenge in applying them arises from their generative nature, which creates a segmentation mask from random noise. To ensure that this mask corresponds to the target image, a restricted diffusion process is needed to guide the generation of the mask in a more accurate and coherent way.

MedSegDiff-V2 (Wu et al., 2023) is a transformer-based diffusion framework that uses two different conditioning techniques—anchor condition and semantic—condition which effectively integrate the conditioning resources into the diffusion model. This framework employs two U-Net architectures: one for the diffusion block and one another for the conditioning block. The condition U-Net block acts as a segmentation feature extractor from the original raw image, learning the most relevant features. These segmentation features are integrated with the noise mask information using the anchor condition technique, which implements the uncertain spatial attention (U-SA) mechanism. The integrated data is fed into the U-Net diffusion model's encoder. On the other hand, the semantic condition integrates the high-level features obtained by the diffusion and conditioning models through a transformation mechanism called spectrum-space transformer (SS-Former). This cross-attention mechanism operates in the frequency domain, aligning the noisy image data with the segmentation features of the raw image. Both conditioning mechanisms address the incompatibility issue of combining a U-Net model with diffusion probabilistic models, by implementing an interface between the two models, which helps to reduce the large variations in the transformer configuration. Based on MedSegDiff, a new architecture called WaterSegDiff has been developed specifically for the task of segmenting bodies of water from remote sensing imagery. Figure 3 illustrates the WaterSegDiff architecture.

Figure 3

WaterSegDiff Architecture Showing the Two Conditioning Mechanisms: U-SA and SS-Former



Note. From “Exploratory analysis using deep learning for water-body segmentation of Peru’s high-mountain remote sensing images,” W. I. Perez-Torres, D. A. Uman-Flores, A. B. Quispe-Quispe, F. Palomino-Quispe, E. Bezerra, Q. Leher, T. Paixão, and A. B. Alvarez, 2024, *Sensors*, 24(16), Article 5177 (<https://doi.org/10.3390/s24165177>).

At each stage t of the diffusion process, a noisy mask x_t is introduced into the diffusion model. This model is conditioned by segmentation features extracted from the raw image using the conditioning model. The diffusion process is instructed using the Anchor Condition and Semantic Condition techniques, where the former allows the diffusion model to be initialised with an approximate but static reference, which helps to reduce variations in diffusion. While the second technique, using the SS-Former, connects the noise and high-level segmentation information to be fed into the diffusion model decoder, generating a more robust representation by taking advantage of the global and dynamic nature of the Transformer proposed by Muzammal et al. (2021). This conditioning introduced into the diffusion model decoder can be expressed as in Equation 9.

$$\epsilon_{\theta}(x_t, I, t) = D(TransF(E_t^I, E_t^x), t) \quad (9)$$

Where E_t^I represents the high-level features of the raw image and E_t^x represents the high-level features of the image with current noise. Using a transformer, both features are incorporated and passed through the D decoder of the diffusion model.

4. EXPERIMENTS

The experiments were carried out at the Federal University of Acre (UFAC) Pesquisa Aplicada em Visão e Inteligência Computacional (PAVIC) laboratory in Brazil, encompassing three independent experiments. All experiments were conducted using PyTorch 2.0.1 on Ubuntu 22.04.3 LTS. Section 4.1 presents a methodology for reconstructing remote sensing imagery in order to estimate Earth's surface temperature. Section 4.2 describes image reconstruction techniques for facial recognition applications, security systems and facial biometrics. Finally, Section 4.3 includes a study on the segmentation of bodies of water in satellite images for remote sensing.

4.1 First Experiment: LST Image Reconstruction

The reconstruction of satellite images is a complex problem that requires high computational power and faces challenges such as noise and cloud cover. To mitigate these effects, image preprocessing techniques inspired by Bezerra et al. (2023) were used as a first step in applying the RePaint model.

The experiment conducted by Leher (2024) explores the applicability of an inpainting approach based on DDPMs (Ho et al., 2020) to reconstruct satellite information (Landsat-8) for the calculation of LST in areas affected by cloud cover. This experiment follows the methodology of the surface energy balance algorithm for land (SEBAL) model (Bastiaanssen et al., 1998) to estimate LST. In this process, emissivity is derived from vegetation indices calculated using the reflectance values extracted from the bands B4 and B5. At the same time, spectral radiance is obtained from the band B10. Finally, the information gathered from the emissivity and spectral radiance is used to reconstruct the LST in each image fragment. Thus, the LST is estimated using the following procedures:

- **Spectral radiance:** Converts digital numbers (DN) from the thermal band (B10) into spectral radiance using band-specific calibration factors.
- **Top-of-atmosphere reflectance:** Calculates reflectance for bands B4 and B5 using solar elevation, sun-earth distance and band-specific calibration factors.
- **Vegetation indices:** Derive the normalized difference vegetation index (NDVI) and the soil adjusted vegetation index (SAVI) from reflectance values. The leaf area index (LAI) is calculated from the SAVI and represents the ratio of the leaf area of a vegetation and the area of the unit covered by that vegetation. These indices represent the health and biomass of the vegetation.
- **Emissivity:** Estimates pixel emissivity using a linear relationship with the SAVI, characterizing the heat radiation properties of a surface.

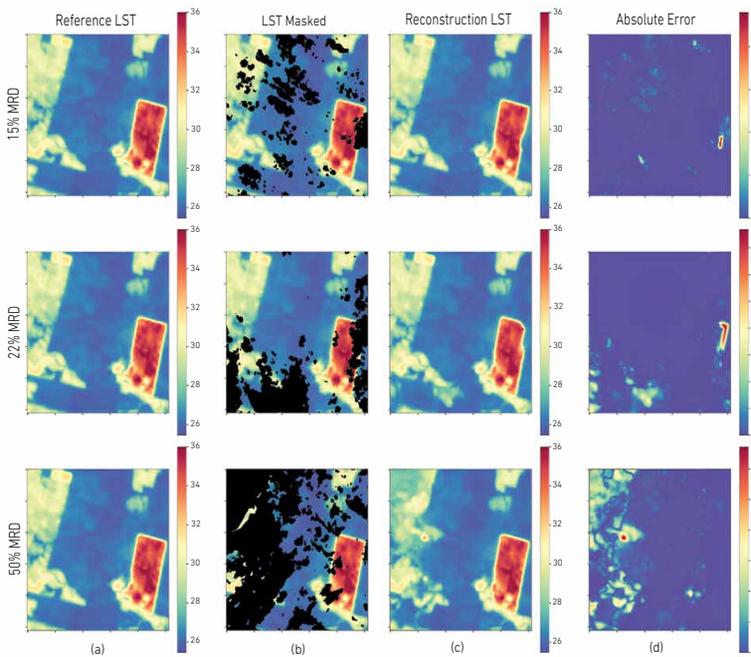
The study region selected for this research is the western Brazilian Amazon rainforest, known for its high annual cloud cover. Figure 4 shows the visual results of the

model reconstructing at three levels of cloud cover: 15%, 22% and 50% missing rate data (MRD).

The complexity of generative models such as RePaint results in significant computational cost. In this study, training on a set of satellite images required 48 hours of processing on dedicated hardware. Training and testing were performed using a 3.0 GHz Intel Xeon Gold 6342 CPU and an NVIDIA HGX A100 GPU. The inference phase - the process of generating new images from the trained model - took an average of 15 minutes per image.

Figure 4

Visual Results of the LST Retrieval: (a) Ground Truth LST, (b) Masked LST, (c) Reconstructed LST, (d) Absolute Error



As shown in Figure 4, the model exhibited strong ability in reconstructing LST images with high fidelity, even under significant cloud cover. The reconstruction with 15% cloud cover achieved the highest quality, with minimal absolute errors compared to the reference LST image. This high quality is evident by both the visual analysis and error quantification, which did not exceed 4°C. Reconstructions for images with 22% and 50% cloud cover also yielded satisfactory results, with maximum errors of 7°C and 6°C respectively. The visual comparison of the reconstructed images against the reference images, as well as absolute error quantification, enabled a robust assessment of the model's performance across cloud cover scenarios.

In addition to the visual analysis of the reconstruction, a quantitative evaluation was carried out using metrics such as mean square error (MSE), for fidelity to the original image, peak signal-to-noise ratio (PSNR) and structural similarity index measure (SSIM). The numerical results of these metrics are shown in Table 1.

Table 1

MSE, PSNR, and SSIM Quantitative Statistics Values from LST Image Reconstruction

Scenarios	MSE ↓	PSNR ↑	SSIM ↑
15 %	0,0019	47,1894	0,9874
22 %	0,0001	39,9359	0,9763
50 %	0,0002	35,9113	0,9478

Note. ↓ indicates that a lower value is better, while ↑ indicates that a higher value is better.

As expected, the results in Table 1 reveal that cloud cover directly affects the quality of the model's reconstruction. The scenario with 15% cloud cover showed the best results, with the highest PSNR (47,1894) and SSIM (0,9874) metrics, indicating a reconstruction that was more faithful to the original image. The 22% cloud cover scenario, despite achieving the lowest MSE (0,0001), obtained slightly lower results in the other metrics. The 50% coverage scenario yielded the lowest PSNR and SSIM values among the three scenarios. However, even at this level of cloud cover, the metric values indicate good reconstruction quality, suggesting the robustness of the model across different cloud cover conditions.

4.2 Second Experiment: Reconstruction of Facial Images

The RePaint model was applied to a set of facial images from the CelebA-HQ dataset, following the pre-processing technique proposed by Alves (2024). This stage, which involves extracting the facial region of interest (ROI), aims at guiding the model's learning toward facial patterns, thereby improving its reconstruction ability. This research uses RePaint with transfer learning, and this pre-processing stage has proven crucial for increasing the robustness of facial recognition systems in scenarios with partial occlusion.

This experiment introduces a dynamic approach using the inpainting technique based on diffusion models to reconstruct occluded areas of facial images. From a single sample, the model realistically synthesizes several missing parts, enabling the extraction of facial features critical for identification. Figure 5 displays the reconstruction results for two randomly chosen samples.

The computational cost of generative models such as RePaint pose a significant challenge, particularly in large-scale projects. In this experiment, training on facial images required 120 hours of processing time (Lugmayr et al., 2022), while generating each reconstructed image took approximately 14 minutes and 30 seconds. These findings underscore the necessity for optimizations and the development of more efficient computational infrastructures to facilitate the large-scale implementation of these models.

The qualitative evaluation of facial reconstruction results, shown in Figure 5, indicates that the model effectively recovers lost facial information in low and moderate occlusion scenarios (15% and 20%). Sample 1 (male face) achieved the best reconstruction for 15% occlusion, while sample 2 (female face) visually produced the best results for 20% occlusion. However, the model's performance degrades notably under conditions of high occlusion (50%), highlighting the need for further research to improve the model's robustness in scenarios with more extensive information loss.

Table 2 presents the quantitative statistics for MSE, PSNR and SSIM metrics. The analysis of sample 1 reveals an inverse correlation between the level of occlusion and the quality of the reconstruction. The 15 % occlusion scenario showed the highest MSE, indicating greater fidelity to the original image. This observation is corroborated by the PSNR and SSIM values, which also achieved the best results in the same scenario. The expected gradual decrease in these metrics with increasing reflects the added challenge larger occluded areas pose to the reconstruction process. However, the results demonstrate the model's robustness to generate high-quality reconstructions, even under challenging conditions.

Figure 5

Reconstruction of Two Samples Under 15%, 20% and 50% MRD Occlusion Scenarios. (a) Sample 1, (b) Sample 2

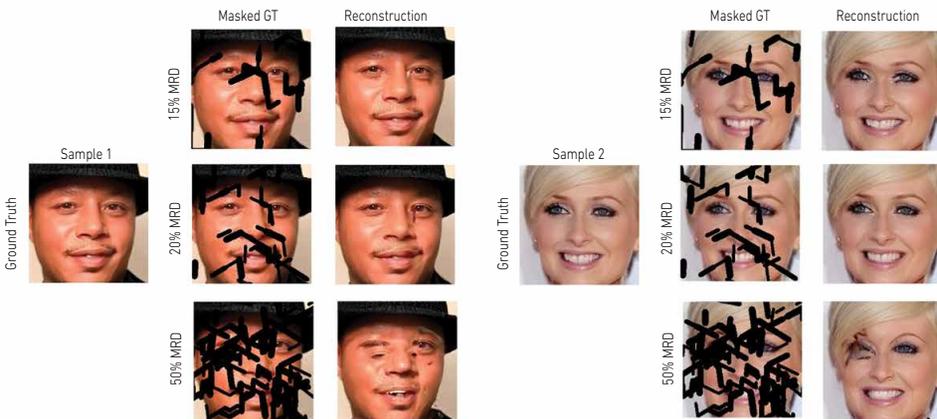


Table 2

MSE, PSNR, and SSIM Quantitative Statistics from Sample 1

Scenarios	MSE ↓	PSNR ↑	SSIM ↑
15 %	0,0044	29,5741	0,9295
20 %	0,0412	29,8718	0,9126
50 %	0,0214	22,7156	0,7773

Note. ↓ indicates that a lower value is better, while ↑ indicates that a higher value is better.

The quantitative statistics of sample 2, presented in Table 3 and using the MSE, PSNR, and SSIM metrics, reveals a different behavior compared to sample 1. The 20% occlusion scenarios showed the lowest MSE, indicating greater fidelity to the original image. This observation is corroborated by the PSNR values which also achieved the best results in the same scenario. However, SSIM reached its peak at 15% occlusion. Similarly to sample 1, the results for sample 2 highlights the model’s robustness to generate high-quality reconstructions, even under challenging occlusion conditions.

Table 3

MSE, PSNR, and SSIM Quantitative Statistics from Sample 2

Scenarios	MSE ↓	PSNR ↑	SSIM ↑
15 %	0,0017	33,6736	0,9379
20 %	0,0014	34,6582	0,9291
50 %	0,0123	25,1303	0,8106

Note. ↓ indicates that a lower value is better, while ↑ indicates that a higher value is better.

4.3 Third Experiment: Segmentation of Bodies Water

The accurate segmentation of lakes in high-resolution images, especially in complex mountainous regions such as the Peruvian Andes, presents significant challenges for environmental monitoring and water resource management. The experiment conducted by Perez-Torres et al. (2024) proposes an innovative approach called WaterSegDiff, which is based on diffusion probabilistic models and transformers. WaterSegDiff incorporates semantic anchoring and conditioning mechanisms to capture the distinctive characteristics of lakes across different environmental contexts. Applied to high-resolution images of the Peruvian Andes, WaterSegDiff generates accurate and up-to-date lake maps, essential for monitoring the dynamics of these ecosystems that are sensitive to climate change and land use. The high temporal and spatial frequency of remote sensing data makes it possible to detect changes in the lake area and morphology, providing crucial information for integrated water resources management and Andean biodiversity conservation.

Figure 6 shows three examples of lake segmentation using WaterSegDiff, illustrating different areas covered by bodies of water. The qualitative results demonstrate the model's ability to approximate ground truth, indicating high performance in segmenting bodies of water, even in complex scenarios. Although small discrepancies were observed between the ground truth and predict masks, the model exhibits accurate and robust segmentation, underscoring its potential for applications in hydrological studies and water resource management.

The computational cost of training and running inference on generative models, such as Repaint, while generating a single image after training required around 15 minutes for segmentation processing. Training and testing were performed using a 3.0 GHz Intel Xeon Gold 6342 CPU and an NVIDIA HGX A100 GPU.

To quantify the segmentation ability, the model was subjected to a quantitative evaluation using the intersection over union (IoU), pixel accuracy (PA) and F1 score metrics, as shown in Table 4. Analysis of Table 4 reveals that scenario 2 has the highest IoU value, indicating a better overlap between the segmented regions and reference regions. On the other hand, scenario 1 obtained the best PA and F1 score values, demonstrating high pixel classification accuracy and a good balance between accuracy and suppression. With all metrics exceeding 0,95, these results suggest that the model exhibits strong generalization power for segmentation tasks, even under challenging scenarios.

Figure 6

Segmentation Using WaterSegDiff: (a) showing the RGB Image, (b) Ground Truth Mask, and (c) Predicted Mask

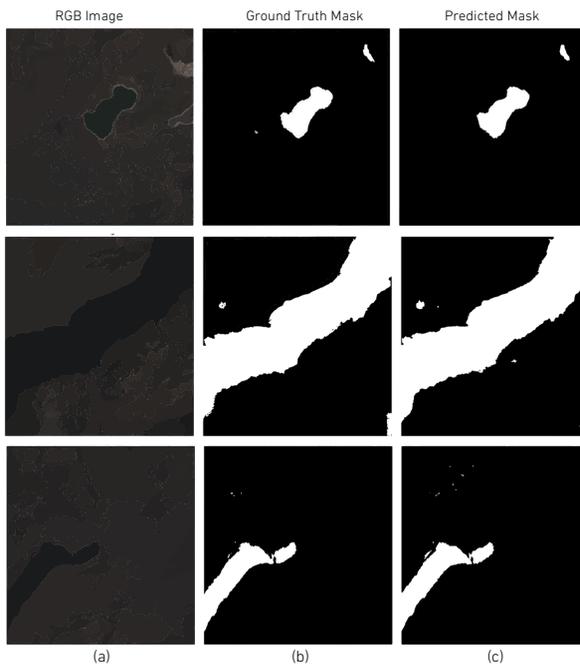


Table 4*Metrics and Standard Parameters for Quantitative Statistics from the WaterSegDiff Model*

Scenarios	IoU ↑	PA ↑	F1 Score ↑
1	0,9561	0,9984	0,9776
2	0,9677	0,9900	0,9836
3	0,9502	0,9971	0,9745

Note. ↓ indicates that a lower value is better, while ↑ indicates that a higher value is better.

5. DISCUSSION

The analysis of Figure 4 and Table 1 - i. e., the results of the first experiment - reveals that cloud cover has a significant impact on the quality of LST image reconstruction in Western Amazonia. As cloud cover increases, the MSE, PSNR and SSIM quantitative metrics indicate a progressive deterioration in reconstruction quality, corroborating the findings from the visual analysis. However, the model shows robustness across different cloud cover conditions, yielding promising results even under high cloudiness. The 15% cloud cover scenario achieved excellent results, with the highest PSNR and SSIM values indicating a reconstruction that was both accurate and closely aligned to the original image. As cloud cover increased to 22% and 50%, a gradual degradation in reconstruction quality was observed, although metric values remained satisfactory, especially considering the complexity of the task. These results suggest that cloud cover is the main factor affecting LST image reconstruction quality in the study region. While other factors - such as cloud type, spatial and temporal resolution, and atmospheric conditions - may contribute to variability in results, cloud cover's influence stands out.

Regarding the second experiment, the qualitative results shown in Figure 5 indicate that robust model performs well in reconstructing facial images with low and moderate occlusion levels, though performance degrades significantly under conditions of high occlusion. Quantitative metrics from Tables 2 and 3, corroborate these observations, with MSE, PSNR, and SSIM metrics showing an inverse correlation between the occlusion level and the reconstruction quality. This suggests that the model performs better in scenarios under a lower level of occlusion. The experiment demonstrates the effectiveness of the inpainting technique based on diffusion models for the reconstruction of partially occluded facial images, highlighting its potential for applications in facial recognition systems.

Finally, in the third experiment, the results obtained with the WaterSegDiff model demonstrate high accuracy in segmenting lakes, even in complex scenarios. The comparison between model-generated masks with reference masks ground truth indicates

excellent agreement, with only minor discrepancies in some cases, as shown in Figure 6. The IoU, PA, and F1 score metrics in Table 4 further quantify the model's performance, with all exceeding 0,95 across all scenarios, which suggests a strong generalization power for segmentation tasks. The application of the WaterSegDiff to high-resolution images of the Peruvian Andes enables the generation of accurate and up-to-date lake maps, essential for monitoring the dynamics of these ecosystems that are sensitive to climate change and land use.

While the results demonstrate considerable potential, the computational cost is significantly higher than that of state-of-the-art models in the literature. Notably, the facial reconstruction model required the most extended training time compared to the other two experiments, highlighting the need for optimization processes to make these models more practical for real-time scenarios.

6. CONCLUSIONS

Diffusion probabilistic models have demonstrated significant potential across various image processing tasks, especially for reconstructing occluded or damaged areas and segmenting image. This study explored the application of DDPMs in three specific areas: reconstruction of remote sensing imagery for estimating LST in areas with cloud cover, segmentation of bodies of water in satellite images for delimiting areas covered by lakes and reconstruction of facial images with occluded areas, to improving facial recognition systems. Reconstruction was achieved through inpainting where DDPMs enabled the recovery of lost information for more precise and complete analyses. The study also presents two applications of RePaint for reconstruction tasks and WaterSegdiff, which uses a DDPM backbone, transformers, semantic anchoring and conditioning mechanisms, for segmentation.

A notable advantage of diffusion-based approaches, as observed in the experiments, is that these methods require only a single sample to perform reconstruction and/or segmentation, unlike other approaches that need multiple images to complement the task.

In the first experiment, cloud cover emerged as the main factor affecting LST image reconstruction quality in Western Amazonia. Although the model exhibited spatial discontinuities relative visual structures in some areas high cloudiness did not compromise reconstruction accuracy, indicating optimal performance. In the second experiment, the model proved robustness in reconstructing facial images with low and moderate occlusion, though performance degraded under high occlusion. Finally, in the third experiment, WaterSegDiff showed high performance in segmenting lakes, even in complex scenarios, achieving quantitative statistics exceeding 0,95 across all scenarios. Thus, despite challenges from atmospheric conditions, occlusion level, and scene complexity, these

findings demonstrate the strong performance of diffusion models in handling complex tasks such as image reconstruction and segmentation.

Generative diffusion models thus offer an innovative approach with significant potential for intelligent digital image processing applications, including environmental monitoring, facial recognition, and water resource mapping, emphasizing the versatility of diffusion models.

Although the outcomes are promising, the models utilized in this research present a key limitation: high computational cost. Pursuing optimization strategies is essential to reduce computational time and enhance the efficiency of these models for practical applications. Future research should focus on strengthening the model's resilience in challenging scenarios, particularly by improving their ability to cope with elevated occlusion rates, which are typical of dynamic and complex environments. Furthermore, accurately segmenting more complex environmental elements, such as transparent objects or those with a similar texture to the background, remains a significant challenge to be addressed. These considerations reveal a significant scope for further research and development, as the field faces numerous challenging and complex issues that require in-depth research.

The exploration of new applications for this promising technology offers a rich field for future research. The authors are particularly interested in utilizing generative diffusion models for tasks such as high dynamic range (HDR) image enhancement and generative data augmentation, aimed at improving computer vision capabilities across various domains. Additionally, advancements of quantization, pruning and knowledge distillation techniques hold great promise for reducing model size and accelerating inference, thereby enhancing their suitability for resource-limited devices.

REFERENCES

- Adrian, R., O'Reilly, C. M., Zagarese, H., Baines, S. B., Hessen, D. O., Keller, W., David M. Livingstone, D. M., Sommaruga, R., Straile, D., Van Donk, E., Weyhenmeyer, G. A., & Winder, M. (2009). Lakes as sentinels of climate change. *Limnology and oceanography*, 54(6 part 2), 2283-2297. https://doi.org/10.4319/lo.2009.54.6_part_2.2283
- Ali, W., Tian, W., Din, S. U., Iradukunda, D., & Khan, A. A. (2021). Classical and modern face recognition approaches: a complete review. *Multimedia tools and applications*, 80, 4825-4880. <https://doi.org/10.1007/s11042-020-09850-1>
- Alves, U. D. S. (2024). *Reconstrução de áreas ausentes em imagens faciais usando a técnica de inpainting baseada em modelo de difusão*. [Master's thesis, Universidade Federal do Acre], UFAC.

- Amit, T., Shaharbany, T., Nachmani, E., & Wolf, L. (2021). *Segdiff: Image segmentation with diffusion probabilistic models*. ArXiv. <https://doi.org/10.48550/arXiv.2112.00390>
- Avrahami, O., Lischinski, D., & Fried, O. (2022). Blended diffusion for text-driven editing of natural images. *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, New Orleans, LA, USA, 18208 – 18218. <https://doi.org/10.48550/arXiv.2111.14818>
- Awais, M., Li, W., Hussain, S., Cheema, M. J. M., Li, W., Song, R., & Liu, C. (2022). Comparative evaluation of land surface temperature images from unmanned aerial vehicle and satellite observation for agricultural areas using in situ data. *Agriculture*, 12(2), 184. <https://doi.org/10.3390/agriculture12020184>
- Ayala, C., Sesma, R., Aranda, C., & Galar, M. (2023). Diffusion models for remote sensing imagery semantic segmentation. *IGARSS 2023-2023 IEEE International Geoscience and Remote Sensing Symposium*, Pasadena, CA, USA (5654 – 5657). <https://doi.org/10.1109/IGARSS52108.2023.10281461>
- Bandara, W. G. C., Nair, N. G., & Patel, V. M. (2022). *DDPM-CD: Denoising Diffusion Probabilistic Models as Feature Extractors for Change Detection*. ArXiv. <https://doi.org/10.48550/arXiv.2206.11892>
- Bastiaanssen, W. G., Menenti, M., Feddes, R. A., & Holtslag, A. A. M. (1998). A remote sensing surface energy balance algorithm for land (SEBAL). 1. Formulation. *Journal of Hydrology*, 212, 198-212. [https://doi.org/10.1016/S0022-1694\(98\)00253-4](https://doi.org/10.1016/S0022-1694(98)00253-4)
- Bezerra, E., Mafalda, S., Alvarez, A. B., Uman-Flores, D. A., Perez-Torres, W. I., & Palomino-Quispe, F. (2023). A cloud coverage image reconstruction approach for remote sensing of temperature and vegetation in amazon rainforest. *Applied Sciences*, 13(23), Article 12900. <https://doi.org/10.3390/app132312900>
- Cao, Y., Li, S., Liu, Y., Yan, Z., Dai, Y., Yu, P. S., & Sun, L. (2023). *A comprehensive survey of AI-Generated Content (AIGC): A history of generative AI from GAN to ChatGPT*. ArXiv. <https://doi.org/10.48550/arXiv.2303.04226>
- Dhariwal, P., & Nichol, A. (2021). Diffusion models beat gans on image synthesis. *Advances in neural information processing systems*, 34, 8780-8794. https://proceedings.neurips.cc/paper_files/paper/2021/file/49ad23d1ec9fa4bd8d77d02681df5cfa-Paper.pdf
- Elharrouss, O., Almaadeed, N., Al-Maadeed, S., & Akbari, Y. (2020). Image inpainting: A review. *Neural Processing Letters*, 51, 2007-2028. <https://doi.org/10.1007/s11063-019-10163-0>
- Hidalgo García, D., & Arco Díaz, J. (2021). Spatial and multi-temporal analysis of land surface temperature through Landsat 8 images: comparison of algorithms

- in a highly polluted city (Granada). *Remote Sensing*, 13(5), 1012. <https://doi.org/10.3390/rs13051012>
- Ho, J., Jain, A., & Abbeel, P. (2020). Denoising diffusion probabilistic models. In H. Larochelle, M. Ranzato, R. Hadsell, M.F. Balcan, & H. Lin (Eds.). *Advances in Neural Information Processing Systems*, 33 (*NeurIPS 2020*) (pp. 6840-6851). https://proceedings.neurips.cc/paper_files/paper/2020/file/4c5bcfec8584af0d967f1ab10179ca4b-Paper.pdf
- Jing, R., Duan, F., Lu, F., Zhang, M., & Zhao, W. (2023). Denoising diffusion probabilistic feature-based network for cloud removal in Sentinel-2 imagery. *Remote Sensing*, 15(9), Article 2217. <https://doi.org/10.3390/rs15092217>
- Kawar, B., Elad, M., Ermon, S., & Song, J. (2022). Denoising diffusion restoration models. In S. Koyejo, S. Mohamed, A. Agarwal, D. Belgrave, K. Cho, & A. Oh (Eds.). *Advances in Neural Information Processing Systems*, 35 (*NeurIPS 2020*), 23593-23606. <https://doi.org/10.48550/arXiv.2201.11793>
- Kortli, Y., Jridi, M., Al Falou, A., & Atri, M. (2020). Face recognition systems: A survey. *Sensors*, 20(2), Article 342. <https://doi.org/10.3390/s20020342>
- Leher, Q. O. (2024). *Inpainting com Modelos Generativos Probabilísticos de Difusão para a Reconstrução de áreas de Interesse em Imagens Satelitais*. [Bachelor's thesis, Universidade Federal do Acre]. UFAC.
- Li, X., Ren, Y., Jin, X., Lan, C., Wang, X., Zeng, W., Wang, X. & Chen, Z. (2023). *Diffusion models for image restoration and enhancement. A comprehensive survey*. ArXiv. <https://doi.org/10.48550/arXiv.2308.09388>
- Liu, J., Yuan, Z., Pan, Z., Fu, Y., Liu, L., & Lu, B. (2022). Diffusion model with detail complement for super-resolution of remote sensing. *Remote Sensing*, 14(19), article 4834. <https://doi.org/10.3390/rs14194834>
- Lugmayr, A., Danelljan, M., Romero, A., Yu, F., Timofte, R., & Van Gool, L. (2022). RePaint: Inpainting using denoising diffusion probabilistic models. *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, New Orleans, LA, USA, (pp. 11461-11471). <https://doi.org/10.48550/arXiv.2201.09865>
- Muzammal, N. M. Ranasinghe, K., Khan, S., Hayat, M., Khan, F. S., & Yang M.-H. (2021). Intriguing properties of vision transformers. *Adv. Neural Info. Process. Syst.*, 34. <https://doi.org/10.48550/arXiv.2105.10497>
- Murfitt, J., & Duguay, C. R. (2021). 50 years of lake ice research from active microwave remote sensing: Progress and prospects. *Remote Sensing of Environment*, 264, Article 112616. <https://doi.org/10.1016/j.rse.2021.112616>
- Naseer, M. M., Ranasinghe, K., Khan, S. H., Hayat, M., Khan, F. S., & Yang, M.-H. (2021). Intriguing properties of vision transformers. In M. Ranzato, A. Beygelzimer, Y. Dauphin, P. S.

- Liang, & J. Wortman Vaughan (Eds.). *Advances in Neural Information Processing Systems 34 (NeurIPS 2021)* (pp. 23296-23308). https://proceedings.neurips.cc/paper_files/paper/2021/file/c404a5adbf90e09631678b13b05d9d7a-Paper.pdf
- Perez-Torres, W. I., Uman-Flores, D. A., Quispe-Quispe, A. B., Palomino-Quispe, F., Bezerra, E., Leher, Q., Paixão, T. & Alvarez, A. B. (2024). Exploratory analysis using deep learning for water-body segmentation of Peru's high-mountain remote sensing images. *Sensors*, 24(16), article 5177. <https://doi.org/10.3390/s24165177>
- Rombach, R., Blattmann, A., Lorenz, D., Esser, P., & Ommer, B. (2022). High-resolution image synthesis with latent diffusion models. *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, New Orleans, LA, USA, (10684-10695). <https://doi.org/10.48550/arXiv.2112.10752>
- Singh, A., & Vyas, V. (2022). A review on remote sensing application in river ecosystem evaluation. *Spatial Information Research*, 30(6), 759-772. <https://doi.org/10.1007/s41324-022-00470-5>
- Sohl-Dickstein, J., Weiss, E., Maheswaranathan, N., & Ganguli, S. (2015). Deep unsupervised learning using nonequilibrium thermodynamics. *Proceedings of Machine Learning Research*, 37, (2256-2265). <https://proceedings.mlr.press/v37/sohl-dickstein15.html>
- Tan, H., Wu, S., & Pi, J. (2022). Semantic diffusion network for semantic segmentation. In S. Koyejo, S. Mohamed, A. Agarwal, D. Belgrave, & K. Cho and A. Oh (Eds.). *Advances in Neural Information Processing Systems 35 (NeurIPS 2020)* https://proceedings.neurips.cc/paper_files/paper/2022/file/396446770f5e8496ca1feb02079d4fb7-Paper-Conference.pdf
- Taskiran, M., Kahraman, N., & Erdem, C. E. (2020). Face recognition: Past, present and future (a review). *Digital Signal Processing*, 106, article 102809. <https://doi.org/10.1016/j.dsp.2020.102809>
- Wu, J., Gan, W., Chen, Z., Wan, S., & Lin, H. (2023). *Ai-generated content (aigc): A survey*. ArXiv. <https://doi.org/10.48550/arXiv.2304.06632>
- Yang, L., Zhang, Z., Song, Y., Hong, S., Xu, R., Zhao, Y., Zhang, W., Cui, B., & Yang, M.-H. (2023). Diffusion models: A comprehensive survey of methods and applications. *ACM Computing Surveys*, 56(4), 1-39. <https://doi.org/10.1145/3626235>
- Zhang, S., Li, J., & Yang, L. (2023). *Survey on controllable image synthesis with deep learning*. ArXiv. <https://doi.org/10.48550/arXiv.2307.10275>
- Zhao, X., & Jia, K. (2023). Cloud removal in remote sensing using sequential-based diffusion models. *Remote Sensing*, 15(11), Article 2861. <https://doi.org/10.3390/rs15112861>

PERSPECTIVAS PARA LA EDUCACIÓN EN IA: IMPORTANCIA DE LA INCLUSIÓN DE HABILIDADES Y COMPETENCIAS TÉCNICAS DE IA EN LOS PLANES DE ESTUDIO

OLDA BUSTILLOS ORTEGA

obustillos@uia.ac.cr

<https://orcid.org/0000-0003-2822-3428>

Universidad Internacional de las Américas, Costa Rica

JORGE MURILLO GAMBOA

jmurillo@uia.ac.cr

<https://orcid.org/0000-0001-5548-8283>

Universidad Internacional de las Américas, Costa Rica

OLMAN NÚÑEZ PERALTA

onunez@uia.ac.cr

<https://orcid.org/0000-0001-6780-022X>

Universidad Internacional de las Américas, Costa Rica

FABIÁN RODRÍGUEZ SIBAJA

frodriguez@uia.ac.cr

<https://orcid.org/0009-0008-3276-9865>

Universidad Internacional de las Américas, Costa Rica

Recibido: 26 de junio de 2024 / Aceptado: 2 de octubre de 2024

doi: <https://doi.org/10.26439/interfases2024.n020.7198>

RESUMEN. La inteligencia artificial (IA) es el invento más importante de la humanidad. Lo tenemos presente en la sociedad y la economía, pero también ahora impacta en la academia, en la que los docentes y los estudiantes hacen uso de modelos lingüísticos y de interacción como el ChatGPT y otros más. En este estudio se hace referencia a encuestas e investigaciones sobre el uso y las aplicaciones de la IA. Se muestran resultados de una encuesta sobre temas de formación en IA, la cual fue aplicada a docentes y estudiantes universitarios en Costa Rica. Se hace un análisis comparativo de los resultados y se presentan cuadros de ambos grupos encuestados. Adicionalmente, se proveen lineamientos base para formular contenidos y temarios de IA dentro de la currícula de una carrera de tecnología. Finalmente, se brindan recomendaciones sobre las habilidades y competencias técnicas a desarrollar.

PALABRAS CLAVE: inteligencia artificial / currículo / encuesta / tecnología

PERSPECTIVES ON AI EDUCATION: THE IMPORTANCE OF INCLUDING AI SKILLS AND TECHNICAL COMPETENCIES IN CURRICULA

ABSTRACT. Artificial intelligence (AI) is the most important invention of humanity and we have it present in society and the economy, but it is also now impacting the academy where teachers and students make use of linguistic and interaction models such as ChatGPT and others. This study refers to surveys and research on the use and applications of AI. The results of a survey on AI training topics are shown, which was applied to teachers and university students in Costa Rica. A comparative analysis of the results is made and tables of both groups surveyed are presented. Additionally, basic guidelines are provided to formulate AI content and syllabus within the curriculum of a technology career. Finally, recommendations are given on the technical skills and competencies to be developed.

KEYWORDS: artificial intelligence / curriculum / survey / technology

1. INTRODUCCIÓN

1.1. Definiciones y objeto de estudio

La inteligencia artificial (IA) la podemos definir como un ámbito de estudio y desarrollo de sistemas computacionales, los cuales son capaces de llevar a cabo tareas que normalmente requieren capacidades cognitivas de los seres humanos. Esta disciplina contempla su aplicación en múltiples áreas, como el procesamiento del lenguaje natural, la visión por computadora, la robótica y los sistemas de recomendación, y su objetivo es diseñar máquinas que puedan simular funciones cognitivas humanas permitiéndoles resolver problemas de manera eficiente.

En el presente estudio se realiza un análisis de diferentes aplicaciones, experiencias, encuestas y usos de la IA enfocado hacia el ambiente de la academia. Se presentan cuadros resumen que reflejan los resultados de la encuesta de opinión acerca de incorporar la IA dentro de los planes de estudio y temas sugeridos por los encuestados. Se consolidan los elementos esenciales sobre formación y competencias, aplicables tanto para el docente, la investigación y el acompañamiento a estudiantes. Con respecto al concepto de competencias, podemos interpretarlo en términos generales como las capacidades o habilidades para efectuar tareas o hacer frente a situaciones de forma eficaz (saber hacer) en un contexto determinado, movilizand o actitudes, destrezas y conocimientos al mismo tiempo y de forma interrelacionada (Cubillos, 2012).

Por otro lado, la Association for Computing Machinery y la IEEE Computer Society, responsables de la publicación *Computing Curricula 2020 (CC2020)*, integraron el enfoque de aprendizaje basado en competencias para abordar el desafío de la brecha de habilidades entre los graduados de programas de computación y las demandas de la industria. Tanto las competencias técnicas como los atributos humanos son cada vez más valorados, y tal como se definen en los planes de estudio de Computación 2020, lo podemos definir en este artículo, como la suma de conocimientos, más habilidades más disposiciones profesionales (Frezza et al., 2018; Impagliazzo, 2019; Raj et al., 2021).

1.2. Orígenes de la IA

De acuerdo con uno de los padres fundadores de la IA, Marvin Minsky, la IA es definida como la "ciencia que tiene como objetivo que una máquina realice tareas que los humanos realizan utilizando su inteligencia" (Elloumi, s. f., p. 18). Estudios sobre la IA comenzaron a publicarse desde 1970, y el campo ha sido un foro generalmente aceptado para la publicación de investigaciones (Fetzer, 1990). Desde 1950, Alan Turing creó un test que define y estipula que a partir del momento en que un internauta no puede discernir si está interactuando con un humano, entonces la computadora puede describirse como inteligente. Para el 2006 aparece Watson, de IBM, como "la supercalculadora", un ejemplo de programa informático capaz de comprender nuestro lenguaje y pensamiento,

de simular el razonamiento humano y de utilizar una base de datos cercana al millón de libros (Elloumi, s. f.).

La IA se incorpora dentro del campo en el que las computadoras resuelven problemas (Schmidt, 2017). Ejemplos de IA los encontramos en nuestros dispositivos móviles, o en aplicaciones como Siri de Apple (desde el 2010) y Alexa de Amazon (desde el 2015), las cuales ayudan a completar tareas y a responder preguntas por medio de la voz (Kumar, 2019). En la academia, las tecnologías de computación se han estado utilizando para estudiar, investigar y resolver problemas como recurso educativo (análogo a una biblioteca o un laboratorio), y para la administración, como un medio para mantener las bases de datos de estudiantes (Jones, 1985).

1.3. Desafíos y riesgos sobre la formación en la IA

El término *chatbot*, o *agente conversacional*, se define como un programa de computadora capaz de simular y mantener una conversación con humanos mediante el intercambio de voz o texto. Esto revolucionará fundamentalmente la forma en que las personas experimentan la informática (Elloumi, s. f.). La IA generativa, específicamente OpenAI y su producto ChatGPT, consiste en un chatbot con una interfaz conversacional del tipo cerrado y autónomo, y que intenta responder cualquier tema que se le pregunte sin exigirle al usuario alguna habilidad o conocimiento previo. Esto podría ser un factor de riesgo en la academia, debido a la ausencia o a un escaso conocimiento de los docentes para utilizar ChatGPT de forma efectiva, sobre todo en lo que respecta a la elaboración de propuestas para evaluar a los estudiantes (Artopoulos, 2023). Otros investigadores señalan la aparición de nuevos desafíos y riesgos relacionados con el desarrollo del lenguaje empleado en clase, lo cual debilitaría capacidades que históricamente se enseñan y transmiten por los profesores de manera presencial (Ubal Camacho et al., 2023).

Entre abril y mayo del 2023, en Australia, se llevó a cabo un estudio con académicos y estudiantes universitarios. Se recibieron un total de 110 respuestas, 78 de estudiantes y 32 del personal académico. El estudio reveló que, menos del 10 % de los estudiantes encuestados había utilizado la IA generativa para crear contenido y elaborar trabajos asignados en clase. Los resultados también expresaron preocupaciones sobre la ética en el uso de esta tecnología, además de respecto a su impacto en las habilidades de aprendizaje y las consecuencias a largo plazo en el pensamiento y aprendizaje humanos (Skeat & Ziebell, 2023).

Otro paradigma para considerar es con respecto a la educación autogestionada, en la cual se plantea que cada persona que emplee la tecnología de IA puede generar su propio autoconocimiento y, con apoyo de una metodología de autocuantificación, puede llegar a medir el nivel de su propio conocimiento adquirido, sin límites de tiempo ni espacio (Palacios Rozo et al., 2018). En mayo del 2019, en Argentina, investigadores del Centro de Innovación en Tecnología y Pedagogía establecieron lineamientos de IA para

el ámbito educativo, en el marco de la Conferencia Internacional sobre la Inteligencia Artificial y la Educación, organizada por la Unesco y por el gobierno de la República Popular de China (Andreoli et al., 2022).

Con respecto a la educación superior, la IA está cada vez más presente en los procesos de digitalización y automatización en las áreas de enseñanza, aprendizaje, gestión, investigación y evaluación educativa. Por lo anterior, se han establecido una serie de desafíos para impulsar los desarrollos y aplicaciones de IA y que impactan en los procesos de enseñanza y aprendizaje (Andreoli et al., 2022). De acuerdo con Andreoli et al. (2022), los desafíos se agrupan en un marco de acciones en tres categorías:

- a) Formación docente. Esto abarca la facilitación con estudiantes, mediante el uso de agentes conversacionales, con un lenguaje natural, en procesos evaluativos, en la corrección automática de cuestionarios y en la calificación de exámenes de forma automatizada.
- b) Investigación y desarrollo. Esto abarca los itinerarios de aprendizaje, los sistemas de tutorías inteligentes para el aprendizaje adaptativo o personalizado, la recomendación de trayectos, la asistencia tutorial a través de agentes conversacionales, el desarrollo de habilidades comunicativas y la telepresencia en el aula física.
- c) Acompañamiento a estudiantes. Esto abarca opciones para el análisis de contenidos, la lectura remota, el procesamiento de imágenes, el aprendizaje adaptativo, y sistemas de aprendizaje basados en la colaboración y en el diálogo entre un agente de IA y un estudiante humano.

2. OBJETIVOS DE LA INVESTIGACIÓN

Se busca establecer perspectivas que sirvan de guía para la formación académica en IA, para lo cual la investigación se enfoca en la identificación de conceptos, herramientas y aplicaciones de IA. Asimismo, la investigación busca proponer la incorporación de IA dentro de los planes de estudio de las carreras informáticas actuales, así como también formular cursos de extensión y talleres prácticos sobre IA con un enfoque de aprendizaje basado en competencias.

Dentro de los objetivos específicos de la investigación, se consideran los siguientes:

1. Identificar elementos claves que deben estar presentes en los planes académicos considerando competencias y habilidades en IA que los puestos de trabajo actuales demandan en instituciones y empresas.
2. Examinar marcos de referencia de organizaciones, empresas internacionales y programas académicos, así como el abordaje no sólo de conceptos técnicos, sino también del pensamiento crítico, la resolución de problemas y la ética.

3. Analizar la encuesta aplicada a docentes y estudiantes universitarios de una carrera de tecnología sobre la inclusión de temas de IA dentro del plan de estudios, y registrar los resultados en tablas con las consideraciones clave de ambos grupos encuestados.
4. Organizar tablas resumen con contenidos temáticos para ser incorporadas dentro de los planes de estudio y justificar las necesidades emergentes sobre el uso y aplicación de la IA en la educación formal.

Como producto final de la investigación, se presentan tablas de referencia que muestran los resultados agrupados en las siguientes áreas temáticas de IA:

- a) Inclusión en el plan de estudios. Formación teórica, práctica y aspectos relacionados con la ética.
- b) Habilidades técnicas. Lógica computacional, análisis, abstracción y algoritmos.
- c) Habilidades transversales. Pensamiento crítico y analítico, creatividad, capacidad efectiva de comunicación, resolución de problemas y desarrollo de equipos de trabajo.
- d) Enfoque práctico. Talleres prácticos que usan herramientas, agentes, asistentes y plataformas de IA para buscar, obtener y gestionar la información.
- e) Aspectos sociales, de seguridad y de gobierno. La IA en la cultura tecnológica, procesos de gobernanza, arquitectura de aplicaciones, seguridad física y ciberseguridad.

3. METODOLOGÍA

Para identificar los componentes y competencias dentro de los planes de estudio en educación técnica-universitaria sobre IA, se realizaron búsquedas a nivel nacional e internacional que abordasen temas relacionados con la formación sobre IA a través de las siguientes etapas: revisión documental, revisión de literatura y aplicación de una encuesta.

3.1. Revisión documental (selección de cursos y talleres)

Se investigó sobre el desarrollo de talleres, cursos prácticos y programas de formación en IA por parte de ministerios de educación, universidades y centros de formación, para lo cual se utilizó fuentes de, entre otras, la Unión Europea (UE), los Estados Unidos de América, la República Popular de China y países de Latinoamérica. Para el caso de IA en Costa Rica, se hizo referencia a publicaciones del Ministerio de Ciencia, Innovación, Tecnología y Telecomunicaciones (MICITT) y del Ministerio de Educación Pública (MEP), además de fuentes privadas como la Coalición de Iniciativas para el Desarrollo (CINDE),

la Cámara de Tecnologías de Tecnologías y el programa IA de la corporación internacional fabricante de semiconductores Intel.

3.2. Revisión de literatura (análisis de documentos)

Se realizó una revisión de literatura accediendo a diferentes bases de datos como Google Académica, ProQuest Digital Dissertation and Theses, IEEE Xplore y Academia.edu. Adicionalmente, se examinaron publicaciones de las oficinas de ministerios de educación y comunicados de prensa de gobiernos, así como iniciativas de institutos y empresas privadas con la mira en elementos clave que nos permitan cumplir con los objetivos específicos 1 y 2.

3.3. Aplicación de una encuesta (docentes y estudiantes universitarios)

Se diseñó y se aplicó una encuesta con invitación exclusiva a docentes y estudiantes de la Escuela de Ingeniería Informática de la Universidad Internacional de las Américas, con sede en San José, Costa Rica. El tema central de la encuesta fue el cuestionamiento: ¿qué habilidades y competencias relacionadas con la formación en IA considera usted importante incluir en el plan de estudios de una carrera de tecnología? Se seleccionó el criterio de utilizar preguntas cerradas de escogencia múltiple y preguntas abiertas de opinión. La encuesta se desarrolló y se procesó mediante la plataforma SurveyMonkey (diseño, envío, recopilación de respuestas, generación de reportes y gráficas con resultados). Para acceder de forma remota y segura a la interfaz que contenía las preguntas, se envió un enlace exclusivo a través de internet, el cual podía ser usado por el participante, desde cualquier equipo móvil o estación de trabajo, utilizando claves cifradas de acceso restringidas únicamente a los encuestados invitados a participar. Se enviaron invitaciones de participación y se obtuvieron respuestas de un total de dieciocho docentes y ciento veinte estudiantes universitarios. Los resultados se procesaron, se resumieron, se analizaron y se elaboraron tablas comparativas, con lo cual se cumplía con los objetivos específicos 3 y 4.

4. COMPETENCIAS Y FORMACIÓN EN IA

4.1. Competencias en IA

Posterior a la pandemia del COVID-19, en la sociedad se ha notado un incremento en cuanto a la innovación que produce el uso de tecnologías apoyadas en la IA; y, en el sector de educación, las generaciones actuales se integran a las lecciones virtuales mediante el uso de dispositivos dentro y fuera del aula (Pascuas-Rengifo et al., 2020). La IA nos ofrece el potencial de cambiar la educación en una forma novedosa para el desarrollo, al incorporar nuevos factores que enriquecen la alfabetización digital; son los docentes y los estudiantes los invitados a aprovecharla (Manjarrés & Pickin, 2021). Dependiendo del

nivel de desarrollo de un país, el impacto en la educación se verá reflejado en los diferentes grados de aceptación y uso, ya sea por la vía del caos o de una adaptación creativa (Ocaña-Fernández et al., 2019).

Por otro lado, existe la necesidad de superar la denominada brecha digital de IA, especialmente de parte de los países en desarrollo. Para esto, se debe promover la inversión e implementación de una estrategia para la educación superior que incorpore tecnologías y sistemas de IA que satisfagan las diversas necesidades de las universidades en general (Cotrina-Aliaga et al., 2021). Adicionalmente, Cotrina-Aliaga et al. (2021) proponen una estrategia de IA que refuerce las siguientes habilidades y competencias:

- Aprender sobre lenguajes de programación: a través de un aprendizaje acorde con un orden, una estructura y un método.
- Diseñar y construir robots: desarrollar habilidades de pensamiento computacional como la abstracción, que permitan dividir un problema en partes y elaborar soluciones en forma de instrucciones o algoritmos.
- Buscar, recopilar y gestionar la información: fomentar la curiosidad, el análisis y la investigación (similar a las actitudes de los científicos).
- Promover una cultura tecnológica: permitiendo el acceso a equipos de computación, a internet y a la gestión de contenido multimedia (audio, video y texto).
- Crear e innovar: ejercicios para comprobar que no hay una única solución válida y que, promoviendo la creatividad, buscando soluciones innovadoras y aprendiendo de sus docentes y demás compañeros, se desarrollan las competencias esperadas.

4.2. Formación y regulación de la IA (a nivel internacional)

Existe un debate sobre quién debe enseñar ciencia: si los maestros o los científicos. Al respecto, la Real Sociedad de Gran Bretaña, en un reporte de julio del 2014 que da cuenta de su visión sobre el aprendizaje de las ciencias y las matemáticas, resaltó que los estudiantes aprenden mejor de ciencia, matemáticas y de conceptos complejos después de los dieciocho años, y que estas áreas deben ser enseñadas por los propios científicos, por su capacidad de contagiar la pasión por su quehacer (The Royal Society, 2014).

La UE ha estado promoviendo el Programa para la Evaluación Internacional de Estudiantes (PISA) con el objeto de valorar los sistemas educativos, y ha medido el rendimiento en áreas de matemáticas, ciencias y lectura. De acuerdo con los resultados de PISA, los primeros diez sistemas educativos con mayor puntaje en la UE corresponden, en orden, a Estonia, Finlandia, Irlanda, Polonia, Suecia, Dinamarca, Noruega, Alemania, Eslovenia y Bélgica; luego, en las diez posiciones siguientes, figuran Francia,

Portugal, República Checa, Países Bajos, Austria, Croacia, Letonia, España, Italia e Hungría (Schleicher, 2018). Con respecto al liderazgo de Estonia, el 2012 se inició el programa "Proge Tiger", promovido por la Fundación de Tecnologías de la Información y la Comunicación para la Educación, con el cual se posicionó como iniciativa académica líder en la UE. El programa introduce la programación y la robótica dentro de los planes de estudio nacionales de la enseñanza preescolar, primaria y profesional. Con respecto a los estudios superiores, se ofertan las clásicas asignaturas de ciencias (matemáticas, conocimiento básico en redes, *software* y *hardware*), en las que se le adicionó también la IA. Los resultados de este experimento revelan que la acogida por parte de los docentes ha sido masiva, con un 80 % de centros educativos del país ya incorporados como parte del programa (Medina et al., 2022). Otro caso es el de Australia, que en el 2018 sufrió el impacto de la automatización del empleo, con el desplazamiento de las horas trabajadas por empleado hacia actividades de mayor valor agregado; debido a esta experiencia, el gobierno elaboró políticas para promover nuevas inversiones en tecnología como una prioridad (Pounder & Liu, 2018).

En el caso del Perú, se visualiza la educación personalizada de la IA como una solución viable, por la cual la asistencia automatizada proporciona una perspectiva innovadora y atractiva, que impulsa el dinamismo en los procesos de aprendizaje tanto para estudiantes como para docentes. Y, a medida que se desarrollen nuevas y mejores aplicaciones apoyadas en la IA, se hace posible la formulación de alternativas dentro de los planes de estudio, con una adaptación acelerada en relación con las parsimoniosas formas de gestionar la educación de parte de los gobiernos clásicos del presente siglo (Ocaña-Fernández et al., 2019).

4.3. Formación en IA (estudio de caso sobre Costa Rica)

En marzo del 2022, el Consejo Superior de Educación de Costa Rica aprobó el primer programa de estudio sobre IA para la educación técnica profesional (ETP). La IA entró a formar parte del repertorio de especialidades de estos colegios técnicos, ya que fomenta el desarrollo de conocimientos, habilidades, destrezas, valores y capacidades actitudinales idóneas para el perfil del recurso humano que demanda el sector productivo del país: la incorporación a puestos de trabajo asociados a la automatización de procesos y al aprendizaje automático (Dirección de Educación Técnica y Capacidades Emprendedoras [DETCE], 2022).

Para noviembre del 2022 el Ministerio de Educación Pública (MEP) y la empresa multinacional Intel de Costa Rica firmaron un convenio para apoyar y habilitar la especialidad de IA para los colegios técnicos profesionales, pero con la inclusión adicional de temas sobre implicaciones éticas y legales de esta tecnología. Anna Katharina Müller, jefa del MEP, señaló que esta es una respuesta a la demanda de nuevos perfiles profesionales que requiere el país y que hoy caracterizan el mercado de trabajo, así como una

oportunidad para incrementar la competitividad, y de promover la innovación y la empleabilidad (Dirección de Prensa y Relaciones Públicas [DPRP], 2022). Finalmente, para febrero del 2023 el Gobierno de Costa Rica formuló la Estrategia Nacional de Inteligencia Artificial adaptada al contexto nacional, la cual sirve de base para una hoja de ruta con una visión ética y responsable en la adopción y uso de la IA a nivel país. Al respecto Paula Bogantes, jefa del MICITT, resalta que se hizo una apuesta por los grandes retos dentro de una sociedad y economía basada en el conocimiento y que, gracias al apoyo de los distintos actores, se han generado diversas iniciativas que incorporan tecnologías digitales y emergentes como la IA (MICITT, 2023a). Por el lado de la empresa privada, Timothy Scott Hall, director de asuntos gubernamentales de Intel, menciona que el propósito de Intel es crear tecnología con el propósito de mejorar la vida de todas las personas, un compromiso que se asumió hace veinticinco años cuando la empresa se estableció en Costa Rica. Este acuerdo, según Scott, va a permitir desarrollar un programa de tres años denominado “AI For Youth” (IA para jóvenes), el cual incluye el desarrollo de material didáctico y aprendizaje automático. Al respecto, Vanessa Gibson, directora de la organización CINDE, señala como un reto el poder aprovechar todo el potencial de esta tecnología para alcanzar una participación equitativa e inclusiva y con beneficios para una gran mayoría (Consejo Superior de Educación, 2016; DETCE, 2022).

Para marzo del 2024, Intel dio a conocer la iniciativa “Mil mujeres IA” durante el Día Internacional de la Mujer, cuyo objetivo es empoderar a mil mujeres ofreciéndoles cursos especializados, en línea, sobre IA. Estos cursos están dirigidos específicamente a mujeres mayores de dieciocho años de América Latina: Argentina, Colombia, Costa Rica, México y Uruguay; tienen una duración de doce semanas y están financiados por Intel y certificados por la Universidad Tecnológica Nacional de Argentina (MICITT, 2024). Las pymes no quedaron ausentes, y el MICITT, junto al Instituto Nacional de Aprendizaje, anunció el lanzamiento del programa “Crear e implementar inteligencia artificial en su negocio”. Este programa de dieciséis semanas busca desarrollar capacidades y competencias en la IA, aumentar la productividad y competitividad, e incrementar las oportunidades de internacionalización. Está dirigido a empresarias tomadoras de decisión de unidades productivas y emprendimientos con tres años o más de actividad comercial, de los sectores productivos pyme y del modelo asociativo empresarial de los pequeños y medianos productores agropecuarios (MICITT, 2023b).

4.4. Tabla comparativa de formación en IA

A continuación, la Tabla 1 resume las principales áreas de formación a considerar para incorporar la IA en la educación, según autores de Costa Rica y de otros países.

Tabla 1

Resumen de formación en IA (elementos esenciales para una formación en IA)

Áreas de IA a considerar	A nivel internacional	En el caso de Costa Rica
1. Inclusión de IA en el plan de estudios	Incorporar nuevos factores que enriquecen la alfabetización digital.	
	Estudiantes aprenden mejor la ciencia, matemáticas y conceptos complejos después de los dieciocho años.	Programa de estudio sobre IA enfocado en la ETP.
	Ciencias enseñadas por los científicos, por su capacidad de contagiar la pasión por el quehacer científico.	Programa "Crear e implementar inteligencia artificial en su negocio" para el sector empresarial.
	Introducir la programación y robótica dentro de los planes de estudio a nivel nacional.	Programa "AI For Youth".
	Adicionar la IA dentro de la oferta clásica de ciencias, matemáticas, conocimiento en redes, software y hardware.	Desarrollo de material didáctico y actualización del docente con temas de IA y aprendizaje automático.
	Asistencia automatizada con una perspectiva innovadora.	Programa "Mil mujeres IA" para empoderar a mil mujeres de América Latina a través de cursos sobre IA.
2. Habilidades técnicas	Programa europeo PISA para evaluar el rendimiento académico en matemáticas, ciencias y lectura.	Igualdad de oportunidades, acceso equitativo no discriminatorio y formación en la nueva especialidad técnica de la IA.
	Incorporar la programación en las clases y aplicarla en las distintas áreas del currículo.	
	La IA permite la formulación de nuevas alternativas dentro de los planes de estudio y con una adaptación acelerada y no parsimoniosa tradicional.	
3. Habilidades transversales	Introducir IA permite una nueva y atractiva perspectiva en relación con el dinamismo del aprendizaje.	Introducir IA en colegios técnicos permite fomentar el desarrollo de conocimientos, habilidades, destrezas, valores y capacidades actitudinales.
	Promover la creatividad, buscando soluciones innovadoras y aprendiendo de sus docentes y de demás compañeros.	IA brinda una oportunidad para mejorar la competitividad, promover la innovación y empleabilidad de los jóvenes y mujeres.
4. Enfoque práctico en la formación	Programa "Proge Tiger" introduce la programación y robótica en los planes de estudio de preescolar, primaria y profesional.	Diseño de programas de IA y aprendizaje automático posibilitan un nuevo desarrollo del material didáctico, lo cual incluye procesos de actualización.

(continúa)

(continuación)

Áreas de IA a considerar	A nivel internacional	En el caso de Costa Rica
5. Aspectos sociales, de seguridad y gobierno	Inversión e implementación de una estrategia de IA para la educación superior.	Promueve el desarrollo social y económico del país, con programas enfocados en potenciar nuevas capacidades y competencias en IA.
	La asistencia automatizada permite una nueva y atractiva perspectiva en relación con el dinamismo del aprendizaje.	Oportunidad para aumentar la productividad y competitividad del negocio, así como su internacionalización.
	Oportunidad para introducir nuevas y mejores aplicaciones apoyadas en IA.	

5. ENCUESTA A DOCENTES Y ESTUDIANTES SOBRE LA IA (CASO DE COSTA RICA)

5.1. Elaboración de la encuesta

En marzo del 2024 se llevó a cabo una encuesta bajo el título de “Perspectivas para la educación en IA: importancia de la inclusión de la IA en los planes de estudio”. La pregunta central de la encuesta fue: ¿qué habilidades y competencias relacionadas con la formación en IA considera usted importante incluir en el plan de estudios de una carrera de tecnología? Se seleccionaron una serie de preguntas sobre formación en IA, las cuales fueron analizadas y simplificadas en su redacción. También, se eliminaron las preguntas que podrían generar alguna redundancia, tendencia o sesgo, o que no necesariamente estuvieran alineadas con el tema central.

Con respecto al rango de respuestas, se decidió usar cuatro alternativas de escogencia única: Muy de acuerdo, De acuerdo, En desacuerdo y Totalmente en desacuerdo. El uso de rangos pares elimina la posibilidad de que el encuestado seleccione “la casilla del medio”, como ocurre cuando se usan opciones de respuestas impares (con tres y cinco opciones). Las respuestas del tipo par (de dos y cuatro opciones) obligan al encuestado a tomar una postura a favor o en contra, lo cual era importante determinar de forma clara. Al final, la encuesta se simplificó y sintetizó en siete preguntas de selección única, una de selección múltiple y dos de opinión, en la que los docentes y los estudiantes podían expresar su posición de manera libre.

En cuanto a la herramienta a utilizar, se revisaron varias opciones en internet y se escogió SurveyMonkey¹ como la más práctica y adecuada para el propósito de la investigación. Esta permite el diseño en línea, diferentes opciones de respuestas y almacena los resultados en su propia base de datos. Además, ofrece ayudas para el envío de invitaciones usando enlaces privados por diferentes medios (correo electrónico y WhatsApp),

1 <https://www.surveymonkey.com/>

y funciona con los sistemas operativos de equipos móviles (celulares y tabletas) y de cualquier estación de trabajo. La interfaz gráfica de la encuesta se ajusta, al abrirla, al tamaño de la pantalla y permite recorrer la encuesta de una manera simple y eficaz.

Al final, se diseñaron dos tipos de encuestas, una para los docentes y otra para los estudiantes. Se buscó redactar las preguntas de manera similar en ambas, lo cual facilitó el análisis comparativo de las respuestas entre ambas poblaciones ante una misma pregunta.

5.2. Aplicación de la encuesta

Se llevaron a cabo varias etapas de aplicación de la encuesta, primeramente, utilizando unas pocas personas en ambiente de pruebas piloto, para conocer y familiarizarse con la herramienta. Se hicieron ajustes al formato (visual y de contenido), así como a la redacción de las preguntas para que fueran lo más claras posibles, sin ambigüedades que luego pudieran generar dudas que implicasen retrasos en el proceso. La idea siempre fue que se comprendiera la pregunta, que el proceso demorara lo menos posible y que se pudieran obtener resultados claros, concisos y comparables entre ambas poblaciones. Se enviaron comunicados con enlaces que dirigían al sitio de internet donde estaba la encuesta para ambas poblaciones (docentes y estudiantes), un enlace para estudiantes y otro para los docentes. De esta forma, se generaron dos grupos de resultados diferentes, pero comparables.

5.3. Recopilación de resultados

Se recopilaron los datos utilizando el mismo instrumento (SurveyMonkey) según la opción de recuperar y almacenar los datos. Los resultados permitieron generar documentos de salida resumidos en formato PDF y gráficas, así como reportes detallados en hojas electrónicas. Se realizaron resúmenes de las respuestas y estas se agruparon por número, con una muestra estadística final de las respuestas de los encuestados.

6. ANÁLISIS DE LA ENCUESTA (DOCENTES Y ESTUDIANTES)

6.1. Análisis de respuestas y preguntas cerradas

A continuación, se presenta el resumen de las siete preguntas cerradas (de escogencia única) aplicadas a los dieciocho docentes y a los ciento doce estudiantes encuestados, con los siguientes resultados combinados (véase la Tabla 2).

Tabla 2

Resultados de la encuesta, preguntas cerradas Q1 a Q7 (docentes y estudiantes)

Pregunta cerrada				
Q1. ¿Cuál es su nivel de experiencia o familiaridad en temas relacionados con la IA?				
	Muy alto	Alto	Bajo	Muy bajo
Docentes	5,56 %	27,78 %	22,22 %	44,44 %
Estudiantes	7,14 %	41,96 %	50,00 %	0,89 %
Q2. ¿Durante su vida profesional/estudiantil, ha llevado capacitaciones, obtenido certificaciones técnicas relacionadas con el tema de IA?				
	Muchas veces	Algunas veces	Pocas veces	Ninguna vez
Docentes	5,56 %	16,67 %	38,89 %	38,89 %
Estudiantes	1,79 %	6,25 %	22,32 %	69,64 %
Q3. ¿Considera relevante la incorporación de temas sobre IA en la formación académica de los estudiantes de hoy?				
	Es muy relevante	Es algo relevante	Es poco relevante	Es nada relevante
Docentes	83,33 %	16,67 %	0,00 %	0,00 %
Estudiantes	79,46 %	19,64 %	0,89 %	0,00 %
Q4. ¿Tiene usted conocimiento si otras Universidades privadas han incorporado temas o contenidos de IA en sus planes de estudios?				
	Sí tengo conocimiento de varias	Solo conozco algunas	Solo una o muy pocas	No he escuchado de ninguna
Docentes	22,22 %	22,22 %	16,67 %	38,89 %
Estudiantes	14,68 %	16,51 %	8,26 %	60,55 %
Q5. ¿Durante su vida profesional ha participado con expertos, empresas o instituciones para tener una perspectiva más práctica sobre la IA?				
	Muchas veces	Algunas veces	Pocas veces	Nunca he participado
Docentes únicamente	11,11 %	16,67 %	27,78 %	44,44 %
Q6. ¿Qué oportunidades laborales considera usted que puede tener un graduado con competencias y habilidades en IA?				
	Muchas	Algunas	Muy pocas	Ninguna
Docentes	94,12 %	5,88 %	0,00 %	0,00 %
Estudiantes	71,43 %	25,00 %	3,57 %	0,00 %

(continúa)

(continuación)

Pregunta cerrada				
Q7. ¿Considera usted que el tema sobre ética en IA, incluyendo su uso justo y responsable, es importante incluirlo en la formación?	Totalmente de acuerdo		No muy de acuerdo	
	De acuerdo	De acuerdo	De acuerdo	Desacuerdo
Docentes	77,78 %	22,22 %	0,00 %	0,00 %
Estudiantes	76,85 %	21,30 %	1,85 %	0,00 %

Sobre la experiencia con IA, las respuestas de los docentes estuvieron en los niveles “Alto”, “Bajo” y “Muy bajo” (27,78 %, 22,22 %, 44,44 %, respectivamente), mientras que los estudiantes indicaron un nivel de familiaridad “Alto” y “Bajo” (41,96 % y 50,0 %, respectivamente). Con respecto a haber recibido cursos, capacitaciones o certificaciones técnicas, los docentes indicaron que esto sucedió “Pocas veces” y “Ninguna vez” (38,89 % y 38,89 %, respectivamente), mientras que los estudiantes respondieron en los mismos dos rangos con 22,32 % y 69,64 %, respectivamente. Sobre la relevancia de incorporar temas sobre IA en el contenido académico, la mayoría respondió que esto era “Muy relevante” (docentes, 83,33 %; estudiantes, 79,46 %).

En la pregunta Q5, exclusiva para los docentes, que inquiría sobre haber participado en iniciativas de expertos, empresas o instituciones externas para proveer una perspectiva práctica sobre la IA, estos indicaron que “Nunca habían participado” o que lo habían hecho “Pocas veces” (44,44 % y 27,78 %, respectivamente). Con respecto al tema de las oportunidades laborales de un graduado con habilidades en IA, ambos grupos respondieron en su mayoría que estas eran “Muchas” (94,12 % y 71,43 %, respectivamente). Y, sobre la pregunta acerca de incluir la ética en IA en la formación académica, con un énfasis en su uso justo y responsable, ambos grupos dieron una aprobación de “Totalmente de acuerdo” (77,78 % y 76,85 %, respectivamente).

6.2. Análisis de respuestas para preguntas de selección múltiple

En la Tabla 3 se muestran las respuestas a la pregunta Q8 sobre opciones que los participantes consideran que pueden complementar la formación en temas de IA. Ambos grupos encuestados pudieron seleccionar varias opciones a la vez.

Tabla 3

Resultados de la encuesta, preguntas Q8 de selección múltiple (docentes y estudiantes)

Q8. Indicar las opciones que considera usted que pueden complementar la formación en temas de IA (puede seleccionar varias respuestas)	Porcentaje de los docentes	Cantidad de respuestas de los docentes	Porcentaje de los estudiantes	Cantidad de respuestas de los estudiantes
Talleres prácticos	88,24 %	15	83,49 %	91
Seminarios	41,18 %	7	43,12 %	47
Cursos de extensión	41,18 %	7	43,12 %	47
Certificaciones técnicas específicas	70,59 %	12	81,65 %	89
Cursos en internet autodirigidos	47,06 %	8	44,95 %	49
Ninguna de las anteriores	5,88 %	1	0,00 %	0

La mayoría de las opciones de ambos grupos se inclinaron hacia “Talleres prácticos” (88,24 % y 83,49 %) y, en segundo lugar, hacia “Certificaciones técnicas específicas” (70,59 % y 81,65 %) para complementar la formación en temas de IA. Luego, en tercer lugar, figuran los cursos en internet autodirigidos (47,06 % y 44,95 %).

6.3. Análisis de respuestas y preguntas abiertas

Con respecto a las preguntas abiertas, en las que los participantes podían expresar su opinión, se presentan las respuestas resumidas en la Tabla 4 (para las de los docentes) y en la Tabla 5 (para las de los estudiantes).

Tabla 4

Resultados de pregunta Q9 (¿Qué habilidades y competencias relacionadas con la formación en IA considera usted importantes incluir en el plan de estudios de una carrera de tecnología?)

Habilidades técnicas	Habilidades transversales	Recursos y métodos de enseñanza	Docentes	Alumnos
Comprender conceptos básicos de IA y procesos de automatización de tareas	Pensamiento crítico y analítico	Talleres prácticos sobre IA	X	
Análítica, visión estratégica, síntesis, y pensamiento crítico	Creatividad y capacidad de comunicación	Integración con plataformas líderes en el mercado	X	
Desarrollo de aplicaciones y algoritmos de IA desde cero, y robótica IA para gestión de sistemas empresariales ERP (enterprise resource planning)	Trabajo en equipo	Análisis de datos	X	

(continúa)

(continuación)

Habilidades técnicas	Habilidades transversales	Recursos y métodos de enseñanza	Docentes	Alumnos
Conocimiento en probabilidad y estadística	Diseño, síntesis y seguridad apoyados en IA	Comunicación asertiva	X	X
Tendencias y uso adecuado de la IA y aspectos éticos y sociales de la IA	Gobernanza, seguridad y arquitectura de sistemas IA	Manipulación de datos	X	X
Lenguajes de programación como Python, R, Java, C++			X	X
Uso de herramientas y plataformas líderes en el mercado			X	
Desarrollo de IA y machine learning, algoritmos supervisados, no supervisados y por refuerzo, y técnicas de preprocesamiento de datos	Conocimiento sobre implicaciones éticas y morales en el uso de IA	Laboratorios prácticos para el uso de IA		X
Comprensión de los algoritmos utilizados en herramientas de IA	Habilidades de comunicación, creatividad y pensamiento crítico relacionadas con la IA	Enfoque en el desarrollo práctico y ético de herramientas de IA		X
Conocimiento en probabilidad y estadística	Responsabilidad y ética en el uso de la IA	Incorporación de IA en proyectos y trabajos diarios		X
Incorporar temas de aspectos éticos y sociales de IA	Ser autodidacta y tener habilidades en informática	Enseñanza sobre cómo crear prompts y programación de IA		X

Ambos grupos encuestados presentan sus respuestas a partir de un entendimiento técnico en el cual se considera importante comprender cómo utilizar y realizar consultas efectivas con las herramientas de IA, una vez se entienda su funcionamiento básico.

Con respecto al desarrollo y la aplicación de la IA, se aprecia un interés en aprender por desarrollar IA, por utilizarla éticamente, por aplicarla en diferentes áreas (como la resolución de problemas, el procesamiento de lenguaje natural, etcétera) y por aprovechar sus beneficios en el día a día y en el trabajo. También se aprecia, en los resultados, un enfoque hacia la experimentación práctica y la práctica autodidacta, la resolución de problemas, el uso de lenguajes de programación (como Python) y el desarrollo de habilidades en el manejo de sistemas y plataformas de IA.

A continuación, la Tabla 6 presenta las respuestas a la pregunta abierta Q10. La tabla muestra el resumen de ambos grupos.

Tabla 5

Resultados de pregunta Q10 (¿Qué temáticas sobre IA considera usted que pueden incorporarse al plan de estudio de una carrera de tecnología?)

Desarrollo de sistemas IA	Fundamentos y técnicas de IA	Aplicaciones y consideraciones éticas	Docentes	Alumnos
Desarrollo de aplicaciones móviles con IA	Machine learning	IA en medicina y biología	X	
Desarrollo de proyectos con IA	Machine learning y big data			X
Desarrollo de IA y machine learning	Estructura de una IA	Uso responsable y ético de la IA en diferentes áreas profesionales		X
Sistemas expertos	Deep learning	Gobernanza de tecnologías de la información (TI)	X	
Robótica con IA	Procesamiento del lenguaje natural	Consideraciones éticas en IA	X	
Usos de la IA, impacto de esta	Acerca del análisis de datos	Ética en IA, su uso adecuado y responsable		X
IA en el desarrollo de juegos	Redes neuronales	Propiedad de datos en IA	X	
Internet de las cosas	Aprendizaje federado		X	
Laboratorios y aplicaciones prácticas de IA	Analítica de datos, probabilidad y estadística, y ciencia de datos		X	
	Lenguajes de programación (Python, R, Java)		X	
Análisis de datos para complementar las IA	Aprender a aprovechar por completo la IA	Ética sobre el uso de las IA (no depender al 100 % de ellas, sino como apoyo)		X
Automatización de resolución de problemas	Aprendizaje de programación y deep learning	Ética, conceptos y teoría, proyectos prácticos		X
Beneficios en la programación.	Fundamentos de la IA y creación de proyectos con IA	Impacto humanitario de la IA, futuras legislaciones y ética laboral		X

(continúa)

(continuación)

Desarrollo de sistemas IA	Fundamentos y técnicas de IA	Aplicaciones y consideraciones éticas	Docentes	Alumnos
Reconocer la diferencia entre algo humano y algo hecho por IA	Reconocimiento de patrones para incorporar IA en programas de software			X
Uso de la IA en desarrollo de juegos y entretenimiento				X

En resumen, los docentes consideran importante utilizar la IA en la práctica en diferentes áreas académicas, mediante el ofrecimiento de espacios para mejorar los fundamentos técnicos de la computación e informática en sus áreas de desarrollo de *software*, técnicas de *machine learning*, redes neuronales y aprendizaje federado. También, algunos docentes consideran relevante incorporar la IA en otras profesiones, como medicina y biología, además de enfocarla en la gobernanza y la ética. Los estudiantes consideran crucial entender el funcionamiento técnico y ético de la IA, así como desarrollar habilidades prácticas enfocadas en su uso responsable y ético, y aprovechar todos los beneficios en diversas aplicaciones.

7. DISCUSIÓN DE RESULTADOS

El uso de la IA en la educación superior se presenta como un recurso que puede facilitar nuestra labor docente en lugar de ser un obstáculo. Es esencial estar preparados para las oportunidades que surjan de la integración y la transversalidad de la IA en este ámbito, para lo cual se requiere promover el desarrollo de habilidades de pensamiento crítico. Las diversas aplicaciones y tendencias tecnológicas auguran un futuro prometedor para el desarrollo de la IA en la educación superior. Sin embargo, es poco probable que los sistemas de aprendizaje basados en computadoras lleguen a reemplazar por completo el proceso de enseñanza humana en las instituciones educativas (Cotrina-Aliaga et al., 2021).

Sobre la base de los resultados obtenidos en la encuesta aplicada a docentes y estudiantes, se presenta a continuación, en la Tabla 6, el resumen de los elementos clave para una formación académica que incorpore la formación y las habilidades sobre la IA.

Tabla 6

Elementos esenciales sobre formación y competencias en IA

Áreas de IA a considerar	Elementos esenciales para formación en IA	Habilidades y competencias
1. Inclusión de IA en el plan de estudios	Preparar a los estudiantes para los desafíos mediante el desarrollo de aplicaciones y algoritmos apoyados en la IA, junto con aspectos relacionados con la ética.	Formación teórica y práctica en IA. Aprender sobre lenguajes de programación (orden, estructura y método).
2. Habilidades técnicas	Habilidades técnicas como programación, machine learning, big data, cloud computing, lenguajes de programación (Python, R, Java, C++), conocimientos de probabilidad y estadística, lógica y algoritmos, y matemáticas.	Pensamiento computacional, análisis, abstracción, instrucciones y algoritmos. Habilidad técnica para diseñar y construir robots.
3. Habilidades transversales	Además de las habilidades técnicas, se enfatiza la importancia de habilidades transversales relacionadas con el desarrollo del pensamiento crítico y analítico, la creatividad, la capacidad efectiva de comunicación, la resolución de problemas y desarrollo de equipos de trabajo.	Habilidades blandas a través del desarrollo de equipos de trabajo. Crear e innovar. Promover la creatividad con soluciones innovadoras y a aprender de los docentes y compañeros.
4. Enfoque práctico en la formación	Implementar talleres prácticos de IA, usando herramientas y plataformas del mercado como Azure, AWS, Google, y otras. Incorporar la IA con un enfoque en la síntesis, programación y análisis de datos.	Habilidades prácticas para buscar, obtener y gestionar la información.
5. Aspectos sociales, de seguridad y de gobierno	Incorporar la seguridad física y en especial la ciberseguridad en sistemas y redes de comunicación apoyadas con la IA. Seguridad en procesos de gobernanza y en la arquitectura de aplicaciones tecnológicas al integrar elementos de IA.	Habilidades sociales (aplicables a la academia y a las empresas). Promover una cultura tecnológica.

8. RECOMENDACIONES

En este estudio se hizo referencia a encuestas e investigaciones de varios países sobre el uso y las aplicaciones de la IA en la educación, y se incluyó el caso de Costa Rica con su estrategia de IA. Investigadores de diversos países y organizaciones, como la Unesco, sugieren promover la incorporación y desarrollo de la IA, enfocándose en tres áreas principales relacionadas con los procesos de enseñanza y aprendizaje: la formación docente, la investigación y el desarrollo, y el acompañamiento a los estudiantes.

Otro aspecto relevante basado en la encuesta son los resultados de la Tabla 2, los cuales muestran la experiencia con IA: los docentes reportaron un 22,22 % en el nivel

“Bajo” y, un 44, 44 % en el nivel “Muy bajo”. En función de estas respuestas, se vuelve imperativo implementar de inmediato cursos cortos, talleres, charlas y otras actividades para introducir el tema de la IA, especialmente dirigidos a la formación docente, con el objetivo de que los educadores lo aprendan, apliquen y desarrollen en sus clases. Adicionalmente, acorde con las respuestas “abiertas”, de opinión, se recomienda:

- a) Recursos y métodos de enseñanza: incorporar un enfoque de desarrollo práctico y ético de herramientas de IA e incorporar IA en proyectos y trabajos diarios.
- b) Aplicaciones y consideraciones: usar de forma responsable la IA en diferentes áreas profesionales, en la gobernanza de TI, usar de manera ética los sistemas de IA (no depender al 100 % de ellos, sino solo como apoyo), considerar el impacto humanitario de la IA y el que tendrá en la legislación futura y en la ética laboral.
- c) Competencias en IA: aprender sobre lenguajes de programación; diseñar y construir robots; buscar, recopilar y gestionar la información; promover una actitud científica y una cultura tecnológica; crear e innovar.
- d) Habilidades y competencias: formar de manera teórica y práctica en IA; aprender sobre lenguajes de programación (orden, estructura y método); fomentar un pensamiento computacional (análisis, abstracción, instrucciones y algoritmos); desarrollar habilidades técnicas para diseñar y construir robots; agregar habilidades transversales (gestión de proyectos con equipos de trabajo); crear espacios para buscar soluciones innovadoras.

Finalmente, es una recomendación de los autores que se utilicen todas las tablas como referencia para coadyuvar a la elaboración de programas de estudio que incorporen temas relacionados con la IA. También se recomienda promover la formación docente mediante la investigación y desarrollo, la innovación en las aulas y la identificación de competencias técnicas y habilidades transversales. Por último, se recomienda acompañar a los estudiantes para mejorar su competitividad y su empleabilidad, siempre manteniendo una visión ética y responsable en la adopción y uso de la IA, tanto al interior de las instituciones como, de manera general, en el país.

REFERENCIAS

- Andreoli, S., Batista, A., Fuksman, B., Gladkoff, L., Martínez, K., & Perillo, L. (2022). *Inteligencia artificial y educación. Un marco para el análisis y la creación de experiencias en el nivel superior*. <http://dx.doi.org/10.13140/RG.2.2.12073.20326>
- Artopoulos, A. (2023). Imaginarios de IA generativa en educación. *Hipertextos*, 11(19), e070. <https://doi.org/10.24215/23143924e070>
- Consejo Superior de Educación. (2016). Política educativa. La persona: centro del proceso educativo y sujeto transformador de la sociedad. Ministerio de Educación

- Pública de Costa Rica. <https://www.mep.go.cr/sites/default/files/2022-06/politicaeducativa.pdf>
- Cotrina-Aliaga, J. C., Vera-Flores, M. A., Ortiz-Cotrina, W. C., & Sosa-Celi, P. (2021). Uso de la inteligencia artificial (IA) como estrategia en la educación superior. *Formación Docente. Revista Iberoamericana de Educación*, Volumen especial 1. <https://doi.org/10.31876/ie.vi.81>
- Cubillos, M. (2012). *Manual sílabo. Difementes*. https://www.difementes.com/revista/2012b/Silabo_Educativo_Colombia.pdf
- Dirección de Educación Técnica y Capacidades Emprendedoras. (2022). Programa de estudio Inteligencia Artificial. <https://www.mep.go.cr/sites/default/files/programadeestudio/programas/inteligencia-artificial-10.pdf>
- Dirección de Prensa y Relaciones Públicas. (2022, 24 de noviembre). Convenio entre MEP e Intel Costa Rica habilitará la especialidad de Inteligencia Artificial en Colegios Técnico Profesionales el otro año. Ministerio de Educación Pública de Costa Rica. <https://www.mep.go.cr/noticias/convenio-mep-e-intel-costa-rica-habilitara-especialidad-inteligencia-artificial-colegios-te>
- Elloumi, Y. (s.f.). *Chatbot&IA*. https://www.academia.edu/38204473/Chatbot_and_IA?sm=b
- Fetzer, J. H. (1990). *Artificial intelligence: Its scope and limits*. Springer.
- Frezza, S., Pears, A., Daniels, M., Kann, V., Kapoor, A., McDermott, R., Peters, A.-K., Wallace, C., Sabin, M., & Cajander, Å. (2018). Modeling global competencies for computing education. En I. Polycarpou, J. C. Read, P. Andreou & M. Armoni (Eds.), *ITICSE 2018: Proceedings of the 23rd annual ACM Conference on Innovation and Technology in Computer Science Education* (pp. 348-349). Association for Computing Machinery. <https://doi.org/10.1145/3197091.3205844>
- Impagliazzo, J. (2019). Computing competency: A contemporary transformational agent. En B. Goda & S. Zilora (Eds.), *SIGITE '19: Proceedings of the 20th Annual SIG Conference on Information Technology Education* (p. 4). Association for Computing Machinery. <https://doi.org/10.1145/3349266.3355615>
- Jones, M. (1985). Applications of artificial intelligence within education. *Computer & Math with Applications*, 11(5), 517-526. [https://doi.org/10.1016/0898-1221\(85\)90054-9](https://doi.org/10.1016/0898-1221(85)90054-9)
- Kumar, P. (2019, 3 de abril). What is artificial intelligence? And machine learning with all examples. *Tech Mashala*. https://www.academia.edu/38723107/What_is_Artificial_Intelligence?sm=b
- Manjarrés, A., & Pickin, S. (2021). Aprendizaje-servicio y agenda 2030 en la formación de ingenieros de la tecnología inteligente. *Revista Diecisiete*, (4), 59-82. https://doi.org/10.36852/2695-4427_2021_04.03

- Medina Lloret, C., Hernández González, A., & Díaz Raboso, D. (2022). Sistemas y recursos educativos basados en IA que apoyan y evalúan la educación. *IA Eñ™*. <https://doi.org/10.21428/39829d0b.4bd0b28b>
- Ministerio de Ciencia, Innovación, Tecnología y Telecomunicaciones (2023a, 20 de febrero). MICITT e Intel unen esfuerzos para capacitar a estudiantes fuera de GAM sobre inteligencia artificial. <https://www.micitt.go.cr/el-sector-informa/micitt-e-intel-unen-esfuerzos-para-capacitar-estudiantes-fuera-de-gam-sobre>
- Ministerio de Ciencia, Innovación, Tecnología y Telecomunicaciones (2023b, 9 de agosto). PYMEs y PYMPAs aplicarán herramientas de Inteligencia Artificial para mejorar competitividad de sus negocios gracias a Plan Piloto. <https://www.micitt.go.cr/el-sector-informa/pymes-y-pympas-aplicaran-herramientas-de-inteligencia-artificial-para-mejorar>
- Ministerio de Ciencia, Innovación, Tecnología y Telecomunicaciones (2024, 8 de marzo). Intel entrenará a 1000 mujeres en inteligencia artificial en América Latina. <https://www.micitt.go.cr/el-sector-informa/intel-entrenara-1000-mujeres-en-inteligencia-artificial-en-america-latina>
- Ocaña-Fernández, Y., Valenzuela-Fernández, L. A., & Garro-Aburto, L. L. (2019). Inteligencia artificial y sus implicaciones en la educación superior. *Propósitos y Representaciones. Revista de Psicología Educativa de la Universidad San Ignacio de Loyola*, 7(2), 536-568. <https://doi.org/10.20511/pyr2019.v7n2.274>
- Palacios Rozo, J. J., Palacio Velásquez, H. E., & González Silva, R. (2018). Educación versus tecnología y su convergencia hacia la IA. *Revista Vínculos*, 15(2), 186-194. <https://doi.org/10.14483/2322939x.14114>
- Pascuas-Rengifo, Y. S., García-Quintero, J. A., & Mercado-Varela, M. A. (2020). Dispositivos móviles en la educación: tendencias e impacto para la innovación. *Revista Politécnica*, 16(31), 97-109. <https://doi.org/10.33571/rpolitec.v16n31a8>
- Pounder, K., & Liu, G. (2018). Nuevas ocupaciones: Latinoamérica y el espejo de Australia. *Integración & comercio*, (44), 272-289. <https://dialnet.unirioja.es/servlet/articulo?codigo=6551949>
- Raj, R., Sabin, M., Impagliazzo, J., Bowers, D., Daniels, M., Hermans, F., Kiesler, N., Kumar, A. N., MacKellar, B., McCauley, R., Nabi, S. W., & Oudshoorn, M. (2021). Professional competencies in computing education: Pedagogies and assessment. En B. R. Krogstie & K. Quille (Eds.), *ITICSE-WGR '21: Proceedings of the 2021 Working Group reports on Innovation and Technology in Computer Science Education* (pp. 133-161). Association for Computing Machinery. <https://doi.org/10.1145/3502870.3506570>
- Schleicher, A. (2018). *PISA 2018. Insights and Interpretations*. OECD. <https://www.oecd.org/content/dam/oecd/en/about/programmes/edu/pisa/publications/>

national-reports/pisa-2018/PISA%202018%20Insights%20and%20Interpretations%20FINAL%20PDF.pdf

Schmidt, T. (2017). *Artificial intelligence* [Diapositiva de Power Point, Conferencia 1 del curso "Informationen zu den Übungen und der Vorlesung Maschinelles Lernen und künstliche Intelligenz aus stochastischer Sicht (SS2017)"]. Universität Freiburg. https://www.stochastik.uni-freiburg.de/de/lehre/ss-2017/vorlesung-maschinelles-lernen-und-kuenstliche-intelligenz-ss-2017/10_BO

Skeat, J., & Ziebell, N. (2023, 22 de junio). *University students are using AI, but not how you think*. Pursuit. <https://pursuit.unimelb.edu.au/articles/university-students-are-using-ai-but-not-how-you-think>

The Royal Society. (2014). *Vision for science and mathematics education*. <https://royalsociety.org/~media/education/policy/vision/reports/vision-full-report-20140625.pdf>

Ubal Camacho, M., Tambasco, P., Martínez, S., & García Correa, M. (2023). El impacto de la inteligencia artificial en la educación. Riesgos y potencialidades de la IA en el aula. *Revista Interuniversitaria de Investigación en Tecnología Educativa*, (15), 41–57. <https://doi.org/10.6018/riite.584501>

DISEÑO E IMPLEMENTACIÓN DE UN CONVERTIDOR DC/DC BOOST CON CONTROL PID PARA APLICACIÓN DE FRENADO REGENERATIVO

JORGE CRISTHOFER ALCÁNTARA VÁSQUEZ
t1023600120@unitru.edu.pe

<https://orcid.org/0009-0007-3138-8836>

Ingeniería Mecatrónica, Universidad Nacional de Trujillo, Perú

RENÉ RONALDO GUTIÉRREZ CÓRDOVA
t1013600221@unitru.edu.pe

<https://orcid.org/0009-0009-2715-1689>

Ingeniería Mecatrónica, Universidad Nacional de Trujillo, Perú

ANGIE TATIANA RECUENCO TAPIA
t1013600421@unitru.edu.pe

<https://orcid.org/0009-0006-8657-5375>

Ingeniería Mecatrónica, Universidad Nacional de Trujillo, Perú

LUIS ALBERTO YOVERA SUÁREZ
t1033600521@unitru.edu.pe

<https://orcid.org/0009-0001-7622-7266>

Ingeniería Mecatrónica, Universidad Nacional de Trujillo, Perú

EDGAR ANDRÉ MANZANO RAMOS
emanzano@unitru.edu.pe

<https://orcid.org/0009-0009-2715-1689>

Ingeniería Mecatrónica, Universidad Nacional de Trujillo, Perú

Recibido: 15 de setiembre de 2024 / Aceptado: 15 de octubre de 2024

doi: <https://doi.org/10.26439/interfases2024.n020.7398>

RESUMEN. Este artículo presenta el diseño e implementación de un convertidor elevador DC/DC de 12 V a 40,99 V, que emplea control PID, con el objetivo de ofrecer una solución eficiente para el aprovechamiento de la energía recuperada en un sistema de frenado regenerativo. En una primera etapa, se diseñó el circuito no controlado utilizando los *softwares* Simulink y PSIM. Posteriormente, se implementó un prototipo del circuito controlado mediante control PID para corregir la señal de salida. Una vez validado el funcionamiento del prototipo en el simulador Proteus, se procedió a la implementación física. Esta fase incluyó el diseño de las pistas en el *software* Eagle, el modelado de la

placa en Autodesk Fusion y la fabricación manual de la misma. El uso del controlador PID permitió obtener un voltaje promedio de salida de 40,99 V, un valor RMS similar y un voltaje rizo pico a pico de 2,40 V. Aunque no se alcanzó el máximo estimado en las simulaciones, los resultados confirman el correcto funcionamiento del convertidor. Además, se identificaron posibles mejoras para optimizar el rendimiento del circuito, como ajustes en la capacitancia o inductancia, con el fin de reducir los picos de corriente y voltaje.

PALABRAS CLAVE: convertidor elevador DC/DC / control PID / freno regenerativo / prototipado

DESIGN AND IMPLEMENTATION OF A DC/DC BOOST CONVERTER WITH PID CONTROL FOR REGENERATIVE BRAKING APPLICATION

ABSTRACT. This article presents the design and implementation of a 12 V to 40,99 V DC/DC boost converter using PID control, with the aim of providing an efficient solution for harnessing recovered energy in a regenerative braking system. In the first stage, the uncontrolled circuit was designed using Simulink and PSIM software. Subsequently, a prototype of the controlled circuit was implemented using PID control to correct the output signal. Once the prototype's functionality was validated in the Proteus simulator, the physical implementation was carried out. This phase included the design of the tracks in Eagle software, the modeling of the board in Autodesk Fusion, and the manual fabrication of the circuit. The use of PID control allowed for an average output voltage of 40,99 V, a similar RMS value, and a peak-to-peak ripple voltage of 2,40 V. Although the maximum estimated in the simulations was not reached, the results confirm the proper operation of the converter. Additionally, potential improvements were identified to optimize the circuit's performance, such as adjustments in capacitance or inductance, in order to reduce current and voltage spikes.

KEYWORDS: DC/DC boost converter / PID control / regenerative braking / prototyping

1. INTRODUCCIÓN

En una actualidad en la que la ingeniería se encuentra en la constante búsqueda de métodos de ahorro de energía y de mejora de la eficiencia de los sistemas energéticos, los sistemas de frenado dinámico o regenerativo han demostrado ser esenciales para el logro de estos objetivos gracias a su principio de funcionamiento, el cual consiste en la conversión de la energía cinética producida durante el frenado —y que usualmente se pierde como calor— en energía eléctrica que puede ser utilizada en la mejora de la eficiencia de la energía almacenada. Este principio se basa en la capacidad que poseen los motores eléctricos para, bajo ciertas condiciones, operar como generadores, aunque cabe resaltar que esta energía recuperada es de menor valor que la entregada inicialmente a la máquina motriz; y es debido a esto que se deben buscar métodos de elevación de voltaje para poder realizar un adecuado almacenamiento de esta electricidad o distribuirla a otros sistemas (Sanchez-Camperos et al., 2022).

Los *boost converters* (convertidores elevadores) son fundamentales en el proceso de elevación de voltaje dentro de sistemas eléctricos gracias al proceso de conmutación entre la fase de encendido y apagado del interruptor y al uso de elementos estáticos de potencia en su composición. Esta propiedad permite que los convertidores elevadores puedan ser utilizados en aplicaciones de baja y alta potencia como las energías renovables, en las que se busca elevar la energía de bajo voltaje otorgada por paneles solares para almacenarla en baterías (Abril et al., 2014; Flores Ordeñana, 2018; Meza et al., 2017), y en dispositivos alimentados por baterías, como son los vehículos híbridos y eléctricos, ya que permiten el aumento de la tensión de la batería y un suministro de energía a los componentes de alta potencia (Palacio Garcés, 2014).

Sin embargo, para realizar el diseño de un convertidor elevador eficiente, se requiere una regulación precisa del voltaje de salida, lo cual se logra mediante el uso de controladores proporcional-integral-derivativos, también denominados *controladores PID*. Esta clase de controladores permiten realizar ajustes a la respuesta del convertidor respecto a las variaciones en las condiciones de entrada y carga, garantizando así la estabilidad y eficiencia del convertidor. Ante este contexto, el control PID se emplea para optimizar la operación de estos elevadores y garantizar una respuesta rápida y estable ante variaciones en las condiciones de carga y entrada.

El presente trabajo se centra en el diseño e implementación de un convertidor elevador de 12 V a 72 V, mediante el empleo de un controlador PID para regular su funcionamiento. El desarrollo de este convertidor tiene como objetivo servir de complemento a la tesis de Narciso Vera (2022), ya que proporciona una solución eficiente para la gestión y aprovechamiento de la energía recuperada, lo cual contribuye a optimizar la autonomía y el desempeño del vehículo.

2. ESTADO DEL ARTE

Se empezó la investigación delimitando las metodologías actuales utilizadas por nuestros predecesores para el control del circuito elevador. Inicialmente, se encontraron estudios de tres autores que permitían optimizar el comportamiento del sistema frente a perturbaciones externas y variaciones de parámetros, en los que se proponen como metodologías de control el uso de redes neuronales recurrentes de alto orden (RHONN) junto con el control por modos deslizantes (Ruz-Canul et al., 2022) y el control MPPT para convertidores elevadores en sistemas fotovoltaicos (Meza et al., 2017). Mientras que Ruz-Canul et al. (2022) se enfocaron en el seguimiento de las trayectorias de voltaje y corrientes AES para el cambio entre convertidores de tipo *boost* y convertidores de tipo *buck*, Meza et al. (2017) se enfocó en el seguimiento del punto de máxima potencia mediante un microcontrolador para modificar la relación del ciclo de trabajo ante las variaciones de la corriente de entrada.

Cuatro autores coinciden con el uso de controladores en cascada, lo cual permite atenuar la señal y obtener un error en estado estable mínimo al evitar las sobreoscilaciones iniciales del voltaje a la salida. Tres de estos autores implementaron el convertidor en base a controlador PI (Abril et al., 2014; Cardona Herrera & Ospina Hurtado, 2015; Rodríguez et al., 2024), mientras que el último autor realizó el diseño y simulación de cuatro propuestas de controladores: PI, PI^λ, controlador con compensadores de atraso-adelanto de orden entero y de orden fraccional (Flores Ordeñana, 2018). El convertidor diseñado por Abril et al. (2014) presentó un rendimiento de 90,02 % que permitía el manejo de cargas variables y la regulación del voltaje de salida a uno cercano al nominal. Al implementar su elevador, Cardona Herrera y Ospina Hurtado (2015) lograron obtener, para un voltaje de entrada de 12 V, un rango de error en estado estable entre 0,15 V y 0,21 V para voltajes de salida de 18 V y 24 V. Finalmente, Rodríguez et al. (2024) implementó un circuito que para un voltaje de entrada de 12 V generaba, con rapidez y robustez, un voltaje de salida que se mantuvo en 24 V a pesar de las variaciones de tensión que se presentaron a la entrada.

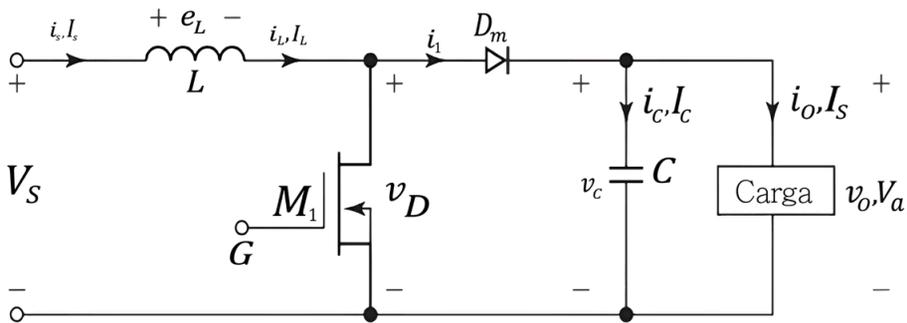
Sobre la base de los antecedentes encontrados, es posible determinar que para el desarrollo del diseño e implementación de convertidores elevadores DC-DC es importante utilizar controladores que sean capaces de atenuar las variaciones de la carga de entrada para obtener una carga estable y cercana a la deseada a la salida. Para ello, los métodos de control más idóneos, debido a su efectividad y correlación entre los resultados de simulación e implementación, son los controladores en cascada, siendo los más usados los de control PI. En virtud de la información obtenida en la presente investigación de antecedentes, se utilizarán aspectos relacionados con los controladores PI. Sin embargo, dado que la regulación precisa del voltaje de salida y la optimización de la operación de elevación son características que se desean lograr en los convertidores elevadores DC/DC, esta investigación realiza la simulación y la implementación mediante el uso de un controlador PID.

3. CONVERTIDOR ELEVADOR DC/DC

Los convertidores elevadores, como se muestra en la Figura 1, son una clase de convertidor DC/DC de potencia que poseen, como característica principal, la propiedad de convertir un voltaje de entrada, en corriente continua, a uno de salida de igual o mayor valor. Aunque existen diversos modelos de elevadores, estos generalmente están compuestos por elementos estáticos de potencia (interruptores, diodos, inductores, condensadores y cargas) debido a que posibilitan el uso de altas frecuencias para lograr bajas pérdidas durante su funcionamiento.

Figura 1

Diagrama de convertidor elevador DC/DC



Nota. De: *Distributed hierarchical droop control of boost converters in DC microgrids*, por O'Keeffe et al, 2017, p. 2.

El funcionamiento de los convertidores elevadores está compuesto por dos fases o estados, los cuales se ejecutan de manera cíclica el uno después del otro. La primera fase, también conocida como *encendido del interruptor*, comprende la activación de este para permitir el paso de la corriente de entrada a través del inductor y el transistor, debido a que el diodo se polariza en inversa y, por lo tanto, no permite el paso de la corriente por los otros componentes del circuito (Rashid, 2015). La siguiente fase se da cuando el interruptor se apaga o desactiva y la corriente, que fluía por el transistor, se dirige hacia el diodo (Rashid, 2015). La energía almacenada en la inductancia, durante la fase anterior, se transferirá a la carga y se sumará con la energía suministrada (Rodríguez et al., 2024). Es durante esta fase que la corriente del inductor cae hasta que el transistor vuelva a ser activado para repetir el ciclo. Adicionalmente a estos dos estados, existen dos modos de operación para los conversores elevadores. Estos se clasifican según el comportamiento de la corriente y se los conoce como *conducción continua* y *conducción discontinua* (Roche Vacacela & Terán Torres, 2011).

3.1. Conducción continua

Este modo se da cuando la corriente del inductor fluye a través de este componente de manera casi constante a un valor promedio, es decir, el inductor nunca se descarga, y la integral del voltaje en el inductor se vuelve cero. El rizado de la corriente es menor y el comportamiento del circuito tiende a ser lineal, lo que permite un control simple de este y un aumento en la eficiencia.

Teniendo en cuenta el circuito visto en la Figura 1 como un convertidor elevador de corriente continua en la inductancia, es posible determinar la relación entre el voltaje de salida promedio y la tensión de entrada en función del ciclo de trabajo k que posee el interruptor o, en este caso, MOSFET de potencia. La relación es la siguiente (Meza et al., 2017; Rashid, 2015):

$$V_a = \frac{V_s}{1-k} \quad (1)$$

En la ecuación (1), V_s se considera como el voltaje de salida del circuito, V_a , como el voltaje de entrada y k , como el ciclo de trabajo.

3.2. Conducción discontinua

Cuando la potencia de salida empieza a disminuir, la corriente del inductor es menor y se descarga completamente antes de que termine el ciclo de conmutación. Debido a esto, el voltaje del inductor toma el valor de cero para ese mismo tiempo. Esto genera que los rizados que existen en la corriente sean más pronunciados y vuelvan más complejo el control del circuito, debido a que el comportamiento deja de ser lineal (Abril et al., 2014).

4. CORRIENTE DE RIZO PICO A PICO DEL INDUCTOR

Durante el funcionamiento del elevador, en conducción continua, se generan fluctuaciones de la corriente que pasa por el inductor debido al constante encendido y apagado del interruptor, así como a la diferencia entre los valores máximos y mínimos de esta. A esta fluctuación de corriente en el inductor se le denomina *corriente de rizo pico a pico*. Es posible determinar este valor a través de la siguiente ecuación:

$$\Delta I = \frac{V_s k}{fL} \quad (2)$$

En la ecuación (2), ΔI es considerada como la corriente de rizo pico a pico, f , como la frecuencia del interruptor o *chopper*, y L , como la inductancia.

Existe un límite entre los modos de conducción continua y discontinua, conocido también como *límite crítico*, que es cuando la corriente toma el valor de cero en el momento que finaliza el ciclo de conmutación (Roche Vacacela & Terán Torres, 2011). Este es el punto en el que se define la corriente mínima que puede fluir en el inductor

antes de que pase de un modo de conducción al otro; nos permite determinar la inductancia crítica al considerar la corriente de rizo del inductor como igual al doble de la corriente promedio (Durango et al., 2017):

$$L_c = \frac{k(1-k)R}{2f} \quad (3)$$

En la ecuación (3), L_c es considerada como la inductancia crítica y R , como la resistencia.

5. VOLTAJE DE RIZO PICO A PICO DEL CAPACITOR

Después de rectificar una señal de entrada, queda un pequeño componente de corriente alterna denominada *rizo*. Este rizo proveniente del capacitor, debido a que este suministra la corriente de carga cuando el transistor regresa a la fase de encendido, posee una forma de onda similar a la de un serrucho, pues posee altos y bajos. La diferencia entre estos valores máximos y mínimos de tensión son lo que denominamos *voltaje de rizo pico a pico*. Al igual que con la corriente de rizo, es posible determinar este valor a través de la siguiente ecuación (Cardona Herrera & Ospina Hurtado, 2015):

$$\Delta V = \frac{I_c k}{fC} \quad (4)$$

En la ecuación (4), ΔV es considerada como el voltaje de rizo pico a pico, I_c , como el valor de la corriente de carga y C , como el capacitor.

Al igual que con la inductancia, es posible hallar un valor de capacitor crítico al tomar las mismas consideraciones para el inductor. La ecuación que determina el valor crítico del capacitor es la siguiente:

$$C_c = \frac{k}{2fR} \quad (5)$$

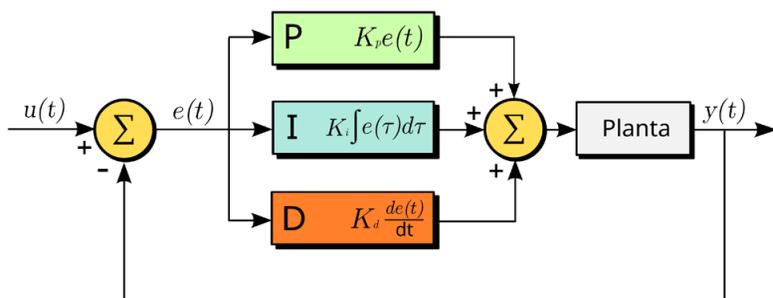
En la ecuación (5), se considera que C_c representa a la capacitancia crítica.

6. CONTROLADORES PID

Un controlador PID es un sistema de control utilizado para regular variables dentro de un proceso a través de un lazo de retroalimentación. Este tipo de controladores opera evaluando la discrepancia entre el valor actual y el valor deseado de la variable, y ajusta el proceso con base a los parámetros de acción proporcional, integral y derivativa, tal como se muestra en la Figura 2.

Figura 2

Diagrama de control PID + planta



Nota. Esquema de un controlador PID, por Arturo Urquiza, 2008, 4 de octubre, Wikimedia Commons (https://commons.wikimedia.org/wiki/File:Controlador_pid.svg). Derechos de autor: Arturo Urquiza reproducido bajo licencia Creative Commons Attribution-Share Alike 3.0 Unported.

Cuando se dispone del modelo matemático de la planta, es factible aplicar técnicas de diseño para determinar los parámetros del controlador que satisfagan las especificaciones tanto del transitorio como del estado estacionario en el sistema de lazo cerrado (Nise, 2014; Razmjoo, 2024). Para los fines de este trabajo, se ha decidido representar el controlador PID en tiempo continuo utilizando la forma paralela y basándonos en la siguiente ecuación, en función de la transformada de Laplace (Razmjoo, 2024):

$$C(s) = K_p + \frac{K_i}{s} + \frac{K_d s}{T_f s + 1} \quad (6)$$

En la ecuación (6), K_p es considerada como la ganancia proporcional, K_i como la ganancia integral, K_d como la ganancia derivativa y T_f como el tiempo del filtro derivativo.

7. DESCRIPCIÓN DEL PROCEDIMIENTO

7.1. Implementación y características de diseño

El diseño del circuito elevador se inició definiendo las características que debería tener el elevador y, también, los valores críticos para la selección de la inductancia y del capacitor. Se estableció lo siguiente:

- Tensión DC de entrada (V_s) de 12 V
- Tensión DC de salida (V_o) de 72 V
- Resistencia: 3 kΩ de 10 W
- Frecuencia: 31372 Hz

A partir de la ecuación (1), se calculó el valor del ciclo de trabajo, el cual, para nuestros cálculos, se representa por la letra :

$$D = \frac{72V - 12V}{72V} = 0,833 \quad (7)$$

Una vez definido el ciclo de trabajo, se usaron las ecuaciones (3) y (5) para determinar los valores críticos de la inductancia L_c y del capacitor. Los valores de estos son los mínimos permisibles para su funcionamiento. Así:

$$L_c = \frac{0,833(1 - 0,833)(3k\Omega)}{2(31372Hz)} = 3,3mH \quad (8)$$

$$C_c = \frac{0,833}{2(31372Hz)(3k\Omega)} = 4,425nF \quad (9)$$

Sabiendo los resultados críticos, se seleccionaron los valores para estos componentes pasivos, de modo tal que el circuito se encuentre en condición de conducción continua. Para ello se eligieron valores superiores a los críticos obtenidos:

$$L = 4,4mH \quad (10)$$

$$C = 100\mu F \quad (11)$$

En el caso de la modulación de la fase correcta de PWM en Arduino, se decidió utilizar la modulación por ancho de pulso. Esto es así porque dicha modulación permite crear ondas cuadradas con una frecuencia específica. Esta técnica utiliza el ciclo de trabajo de una señal periódica para transmitir información o controlar la cantidad de energía enviada a una carga. Se determinó el modo de fase correcta de PWM utilizado en Arduino. Este modo opera mediante una doble pendiente. La frecuencia de salida al utilizar el modo de fase correcta de PWM se puede determinar usando la siguiente ecuación:

$$f = \frac{f_{clk}}{2(N)(TOP)} \quad (12)$$

En la ecuación (12), se considera lo siguiente:

- N es la variable que representa el divisor *prescaler* (1, 8, 64, 256 o 1024).
- TOP es el valor máximo que toma la señal y puede variar de 0 a 255.
- f_{clk} es la frecuencia del reloj del Arduino (16 MHz).

Con ello se determinó la frecuencia de salida, considerando que el pin a utilizar es el número 3, correspondiente a la variable de división *prescaler* igual a 1 y a un valor máximo de señal igual a 255:

$$f = \frac{16MHz}{2(1)(255)} = 31372,55Hz \tag{13}$$

Además, se definió un ciclo de trabajo (*p*) para el microcontrolador Arduino, sabiendo que su ciclo de trabajo varía de 0 a 255. Fue así como se estableció una relación entre el ciclo de trabajo *D* y *p*.

$$p = D \times 255 \tag{14}$$

En la ecuación (14), el ciclo de trabajo en el Arduino es de 213.

7.2. Elaboración del circuito no controlado

Se elaboró el circuito en los *software* Simulink que se muestra en las figuras 3 y 4 y PSIM que se observa en las figuras 5 y 6. El voltaje establecido para cada uno de ellos es el siguiente:

- Simulink: voltaje en la salida de 72 V
- PSIM: voltaje en la salida de 72 V

Figura 3

Circuito elevador elaborado en Simulink

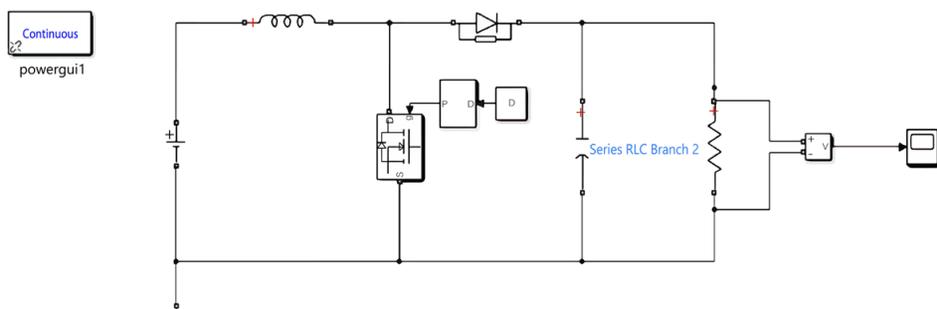


Figura 4

Gráfica del voltaje obtenido por el circuito no controlado en Simulink

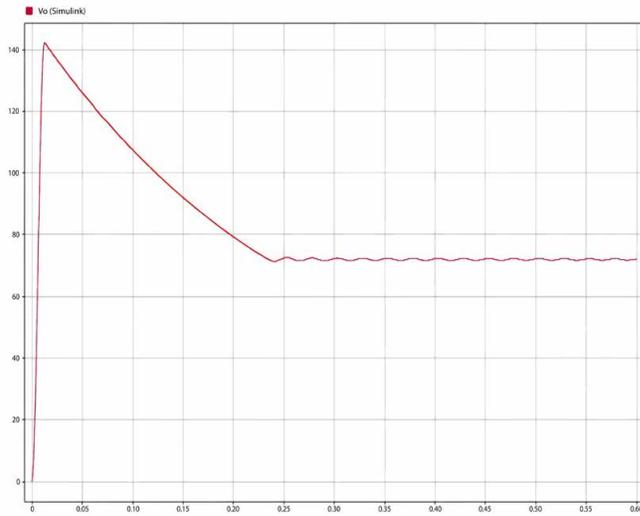


Figura 5

Circuito elevador elaborado en PSIM

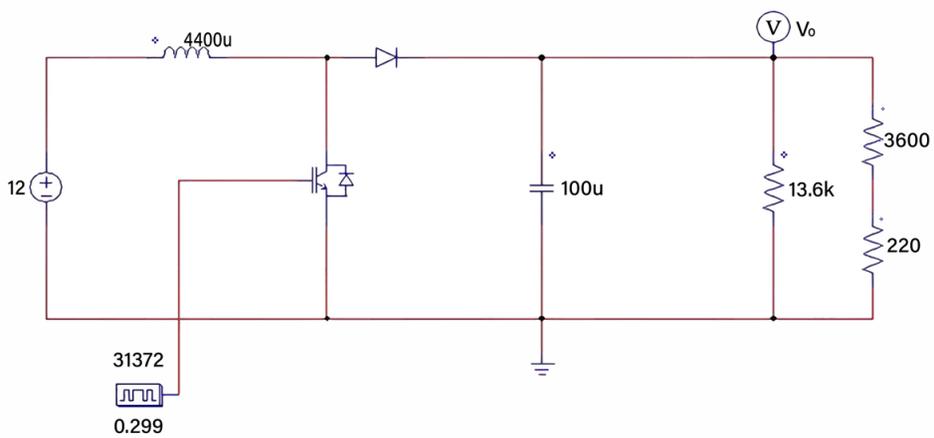
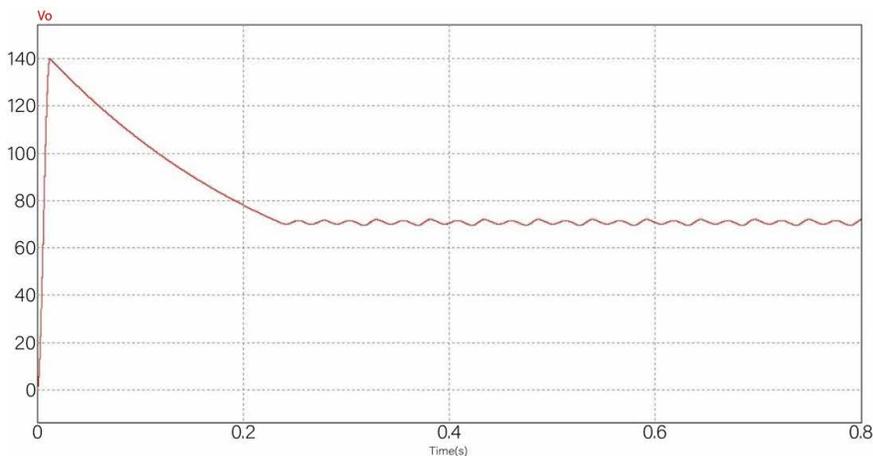


Figura 6

Gráfica del voltaje obtenido por el circuito no controlado en PSIM



7.3. Elaboración del circuito controlado

Espacio de estados del circuito

Considerando el circuito elevador ya presentado, se elaboró la representación en espacios de estados, de la cual da cuenta la siguiente ecuación (15).

$$\begin{bmatrix} \dot{i}_L \\ \dot{v}_C \end{bmatrix} = \begin{bmatrix} 0 & -\frac{1-D}{L} \\ \frac{1-D}{C} & -\frac{1}{CR} \end{bmatrix} \begin{bmatrix} i_L \\ v_C \end{bmatrix} + \begin{bmatrix} 1/L \\ 0 \end{bmatrix} V_S \quad (15)$$

Función de transferencia

Se implementó el circuito del elevador en el *software* MATLAB. Se obtuvo la siguiente función de transferencia para la configuración del circuito:

$$\frac{R(1-D)}{RD^2 - 2RD + CLR s^2 + Ls + R} \quad (16)$$

Con ayuda del apartado de Show Parameters del entorno PID Tunner APP de MatLab se logró determinar los valores de las ganancias (K_p , K_i , y K_d) para el controlador PID. Estos valores se resumen en la Tabla 1.

Tabla 1

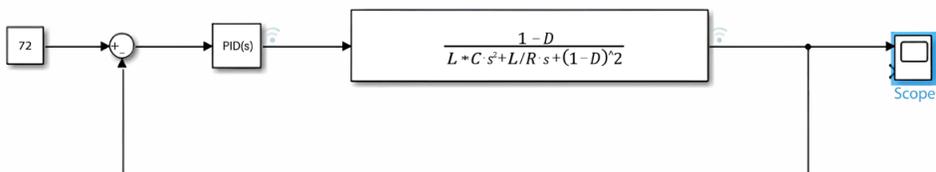
Parámetros considerados en el PID Tunner de MatLab

Parámetros	Valor
K_p	0,013261
K_i	0,30339
K_d	0,00014491

A continuación, en la Figura 7, se procederá a presentar el diagrama de bloques correspondiente al sistema, el cual ofrece una representación detallada de su estructura y la presencia del compensador PID para su control.

Figura 7

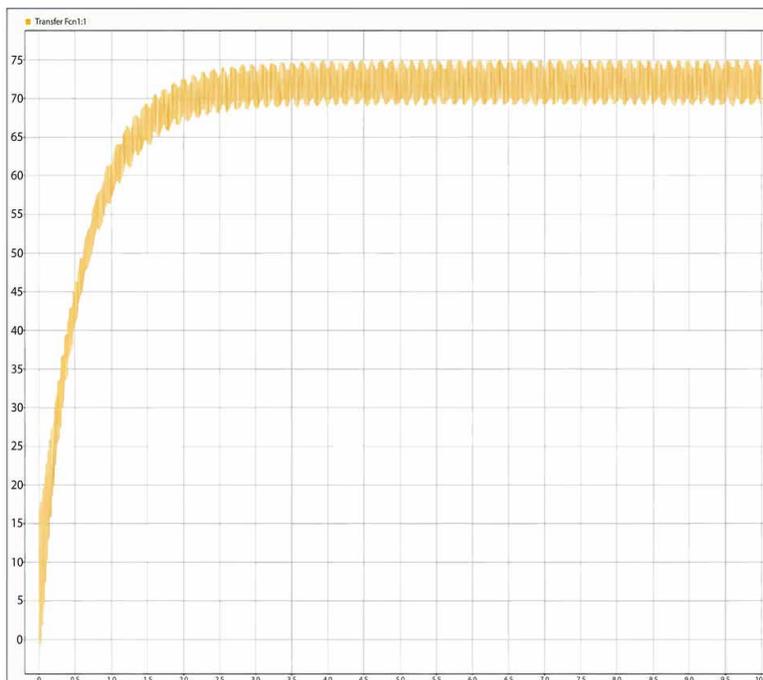
Diagrama de bloques del circuito elevador



En la Figura 8 se presenta la representación gráfica de la función obtenida, considerando los valores de las ganancias y el PID en retroalimentación. Como se observa en la figura, el resultado que se obtiene es que la señal de salida se estabiliza aproximadamente en 72 V.

Figura 8

Voltaje a la salida aplicando PID en Simulink



Prototipo del convertidor elevador en lazo cerrado

Para el control PID, la retroalimentación del sistema se lleva a cabo utilizando un divisor de tensión. Este actuará como un sensor del sistema que permita cerrar el lazo y cuya señal pueda llegar al microcontrolador, de modo tal que el algoritmo de control se encargue de corregir la señal. Debido a que nuestra salida es de 72 V y el Arduino acepta voltajes máximos entre 4 V y 5 V como señal, se usaron resistencias de 220 Ω y 3600 Ω para la reducción de tensión como uso de señal de retroalimentación.

$$\text{señal del sensor} = \frac{220}{220 + 3600} \times 72V = 4,15V \quad (17)$$

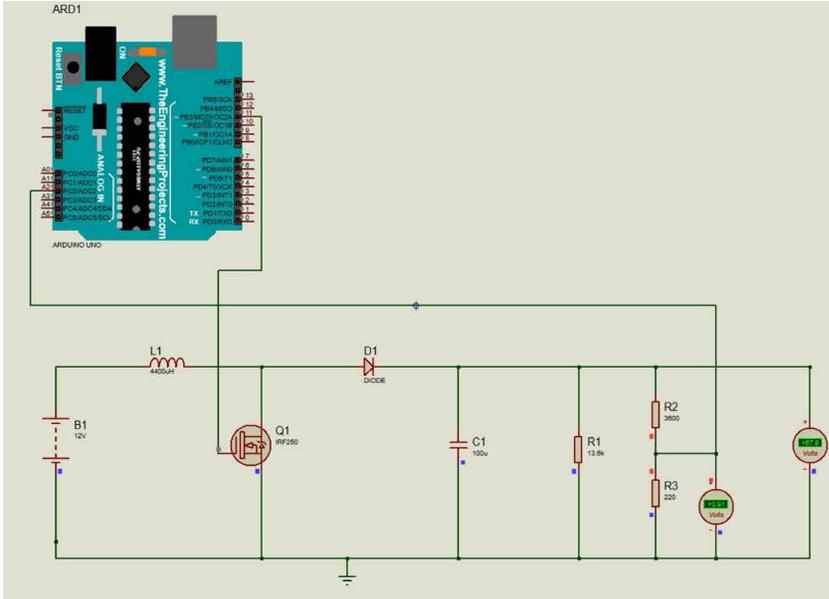
Simulación del circuito controlado

Como parte de las pruebas en simulación, se elaboró un código en Arduino, considerando las ganancias halladas, con el objetivo de probar su funcionamiento en el *software* Proteus y poder tener una idea de lo que podríamos obtener una vez se implemente el circuito. Debido a que el *software* nos solicitaba utilizar un modelo predeterminado de MOSFET para el desarrollo de la simulación, se optó por utilizar el modelo IRF250 debido a su gran capacidad de estabilidad ante altos voltajes y su resistencia a altas

temperaturas, ya que se había tomado en consideración que, debido a las altas corrientes que iban a pasar por el circuito, la temperatura del componente iba a aumentar. La Figura 9 muestra el voltaje de salida obtenido una vez que se subió el código al entorno de Proteus.

Figura 9

Simulación del circuito PID en Proteus



7.4. Implementación

La implementación del circuito elevador se llevó a cabo siguiendo un proceso en tres etapas principales: diseño de pistas, modelado en 3D y fabricación artesanal del circuito impreso.

Diseño de pistas en Eagle

El primer paso consistió en diseñar las pistas del circuito elevador utilizando el *software* Eagle. Se seleccionaron y ubicaron los componentes necesarios, estableciendo las conexiones eléctricas pertinentes para asegurar un diseño óptimo. Una vez finalizado, se generó el archivo Gerber, que es esencial para la fabricación del circuito impreso. La Figura 10 muestra el diseño esquemático resultante.

Modelado 3D en Fusion 360

El siguiente paso fue el modelado 3D del circuito utilizando Fusion 360. Este *software* permitió visualizar y ajustar el diseño en un entorno tridimensional, garantizando la correcta disposición de los componentes y la compatibilidad física de los mismos en la placa de circuito. En la Figura 11, se muestra el modelo 3D del circuito antes de proceder a la fabricación.

Figura 10

Diseño de pistas de la placa en Eagle

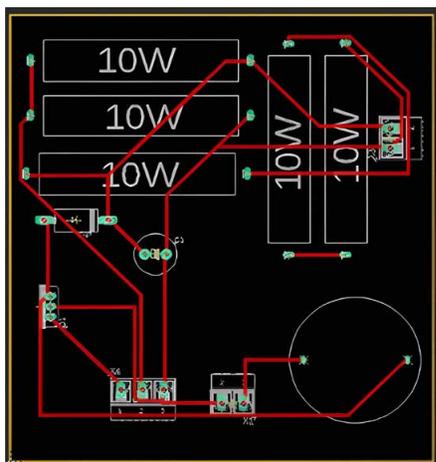
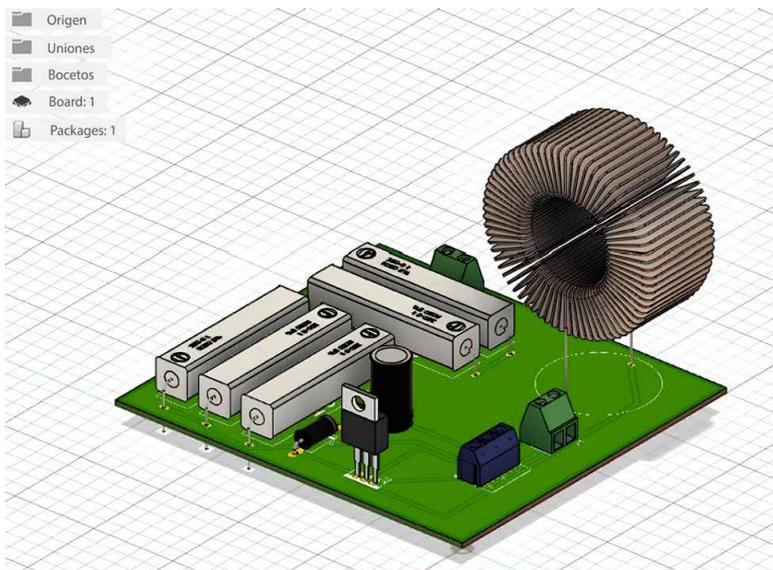


Figura 11

Modelado en 3D de la placa en Autodesk Fusion



Fabricación artesanal del circuito impreso

Finalmente, se fabricó el circuito impreso utilizando un método artesanal basado en transferencia térmica. Se imprimió el diseño de las pistas en papel fotográfico mediante una impresora láser, se transfirió el diseño a una placa de cobre virgen usando una plancha y se corroyó el cobre excedente con una solución de percloruro férrico. La Figura 11 presenta el circuito impreso terminado y listo para su ensamblaje.

Debido que el *software* nos solicitaba utilizar un modelo predeterminado de MOSFET para el desarrollo de la simulación, se había optado por utilizar el modelo IRF250 debido a su gran estabilidad ante altos voltajes (con un máximo posible de 200 V) y a su resistencia a altas temperaturas, ya que se anticipó que, debido a las altas corrientes que iban a pasar por el circuito, la temperatura del componente aumentaría.

8. RESULTADOS

Tras implementar el circuito, se verificó el correcto funcionamiento de los componentes seleccionados:

- Dos resistencias de $5\text{ k}\Omega$
- Dos resistencias de $3,6\text{ k}\Omega$
- Una resistencia de $220\text{ k}\Omega$
- Un capacitor (C) de $100\ \mu\text{F}$
- Una inductancia (L) de $4,4\text{ mH}$

Figura 12

Circuito impreso y ensamblado en la placa



Las mediciones realizadas con el multímetro y osciloscopio muestran que el voltaje de salida promedio es de hasta 40,99 V.

Figura 13

Medición del voltaje en la salida



9. DISCUSIÓN DE RESULTADOS

Como se mencionó en apartados anteriores, los resultados obtenidos con las mediciones reales muestran un voltaje de salida promedio de 40,99 V, que representa una diferencia significativa a los 72 V de la simulación. Es posible que esta discrepancia pueda deberse a diversos factores, tales como el uso del MOSFET IRF630 en lugar del usado en la simulación. Cabe resaltar que este último componente fue utilizado para la implementación debido a su disponibilidad y fácil adquisición en el mercado, así como a características identificadas durante la simulación, como es el voltaje máximo de 200 V. El IRF630 posee una mayor resistencia en el estado de conducción a temperaturas elevadas y permite un paso de corriente máxima de 9 A, en comparación a los 30 A del IRF250.

Debido a esto, y a que este nuevo componente no soporta altas temperaturas, se optó por añadir un disipador de calor, que, aunque pudo mejorar su desempeño, es posible que no alcance la misma eficiencia térmica que el IRF250 y, por ende, que haya contribuido a la caída del voltaje observada en las mediciones reales.

10. CONCLUSIONES

Las mediciones realizadas, que muestran un voltaje de salida cercano a 72 V en las simulaciones de PSIM y Proteus, y una medición práctica de 40,99 V, evidencian un rendimiento parcial del circuito. Las variaciones podrían atribuirse a las tolerancias en los

componentes y a las condiciones del control de operación reales. Por otro lado, el cálculo del ciclo de trabajo ($D = 0,833$) se confirmó como adecuado, lo cual permitió alcanzar la elevación de voltaje requerida en las simulaciones mostradas. La utilización del valor adecuado de ciclo de trabajo, en conjunto con el método de control PID, fue fundamental para el desarrollo del elevador ya que nos permitió obtener un control preciso del sistema y, por ende, una mayor estabilidad en la salida. Por último, el proceso de diseño, modelado 3D y fabricación del circuito fue exitoso, permitió la implementación física del circuito elevador y confirmó la viabilidad del diseño tanto en simulaciones como en la prueba práctica.

REFERENCIAS

- Abril, C. S., Arias, R. E., Guerrero, L. M., & González, L. G. (2016). Diseño de un convertidor elevador, para aplicaciones de energías renovables en instalaciones aisladas. *Maskana*, 5, 99–108. <https://publicaciones.ucuenca.edu.ec/ojs/index.php/maskana/article/view/578>
- Cardona Herrera, S., & Ospina Hurtado, S. (2015). *Construcción de módulo convertidor CC-CC elevador, para prácticas en el laboratorio del programa ingeniería mecatrónica* [Tesis de bachillerato, Universidad Tecnológica de Pereira]. Repositorio Institucional de la Universidad Tecnológica de Pereira. <https://repositorio.utp.edu.co/entities/publication/32f0b289-70af-48d5-9ada-b11b41cc9c58>
- Durango, J. J. M., Ordoñez, J. J., & Machado, L. F. M. (2017). Design and construction of a boost type dc/dc converter with adjustable PWM. *Scientia et Technica*, 22(1), 9-14. <https://doi.org/10.22517/23447214.12811>
- Flores Ordeñana, J. A. (2018). *Diseño de convertidores DC-DC tipo boost con controladores fraccionales para arreglos de paneles fotovoltaicos* [Tesis de maestría, Universidad Politécnica de Puebla]. Repositorio de la Universidad Politécnica de Puebla. <http://repositorio.up Puebla.edu.mx:8080/xmlui/handle/123456789/371>
- Meza, H. A., García, J. L. M., & Mora, S. B. S. (2017). Estrategias de control MPPT aplicadas en un convertidor DC/DC tipo *boost* para sistemas fotovoltaicos. *Revista Colombiana de Tecnologías de Avanzada (RCTA)*, 2(30), 102-108. <http://repositorio.ufps.edu.co/handle/ufps/1019>
- Narciso Vera, W. M. (2022). *Desarrollo de un sistema de freno regenerativo para el aumento de autonomía de la moto eléctrica modelo Sakura M500* [Tesis de bachillerato, Universidad Nacional de Trujillo]. Red de Repositorios Latinoamericanos. <https://repositorioslatinoamericanos.uchile.cl/handle/2250/4748204>
- Nise, N. S. (2014). *Control systems engineering* (7.^a ed.). John Wiley & Sons.

- O’Keeffe, D., Rivero, S., Albiol-Tendillo, L., & Lightbody, G. (2017). Distributed hierarchical droop control of boost converters in DC microgrids [Presentación de escrito]. 28th Irish Signals and Systems Conference (ISSC), Killarney, Irlanda (pp. 1-6). IEEE. doi: 10.1109/ISSC.2017.7983615.
- Palacio Garcés, V. A. (2014). *Convertidores DC-DC para aprovechamiento de frenado regenerativo en sistemas de tracción alimentados con corriente directa* [Tesis de grado, Universidad Pontificia Bolivariana]. Repositorio Universidad Pontificia Bolivariana. <https://repository.upb.edu.co/handle/20.500.11912/1904>
- Rashid, M. H. (2015). *Electrónica de potencia* (4.ª ed.). Pearson.
- Razmjoo, N. (2024). *PID control* [Archivo en MATLAB, versión 1.1.0.0]. MATLAB Central File Exchange. <https://www.mathworks.com/matlabcentral/fileexchange/48060-pid-control>
- Roche Vacacela, E. M., & Terán Torres, S. F. (2011). *Diseño y construcción de un convertidor DC/DC boost mediante lógica difusa* [Tesis de bachillerato, Escuela Politécnica Nacional de Ecuador]. Repositorio digital Escuela Politécnica Nacional. <https://bibdigital.epn.edu.ec/handle/15000/4349>
- Rodríguez, C. A. D., Torres, W. N. R., & Rodríguez, G. E. G. (2024). Diseño e implementación de un convertidor *boost* regulado empleando una estrategia de control PI. *Scientia et Technica*, 29(02), 73-88. <https://doi.org/10.22517/23447214.25452>
- Ruz-Canul, M. A., Djilali, L., Ruz-Hernandez, J. A., & Sanchez-Camperos, E. N. (2022). Control neuronal por modos deslizantes para el frenado regenerativo de vehículos. *Journal Innovative Design*, 6(15), 10-18. https://www.ecorfan.org/taiwan/research_journals/Diseno_Innovativo/vol6num15/Journal_Innovative_Design_V6_N15_2.pdf
- Sanchez Rosado, R. M. (2015). *Análisis comparativo entre controladores basados en lógica difusa y control PID clásico, aplicados a sistemas de control de velocidad de motores DC sin escobillas*. [Tesis de maestría, Escuela Superior Politécnica del Litoral]. Repositorio Dspace. <https://www.dspace.espol.edu.ec/xmlui/handle/123456789/46967>

HACIA UNA NORMATIVA SOBRE LA INTELIGENCIA ARTIFICIAL (IA): CONSIDERACIONES CLAVE Y REGULACIONES INTERNACIONALES

OLDA BUSTILLOS ORTEGA

obustillos@uia.ac.cr

<http://orcid.org/0000-0003-2822-3428>

Escuela de Ingeniería Informática, Universidad Internacional de las Américas, San José, Costa Rica

JORGE MURILLO GAMBOA

jmurillo@uia.ac.cr

<http://orcid.org/0000-0001-5548-8283>

Escuela de Ingeniería Informática, Universidad Internacional de las Américas, San José, Costa Rica

OLMAN NÚÑEZ PERALTA

onunez@uia.ac.cr

<http://orcid.org/0000-0001-6780-022X>

Escuela de Ingeniería Informática, Universidad Internacional de las Américas, San José, Costa Rica

FABIÁN RODRÍGUEZ SIBAJA

frodriguez@uia.ac.cr

<http://orcid.org/0009-0008-3276-9865>

Escuela de Ingeniería Informática, Universidad Internacional de las Américas, San José, Costa Rica

Recibido: 13 de junio del 2024 / Aceptado: 21 de setiembre del 2024

doi: <https://doi.org/10.26439/interfases2024.n020.7178>

RESUMEN. La inteligencia artificial (IA) es una tecnología disruptiva que tiene un impacto significativo en diversos aspectos de la sociedad y la economía. Su rápido desarrollo ha generado la necesidad urgente de definir y establecer regulaciones que aborden los desafíos éticos, sociales y económicos que conlleva su adopción. La falta de una regulación adecuada trae consigo el riesgo de discriminación y sesgos en la toma de decisiones basadas en IA, lo que podría socavar la confianza pública en esta tecnología. Este artículo tiene como objetivo identificar los elementos clave necesarios que sirvan de base para la elaboración de una normativa efectiva de IA. Se toman en cuenta las regulaciones

internacionales de la Unión Europea, los Estados Unidos, así como las iniciativas de organismos internacionales como la Unesco, la OCDE y la Comisión Económica para América Latina (Cepal) con su Índice Latinoamericano de Inteligencia Artificial (ILIA). Además, se presenta el caso específico de Costa Rica como ejemplo de formulación de una estrategia de inteligencia artificial. Se proponen lineamientos para una normativa coherente y efectiva de IA que promueva la cooperación y la armonización de las regulaciones. Estas pautas se ofrecen como guía para regular las herramientas y aplicaciones de IA, así como para adoptarla y usarla de manera responsable en beneficio de la sociedad, apoyada en la cooperación, consensos y acuerdos entre organizaciones y países.

PALABRAS CLAVE: artificial / inteligencia / normativa / regulaciones

TOWARDS A REGULATION ON ARTIFICIAL INTELLIGENCE (AI): KEY CONSIDERATIONS AND INTERNATIONAL REGULATIONS

ABSTRACT. Artificial Intelligence (AI) is a disruptive technology that has a significant impact on various aspects of society and the economy. Its rapid development has generated an urgent need to define and establish regulations that address the ethical, social and economic challenges that come with its adoption. The lack of adequate regulation carries the risk of discrimination and bias in AI-based decision-making, which could undermine public trust in this technology. This article aims to identify the key elements necessary to serve as a basis for the development of effective AI regulations. International regulations from the European Union, the United States, as well as initiatives from international organizations such as UNESCO, the OECD and the Economic Commission for Latin America (ECLAC) with its ILIA AI Strategy Index are taken into account. In addition, the specific case of Costa Rica is presented as an example of the formulation of an Artificial Intelligence Strategy. Guidelines are proposed for coherent and effective AI regulations that promote cooperation and harmonization of regulations. These guidelines are offered as a guide to regulate AI tools and applications, as well as to adopt and use them responsibly for the benefit of society supported by cooperation, consensus and agreements between organizations and countries.

KEYWORDS: artificial / intelligence / normative / regulations

1. INTRODUCCIÓN

Importancia de regular la IA en la sociedad moderna

La inteligencia artificial (IA) representa una de las fuerzas más dinámicas y transformadoras de nuestra era, con interacciones sociales, económicas, tecnológicas. A medida que los sistemas de IA se vuelven más avanzados y autónomos, pueden ayudar a reducir las ineficiencias burocráticas y mejorar la participación ciudadana, pero, a su vez, también introducen desafíos relacionados con la ética, la transparencia y la rendición de cuentas (Khairo & Busroh, 2023). Es una de las tecnologías que ha crecido de forma exponencial y sobre la que los gobiernos tienen los ojos puestos. De acuerdo con Nitzberg y Zysman (2022), se plantea la gobernanza de la inteligencia artificial (IA) como una serie de desafíos entrelazados, comparable a la energía del vapor o la electricidad: no puede gobernarse de forma aislada, sino en el contexto de una caja de herramientas de tecnología digital más amplia. Se hace necesario establecer prioridades nacionales sobre cómo aprovechar los beneficios y, al mismo tiempo, gestionar sus riesgos sociales y económicos; y todo esto en constante evolución.

De acuerdo con Burt (2021), las regulaciones de IA están evolucionando rápidamente y organismos gubernamentales —incluyendo la Comisión Federal de Comercio de Estados Unidos y la Comisión Europea— han anunciado directrices o propuestas para regular la inteligencia artificial. En lugar de esperar a que se aclaren las leyes y regulaciones, las empresas y organizaciones pueden comenzar a tomar medidas desde ahora para prepararse y adoptar estándares y mejores prácticas relacionadas con los derechos fundamentales de las personas y los futuros sistemas de IA, lo que les permitirá ser reconocidas como confiables (Katulić, 2020).

Áreas a regular en la IA

Baiocchi y Leicht (2023) indican que, en 2020, el secretario general de la ONU, António Guterres, presentó una hoja de ruta para la cooperación digital. Esta hoja de ruta se centró en cómo la comunidad internacional puede aprovechar las oportunidades de las tecnologías digitales, al tiempo que enfrenta sus desafíos. En 2021, la Unesco elaboró el primer marco normativo global, conocido como la *Recomendación sobre la ética de la inteligencia artificial*, que fue aprobado y adoptado por los 193 Estados miembros. Este estándar global para la IA se fundamenta en valores y principios éticos clave, aplicables a diversas áreas políticas que están siendo transformadas por la IA, como la gobernanza de datos, el medio ambiente, la igualdad de género, la economía y el trabajo, la cultura, la educación y la investigación (Baiocchi & Leicht, 2023).

En febrero del 2023, Costa Rica, siguiendo la recomendación de la Unesco, abordó la implementación de políticas mediante un evento denominado Hacia una Estrategia de

Inteligencia Artificial en Costa Rica, coordinado por el Ministerio de Ciencia, Innovación, Tecnología y Telecomunicaciones (MICITT) y con apoyo de la Unesco y el Centro Nacional de Alta Tecnología (Cenat). Juntos, propusieron trazar la hoja de ruta a través de procesos de vinculación y transformación social y productiva, aunados al uso intensivo del conocimiento y al acceso democrático a los beneficios de la ciencia, la innovación y la tecnología, con miras a generar el cambio que el país necesita (Ministerio de Ciencia, Innovación, Tecnología y Telecomunicaciones [MICITT], 2023b).

Vanessa Gibson señala que, solo en Costa Rica, cerca del 75 % de las empresas ha iniciado los primeros pasos para implementar la inteligencia artificial en sus procesos. Junto al *machine learning*, la IA es una de las cinco megatendencias en los sectores de mayor atracción de inversión extranjera directa (Dirección de Prensa y Relaciones Públicas [DPRP], 2022).

En junio del 2024, la Unesco reunió a expertos internacionales en IA para llevar a cabo el Diálogo Político sobre la Gobernanza de la IA, en el cual se debatieron soluciones concretas y éticas para un ecosistema de IA. Gabriela Ramos, de la red AI Ethics Experts Without Borders, aportó recomendaciones específicas sobre la gobernanza de la IA, basadas en evaluaciones llevadas a cabo en más de cincuenta países. En suma, se propone establecer un diálogo político (para reunir y compartir experiencias, conocimientos y buenas prácticas entre países), enfocado en la gobernanza de la inteligencia artificial; es necesario abordar las cuestiones apremiantes, los retos asociados y fomentar el desarrollo de una IA ética que respete y promueva los derechos humanos, la dignidad humana y las libertades fundamentales (Unesco, 2024).

Riesgos sobre una regulación en la IA

La IA puede ser una herramienta poderosa para el bien, pero también tiene el potencial de ser utilizada de manera perjudicial. Puede ocasionar discriminación y sesgos a medida que se integra en una amplia gama de aplicaciones, desde la atención médica hasta la toma de decisiones financieras. Los aspectos técnicos de las herramientas que se están desarrollando y promoviendo tienen importantes y directas consecuencias sociales y políticas. Se debe considerar a la IA como algo que existe en sí mismo, más que como un conjunto de tecnologías cognitivas, por lo que una regulación al respecto tendría como objetivo ayudar a que los gobernantes y profesionales de la IA aborden no solo los aspectos técnicos, sino también los riesgos de las consecuencias sociales y políticas (Dumouchel, 2023). De acuerdo con Schuett (2023), en lugar de utilizar el término IA, los responsables de generar las políticas deberían centrarse en establecer lineamientos sobre los riesgos específicos que quieren reducir. Para el cumplimiento legal, es mejor definir las principales fuentes de riesgos relevantes, como: técnicos (aprendizaje por refuerzo), aplicaciones (reconocimiento facial) y capacidades (interactuar físicamente con el entorno).

Según Pownall (2019), en el aspecto meramente técnico de la regulación sobre la IA existe el riesgo de discriminación algorítmica, incluyendo sesgos en la toma de decisiones y violaciones de la privacidad. Por ello, propone considerar los siguientes riesgos:

- Algoritmos injustos o discriminatorios
- Resultados poco fiables o que funcionan mal
- Uso indebido de datos personales o confidenciales
- Mayor exposición a ciberataques
- Pérdida de empleos
- Riesgos y responsabilidades legales
- Riesgos reputacionales, incluidos *deepfakes* maliciosos

Desafíos y ética sobre la regulación de la IA

De acuerdo con Truby et al. (2020), existe un consenso internacional sobre los principios de la gobernanza de la IA, pero los legisladores no han logrado traducir esos principios en regulaciones para el sector financiero. Por tal motivo, consideran que la mejor manera consiste en un enfoque regulatorio proactivo, antes de que ocurra algún daño.

Otro desafío se relaciona con los factores que influyen en los ciudadanos para utilizar robots. Al respecto, Chatterjee (2020) revela un estudio donde plantea que el uso de robots aumentaría apreciablemente si el Gobierno impusiera un estricto control de inteligencia artificial (IA) y que el uso de estos robots mejoraría la calidad de vida de los ciudadanos.

El sector de salud es otro ejemplo de desafío, al considerar la utilización de la inteligencia artificial (IA) en la atención de pacientes. Konttila y Väyrynen (2022), quienes llevaron a cabo un estudio en el sector sanitario finlandés, identificaron los desafíos que presenta una regulación de la tecnología basada en IA (AI-based healthcare technology por sus siglas en inglés, abreviado AIHT) y señalaron la ambigüedad de tener varias regulaciones sobre el AIHT y, además, la ley europea de IA, todo lo cual podría obstaculizar la innovación en este sector e, incluso, desacelerar su desarrollo.

De acuerdo con Cain y Webster (2022), el *software* de inteligencia artificial se ha convertido cada vez más en parte de la economía hotelera y turística, y la automatización de la industria de servicios ha sido una evolución natural. Sin embargo, estas tecnologías se implementan en una industria que tiene un alto grado de regulación y una necesidad de rentabilidad y satisfacción del cliente. Por lo tanto, la intención de las políticas de regulación y las instituciones que las procesan tendrán el desafío de lograr un impacto masivo en la competitividad de este sector.

Con respecto a la ética en los sistemas de inteligencia artificial (IA), ha emergido como un tema central en la discusión académica y laboral. Sin embargo, hasta la fecha no se ha alcanzado un consenso claro sobre la configuración de un marco ético para la IA. Esta falta de acuerdo se debe a la diversidad de interpretaciones y percepciones asociadas con las variaciones culturales y los diferentes contextos de aplicación de estas tecnologías (Ferreira Beni et al., 2023).

Ferreira Beni et al. añaden una lista de posibles problemas sociales y éticos asociados a la IA:

- Privacidad, seguridad y precisión (consentimiento para utilizar datos privados)
- Intrusión en la privacidad (interrumpir las actividades y rutinas de las personas)
- Evaluación (al ser automatizada podría no ser precisa ni equitativa, lo cual genera un impacto negativo)
- Sesgo y discriminación (de género, raciales y culturales)
- Menor interacción humana (reducción de la interacción humana y aislamiento social).

De acuerdo con Martínez (2024), la IA está presente en la automatización de tareas y la creación de sistemas de recomendación, e incluso tiene influencia en los procesos creativos y la toma de decisiones. Sin embargo, existe la suposición de que los sistemas basados en inteligencia artificial (IA) son inherentemente neutrales; pero considerarlos así no solo es incorrecto, sino que, además, puede tener consecuencias peligrosas en la toma de decisiones y en la formulación de políticas. Han surgido una serie de propuestas sobre cómo lograr una IA ética y confiable, tanto en el sector privado como en entidades gubernamentales en varias partes del mundo. Se enumera, a continuación, una serie de valores y principios éticos:

- Equidad y no discriminación (decisiones de la IA no deben sistemáticamente privilegiar a un grupo arbitrario de usuarios sobre otros)
- Transparencia y explicabilidad (de la construcción y despliegue, la documentación, el estudio de riesgos y la metodología de recolección de datos; se debe explicar cómo la IA entrega un resultado y también cómo llegó a ese resultado)
- Supervisión y decisión humanas (la IA debería ayudar a las personas a tomar decisiones mejores y más informadas de acuerdo con sus objetivos)
- Responsabilidad y rendición de cuentas (la IA nunca podrá reemplazar la responsabilidad final de los seres humanos y su obligación de atribuir la responsabilidad ética y jurídica a las personas físicas o a entidades jurídicas)
- En la siguiente Tabla se agrupan las áreas políticas de la Unesco sobre la IA y se organizan en diez dominios (Baiocchi & Leicht, 2023).

Tabla 1*Áreas políticas sobre regulaciones en IA según la Unesco*

Dominios IA	Elementos esenciales de una normativa sobre la IA	Áreas políticas sobre la IA según la Unesco
a) Marco legal y regulatorio	Establecimiento de un marco legal sólido que defina claramente las responsabilidades, requisitos y procedimientos relacionados con la IA.	Estándar global IA para el trabajo y la cultura. Con valores y principios éticos clave para su desarrollo y uso en igualdad de género. Fomentar el desarrollo de una IA ética que, desde su concepción, respete y promueva los derechos humanos, la dignidad humana y las libertades fundamentales
b) Ética y principios rectores	Incorporación de principios éticos, como la transparencia, la equidad, la responsabilidad y la no discriminación.	
c) Gobernanza y supervisión	Creación de una estructura de gobernanza que incluya un organismo regulador encargado de supervisar la aplicación de regulaciones, incorporando la aplicación de índices de IA.	Amplia gama de áreas políticas como gobernanza de datos. Supervisión y decisión humanas
d) Protección de datos y privacidad	Establecimiento de directrices claras sobre el manejo de datos personales y garantizar la privacidad en los sistemas IA.	Acceso seguro a los beneficios de la IA.
e) Evaluación de riesgos y seguridad	Definición de procesos para evaluar y gestionar los riesgos asociados con la IA, especialmente en aplicaciones críticas.	Diálogos políticos entre países para compartir experiencias, conocimientos y buenas prácticas.
f) Auditorías y conformidad	Implementación de auditorías periódicas para evaluar el cumplimiento de las regulaciones y la calidad de los sistemas.	Equidad y no discriminación. La IA no debe sistemáticamente privilegiar a un grupo arbitrario de usuarios sobre otros.
g) Educación y formación	Promoción de la educación y formación en el uso seguro y ético de la IA, tanto para el Gobierno, el sector privado, así como en la población de estudiantes y sociedad en general.	Uso intensivo del conocimiento en automatización de tareas, creación de sistemas de recomendación y diseño de herramientas creativas.
h) Transparencia y responsabilidad	Transparencia en decisiones y funcionamiento de sistemas de IA y definición de responsabilidades en caso de incidentes.	Transparencia en la construcción y entrega de resultados, explicando cómo se llegó a ese resultado. La responsabilidad ética y jurídica y rendición de cuentas corresponde a las personas físicas o entidades jurídicas y no a los sistemas de IA.
i) Impacto social y económico	Evaluación del impacto de la IA en el empleo, la economía, la sociedad en general, y desarrollo de estrategias de mitigación.	Medioambiente, industria, diferentes sectores de la economía y la academia. Vinculación y transformación social y productiva.

(continúa)

(continuación)

Dominios IA	Elementos esenciales de una normativa sobre la IA	Áreas políticas sobre la IA según la Unesco
j) Cooperación internacional	Colaboración e intercambio de información con países y organismos internacionales para abordar los desafíos de IA.	Acceso democrático a los beneficios de la ciencia, la innovación y la tecnología de IA.

2. OBJETIVOS DE LA INVESTIGACIÓN

Elaborar una serie de elementos y consideraciones clave que conformen guías para una normativa sobre la inteligencia artificial (IA), a partir del análisis de normativas, leyes y directrices internacionales, y la evaluación y comparación de las regulaciones existentes a nivel global, con base en los enfoques de la Unión Europea, Estados Unidos, República Popular China y organizaciones internacionales como la Unesco, la OCDE, Cepal y el Banco Interamericano de Desarrollo (BID).

Dentro de los objetivos específicos de la investigación están los siguientes:

- Identificar elementos clave que deben estar presentes en todo marco regulatorio de IA, mediante el análisis de la transparencia, la privacidad, la responsabilidad y la supervisión humana.
- Explorar marcos regulatorios internacionales, el caso de Costa Rica y la región latinoamericana en relación con la forma en que están abordando la regulación de la IA.
- Elaborar tablas comparativas para identificar y extraer consideraciones relevantes, a manera de lineamientos, para una normativa sobre la inteligencia artificial.

3. METODOLOGÍA

Para identificar las normativas sobre IA, en las etapas de revisión documental y revisión de literatura se realizó una búsqueda, a nivel nacional e internacional, de temas relacionados con regulaciones y legislación sobre la inteligencia artificial.

Revisión documental

Se investigó sobre el uso y desarrollo de la inteligencia artificial (IA) de parte de organismos internacionales como la Comisión Económica para América Latina (Cepal) y su índice ILIA; el BID y su programa fAIr LAC, la Unión Europea, los Estados Unidos de América y la República Popular China. Para el caso de Costa Rica, se consultaron

comunicados y publicaciones del Ministerio de Ciencia, Innovación, Tecnología y Telecomunicaciones (MICITT) del Ministerio de Educación Pública (MEP) y de entidades no gubernamentales, como la Coalición de Iniciativas para el Desarrollo (CINDE), la Cámara de Tecnologías de Información y Comunicaciones (CAMTIC) y la corporación multinacional INTEL.

Revisión de literatura

Se realizó una revisión de literatura consultando bases de datos tales como Google Académica, ProQuest Digital Dissertation and Theses e IEEE Xplore. Con la revisión documental y de literatura se pudieron extraer los elementos clave y completar tablas, cumpliendo así con los objetivos específicos, y elaborar otras para guiar la propuesta de una normativa de IA.

4. REGULACIONES Y NORMATIVAS DE PAÍSES SOBRE LA IA

IA en los Estados Unidos de América

Cuéllar et al. (2024) realizaron una encuesta a más de mil gerentes en los Estados Unidos sobre el impacto de posibles regulaciones en la inteligencia artificial, incluyendo cuestiones éticas y sus intenciones de adoptar tecnologías de este tipo. Descubrieron que este tema aumenta la percepción de los gerentes sobre la importancia de la seguridad, privacidad, prejuicios, discriminación y transparencia relacionadas con la IA, y que ello requiere de personas con cualidades humanas como empatía, juicio y justicia. También se incrementa la intención de los gerentes de gastar en el desarrollo de una estrategia de IA, capacitar al personal o adquirir paquetes de *software* basados en esta tecnología.

David Heiner, asesor de políticas estratégicas de Microsoft y representante de Partnership on AI, hace hincapié en que la IA no debería estar controlada por un pequeño número de empresas. Señaló también que Microsoft estaba haciendo que su tecnología IA de reconocimiento de imágenes estuviera ampliamente disponible para el usuario final y exponiendo las interfaces de programación para que cualquiera pueda desarrollar nuevas aplicaciones (OECD, 2018).

IA en la Unión Europea

Benedetta Arese Lucini (Italia) presentó, en septiembre de 2017, en el marco de la Conferencia Ministerial de Industria y TIC del G7 celebrada en Turín, el enfoque de la IA centrado en lo humano. Los países del G7 reconocieron los enormes beneficios potenciales de la IA, pero también su impacto incierto en la sociedad y la economía.

Las directrices planteadas por Arese se agrupan en cuatro áreas:

- i) Comprender el impacto cultural, ético, regulatorio y legal de la IA
- ii) Explorar el impacto de la IA, especialmente en el crecimiento, la creación de empleo, la rendición de cuentas, la privacidad y la seguridad
- iii) Adoptar un enfoque de múltiples partes interesadas, como forma eficaz de abordar cuestiones políticas y regulatorias
- iv) Trabajar para lograr un entendimiento común sobre cómo beneficiarse del potencial de la IA para una sociedad equitativa, subrayando al mismo tiempo que la regulación no debe obstaculizar el desarrollo de la tecnología y la industria (OECD, 2018).

Una de las iniciativas internacionales más relevantes surgió en 2023, cuando el Parlamento Europeo aprobó el AI Act (AIA), el texto de compromiso de la Ley de IA de la Unión Europea. De acuerdo con Tallberg et al. (2024), se realizaron consultas públicas sobre esta regulación europea, en las que los actores empresariales expresaron preocupaciones sobre la IA, apoyando la regulación y mostrando menos preocupación por las desventajas de la IA que otros actores no estatales. Los resultados mostraron que estas diferencias son más pronunciadas en países con sectores comerciales de IA más fuertes (Tallberg et al., 2024; Stahl et al., 2022). Según el AIA el nivel de riesgo de la IA en la educación, el empleo, la migración, la justicia y la aplicación de la ley se considera de alto riesgo o riesgo significativo y, por tanto, requiere de una evaluación de la gravedad, intensidad, probabilidad, duración e impactos potenciales de dicho riesgo. Este enfoque es particularmente relevante en el uso de la IA para la identificación biométrica remota en tiempo real, ya que puede afectar derechos y libertades fundamentales, como la privacidad y la libertad de reunión, e implicar resultados sesgados o efectos discriminatorios en función de edad, etnia, raza, sexo o discapacidades.

Al respecto, Novelli et al. (2024) proponen hacer una clasificación de riesgo dividida en cuatro categorías: inaceptable, alto, limitado y mínimo. Adicionalmente, se exige una evaluación del impacto y un plan de mitigación de riesgos (AIA, Recital 58a). Comparan esta clasificación con el cambio climático, pues ambos fenómenos comparten riesgos similares, con magnitudes impredecibles y una complejidad creciente por la interacción de múltiples factores (Novelli et al., 2024; Gstrein, 2022).

IA en la República Popular China

Franks et al. (2024), en su reporte sobre regulaciones de IA en la República Popular China indican que este país se ha adelantado a otras jurisdicciones de la inteligencia artificial, promulgando un conjunto de regulaciones sobre los riesgos asociados, estableciendo obligaciones integrales sobre el uso de IA generativa y sus algoritmos, protegiendo contra una dirección política incorrecta y la violación de la moral social. Además, se

garantiza que el regulador tenga visibilidad de ciertos algoritmos al exigir la presentación de información relevante.

De acuerdo con Matt Sheehan (2023), China está a punto de implementar algunas de las regulaciones más tempranas y detalladas del mundo que rigen la IA. Se incluyen medidas sobre los algoritmos, así como nuevas reglas para las imágenes generadas sintéticamente y *chatbots* en la plataforma de ChatGPT.

Xiao Zhang, subdirectora del Centro de Información de la Red de Internet en China, durante la sesión número cinco sobre el panorama de las políticas de IA en la conferencia de la OECD en París, menciona que el país se encuentra actualmente en la tercera fase de Internet de las cosas (IoT) y se espera que la IA integre datos y sistemas en el futuro. Además, presentó (durante esta misma sesión número cinco) la Directriz sobre el desarrollo de la IA con un enfoque a largo plazo donde se apunta a que China sea el centro mundial de innovación en IA para el año 2030 (OECD, 2018).

Tabla 2

Enfoque de regulaciones sobre la IA según países (fuente: de los autores)

Dominios IA	Estados Unidos de América	Unión Europea	República Popular de China
a) Marco legal y regulatorio	La IA no debería estar controlada por un pequeño número de empresas	Ley de IA de la Unión Europea y Parlamento Europeo	Directriz sobre el desarrollo de la IA
b) Ética y principios rectores	Requiere personas con cualidades humanas como empatía, juicio y justicia	Directrices éticas de la Comisión Europea y Carta de derechos fundamentales	Proteger contra una dirección política incorrecta y la violación de la moral social
c) Gobernanza y supervisión		Adoptar un enfoque <i>centrado en lo humano</i> respecto de la IA	
d) Protección de datos y privacidad	La importancia de la seguridad, privacidad, prejuicios, discriminación y transparencia relacionadas con la IA	Explorar aspectos positivos y controversiales sobre la privacidad.	Medidas sobre los algoritmos y reglas para imágenes generadas sintéticamente y <i>chatbots</i> en plataforma ChatGPT
e) Evaluación de riesgos y seguridad		Categorías de riesgo: inaceptable, alto, limitado y mínimo. Sistemas con riesgo significativo (alto) requieren de una evaluación de la gravedad, intensidad, con probabilidad, duración e impactos potenciales del riesgo	Visibilidad de ciertos algoritmos al exigir la presentación de información relevante

(continúa)

(continuación)

Dominios IA	Estados Unidos de América	Unión Europea	República Popular de China
f) Auditorías y conformidad	Tecnología de IA de reconocimiento de imágenes están disponibles ampliamente	Diálogo entre múltiples partes interesadas para la rendición de cuentas Lograr un entendimiento común sobre cómo beneficiarse de todo el potencial de la IA para una sociedad equitativa	Obligaciones integrales sobre el uso de IA generativa y sus algoritmos
g) Educación y formación	Formar personas en IA con énfasis en la empatía, juicio y la justicia	Enfoque de múltiples partes interesadas, como forma eficaz de abordar cuestiones políticas y regulatorias	Inteligencia, investigación y desarrollo de IA
h) Transparencia y responsabilidad	Servicios para usuario final y exponiendo las interfaces de programación a los desarrolladores	La regulación sobre IA no debe obstaculizar el desarrollo de la tecnología y la industria	Aplicaciones en áreas socioeconómicas con impacto de la IA en la sociedad
i) Impacto social y económico	La IA sobresale en: videos, voz, sonidos y en reconocimiento de imágenes	Beneficios potenciales, impacto en la sociedad y en la economía	Enfoque a largo plazo que apunta a China como centro mundial de innovación en IA en 2030
j) Cooperación internacional	Cualquiera puede desarrollar nuevas aplicaciones		

5. REGULACIONES Y DIRECTRICES SOBRE LA IA DE ORGANISMOS INTERNACIONALES

Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura (Unesco)

En 2020, António Guterres, secretario general de la ONU, presentó una hoja de ruta destinada a potenciar la colaboración en el ámbito de las tecnologías digitales. Al año siguiente, Allegra Baiocchi, coordinadora de la ONU en Costa Rica, y Alexander Leicht, director de la oficina multipaís de la Unesco, lanzaron el documento titulado *Ética de la Inteligencia Artificial*, que fue ratificado por los 193 Estados miembros de la organización. Este documento se basa en principios éticos esenciales para guiar el desarrollo y uso de la IA en áreas como la gobernanza de datos, la sostenibilidad ambiental, la igualdad de género y la economía, entre otros. Su propósito es establecer un marco que fomente la cooperación internacional y promueva el uso responsable de

la tecnología, respetando los derechos humanos y asegurando un enfoque sostenible y pacífico (Baiocchi & Leicht, 2023).

Organización para la Cooperación y el Desarrollo Económico (OCDE)

Anne Carblanc, jefa de la División de Política de Economía Digital de la OCDE, presentó el panorama de políticas de IA, con iniciativas de los gobiernos, el sector privado, las comunidades de investigación, la sociedad civil y los sindicatos. El potencial de la IA permite aumentar la eficiencia y eficacia de sectores enteros, incluida la prestación de servicios públicos, la mejora en la educación, la seguridad pública, la salud y el equilibrio entre la vida laboral y personal. Los gobiernos, según Carblanc, deben planificar la inversión y el desarrollo de la IA. Adicionalmente, se han delineado políticas y programas para minimizar la perturbación económica y brindar un acceso más amplio a pequeñas y medianas empresas (PYME) e incorporar la IA en sus procesos productivos (OECD, 2018).

Comisión Económica para América Latina y el Caribe (Cepal)

El 4 de agosto de 2023, la Cepal llevó a cabo el evento IA para el Desarrollo Sostenible de América Latina en Santiago de Chile. Allí se presentó el primer Índice Latinoamericano de Inteligencia Artificial (ILIA). Según Soto Arriaza y Durán Rojas (2024), este índice proporcionará una visión regional para fomentar la creación de ecosistemas de desarrollo e innovación en IA, pues evalúa tres dimensiones: factores habilitantes, investigación y desarrollo, y gobernanza. El índice también ofrece un análisis detallado del estado de madurez de la IA en la región, abarcando aspectos como infraestructura, capital humano, disponibilidad de datos, regulaciones, áreas estratégicas y participación ciudadana. Además, mide la existencia de regulaciones en áreas como ciberseguridad, protección de datos y experimentación regulatoria, y posiciona a la IA como una herramienta valiosa para los latinoamericanos y una importante contribución global.

José Manuel Salazar-Xirinachs, secretario ejecutivo de la Cepal, durante el evento titulado IA para el desarrollo sostenible de América Latina de la Cepal en Santiago de Chile, el 11 de agosto de 2023, enfatizó la importancia de que “la inteligencia artificial se trabaje de manera explícita y deliberada en las políticas de desarrollo productivo de los países de la región y sus territorios” (Comisión Económica para América Latina y el Caribe [Cepal], 2023, p.1).

El 23 de septiembre del 2024 se llevó a cabo el lanzamiento de la segunda versión del Índice Latinoamericano de Inteligencia Artificial (ILIA), organizado por la Cepal y con la presencia de expositores de varios países que presentaron sus productos de investigación y mencionaron que, con respecto al uso de ILIA, se utilizan los siguientes principios de la IA (Cepal, 2024):

- Ser socialmente beneficiosa
- Evitar que cree o refuerce sesgos injustos
- Ser construida y probada para seguridad
- Ser responsable ante la gente
- Incorporar principios de diseño de privacidad
- Mantener altos estándares de excelencia científica
- Estar disponible para usos que concuerden con estos principios (Pichai, 2018).

De acuerdo con Jorge Patiño, coordinador del ILIA en la Cepal, cada proyecto que se inicia tiene que ser beneficioso para la sociedad, tiene que ser justo y además seguro, al incorporar un diseño de privacidad y proveer un avance en las ciencias. La versión 2 de ILIA busca hacerse cargo del ecosistema que envuelve la normativa y regulación de la IA, subdividiendo la dimensión de gobernanza en tres subdimensiones: visión e institucionalidad, vinculación internacional y regulación. Asimismo, esta segunda versión añade nuevos subindicadores con caracterizaciones discretas. Así, por ejemplo, Visión e institucionalidad, del indicador Estrategia de IA, incluye: ética y gobernanza, infraestructura y tecnología, desarrollo de capacidades, datos, gobierno digital, industria y emprendimiento, investigación y desarrollo y cooperación regional e internacional.

Aplicando el índice ILIA, se logran obtener mediciones de los países en los siguientes aspectos:

1. Estrategia en IA: se mide la falta de estrategias de IA sistemáticas y actualizadas, así como la ausencia de una hoja de ruta para su uso (países a la deriva).
2. Orientación de las estrategias: mide la presencia de elementos críticos, de similitud en las estructuras, y mecanismos de evaluación y coordinación para cumplir objetivos nacionales de IA.
3. Espacios para construcción de estrategia: mide la escasez de procesos de participación ciudadana en la elaboración de la estrategia, la importancia de mejorar la formulación de políticas, y la oportunidad para aumentar los estándares de participación y legitimidad en la incorporación de personas en la construcción colectiva de una estrategia de IA.
4. Enfoque regulatorio: mide la falta de una posición común, la ausencia de un relato o propuesta regional para la regulación de la IA, y una oportunidad perdida para construir una posición regional sobre la normativa de la IA. La mayoría de los países están inspirados en la Unión Europea, pero hay fragmentación entre ellos y poca unificación para participar regionalmente.

5. Entornos sólidos, seguros y explicables: mide el índice de ciberseguridad con respecto a los ecosistemas maduros de IA en América Latina, la transparencia, explicabilidad y el enfoque utilizado en la rendición de cuentas y promoción del “no daño” en IA.
6. Sostenibilidad: mide las condiciones favorables para el acceso a energías limpias, el potencial para convertirse en carbono neutral y la necesidad de sensibilización y promoción para aprovechar el potencial de ser *más verdes* que los europeos.

Algunos panelistas en el evento de lanzamiento del ILIA 2 como Nicolás Schubert de Google, Chile, propuso que el rol de la IA debe mejorarse en mercados emergentes y superar lo que tenemos actualmente. Asevera que tiene más sentido regular los riesgos que la tecnología, por lo que se hace necesario generar marcos interoperables que permitan la tecnología transfronteriza. Y añade que la IA es tan importante que hay que regularla, pero de forma coordinada.

Lourdes Martínez de la Sociedad Mexicana de IA nos recuerda que ya teníamos muchos actores que habían puesto las primeras piedras y que el Gobierno no contemplaba la IA en la factura de datos. Este índice ILIA refleja la necesidad de tener una estrategia de IA responsable, la cual requiere leyes, pero además cumplir con las mejores prácticas.

Fabio Senne del Observatorio Brasileño de IA, agregó que el monitoreo es fundamental, así como la adopción de datos estadísticos para analizar tendencias y logros, aunque los procesos estadísticos sean costosos. Desde el 2019 Brasil realiza encuestas a nivel nacional y mide, así, como las empresas y el Gobierno están adoptando tecnologías basadas en IA. Ahora se busca profundizar esta medición para captar aspectos más sofisticados sobre la adopción de IA (cuánto es desarrollo propio y cuánto es en la compra de productos de mercado) y para medir principalmente cuánto aprendizaje interno se tiene hoy. Añadió Senne que en julio del 2024 se desarrolló en Brasil un plan con metas claras y presupuesto para los cinco ejes: infraestructura y desarrollo, capacitación en IA, la IA en servicios públicos, la innovación empresarial, y la gobernanza e innovación.

Iniciativa fAIr LAC del Banco Interamericano de Desarrollo (BID)

Galdón Clavell y Lorente Martínez de Argentina, con el apoyo del Laboratorio de Innovación del Banco Interamericano de Desarrollo y la iniciativa fAIr LAC del BID, presentaron la propuesta de un prospecto algorítmico como herramienta específica para solventar la complejidad técnica de los sistemas algorítmicos dentro del contexto de una normativa general. Un ejemplo concreto de aplicación de la guía son las aplicaciones de movilidad con el sistema de posicionamiento global (GPS, por sus siglas en inglés) para sugerir

rutas eficientes en tiempo real, en las que este algoritmo utiliza un conjunto de datos sobre la movilidad de los vehículos en una localización específica y puede de esta manera recomendar la ruta más eficiente para el conductor, siguiendo parámetros definidos previamente de forma autónoma y automática.

Clavell y Lorente Martínez (2022) proponen aplicar ese documento guía (Prospecto algorítmico de IA) para describir el funcionamiento detallado del sistema IA, utilizando unos apartados descriptivos: número de registro, detalles del modelo, objetivo y uso intencionado, factores, métricas, datos de evaluación, datos de entrenamiento, análisis cuantitativo y consideraciones éticas. El instrumento propuesto deberá acompañarse de una guía de uso con definiciones clave, ejemplos y otras instrucciones que faciliten su comprensión y aplicación dentro de una normativa de IA (Galdón Clavell & Lorente Martínez, 2022).

Tabla 3

Enfoque de regulaciones sobre la IA según países (fuente: de los autores)

Dominios IA	Unesco	OCDE	Cepal	BID
a) Marco legal y regulatorio	Estándar global IA	Panorama de políticas de IA	Índice Latinoamericano de Inteligencia Artificial, versiones 1 y 2. Es mejor regular riesgos y no la tecnología	Prospecto algorítmico de IA, en el marco regulatorio laboral
b) Ética y principios rectores	Valores y principios éticos clave para su desarrollo y uso	Mejorar el equilibrio entre la vida laboral y personal	La IA debe trabajarse de manera explícita en el marco de las políticas de desarrollo productivo de los países de la región y de sus territorios	Solventar la transparencia técnica de algoritmos dentro del contexto de una normativa general
c) Gobernanza y supervisión	Gobernanza de datos de los países miembros	Iniciativas de los gobiernos, sector privado, comunidades de investigación y sociedad civil	Reflexión, visión estratégica, regulación, coordinación regional y multilateral. Ausencia de una hoja de ruta y de estrategias sistemáticas y actualizadas para determinar nivel de madurez en la estrategia de IA de cada país	Prospecto algorítmico con definiciones clave, ejemplos e instrucciones dentro de una normativa IA
d) Protección de datos y privacidad			Recolección y disponibilidad de datos y minimizar potenciales amenazas	Contextos de desarrollo e implementación de sistemas automatizados IA
e) Evaluación de riesgos y seguridad		Mejorar el bienestar de las personas en áreas de la seguridad pública	Aprovechar oportunidades y minimizar sus potenciales amenazas en infraestructura, capital humano	Algoritmos considerados como de alto riesgo

(continúa)

(continuación)

Dominios IA	Unesco	OCDE	Cepal	BID
f) Auditorías y conformidad			Visión e institucionalidad, vinculación internacional y regulación. Índice IA con dimensiones, subdimensiones, indicadores y subindicadores	Prospecto algorítmico de IA con apartados descriptivos sobre su funcionamiento
g) Educación y formación	Cultura, la educación y la investigación. Adelantar diagnósticos médicos y ayudar en la investigación científica	Mejorar el bienestar de las personas en áreas de la educación y la salud	Formación de capital humano avanzado con la participación de personas con experiencias diversas	
h) Transparencia y responsabilidad			Data sets relevantes sin datos personales y cuestionarios se pueden compartir	Guía de uso con definiciones clave de algoritmos IA
i) Impacto social y económico	Usar la tecnología de manera respetuosa con los derechos humanos, de forma segura y sostenible	Aumentar la eficiencia y eficacia de sectores, incluida la prestación de servicios públicos	En áreas estratégicas y con participación ciudadana de sectores activos y rezagados	Impactos en el trabajo, salud, seguridad, educación, justicia criminal y servicios sociales
j) Cooperación internacional	Fortalecer el desarrollo y uso respetuoso con los derechos humanos, de manera segura y sostenible, y promover la paz		Necesidad de generar marcos interoperables y transfronterizos. Compartir estadísticas y espacios para construcción colectiva de políticas de IA	Desarrollo e implementación de sistemas automatizados

6. ESTUDIO DE CASO: LA IA EN COSTA RICA

En febrero de 2023, el gobierno de Costa Rica comenzó a desarrollar una base para su Estrategia Nacional de IA. Los objetivos y pilares propuestos están adaptados al contexto local y buscan orientar la construcción de una estrategia sólida, con un enfoque ético y responsable en el uso de la inteligencia artificial.

Paula Bogantes, jerarca del Ministerio de Ciencia y Tecnología MICITT, manifiesta:

Hemos apostado por grandes retos globales en una sociedad y economía basada en el conocimiento y gracias al apoyo de los distintos actores desde el Sistema

Nacional de Ciencia, Tecnología e Innovación se han generado diversas iniciativas, como el Plan Nacional de Ciencia, Tecnología e Innovación, incorporando las tecnologías digitales y las tecnologías emergentes como la inteligencia artificial. (MICITT, 2023b, p.1)

Con respecto a la formación en IA, el 8 de marzo del 2022 el Consejo Superior de Educación de Costa Rica aprobó el primer programa de estudios sobre inteligencia artificial dentro de la Educación Técnica Profesional (ETP). Estos colegios constituyen un pilar en la preparación de técnicos calificados para promover el desarrollo social y económico del país. La IA entraría a formar parte del repertorio de especialidades de estos colegios, desarrollando conocimientos, habilidades, destrezas, valores y capacidades actitudinales que facultan la formación del perfil de recurso humano que demanda el sector productivo, y la incorporación en puestos de trabajo sobre automatización de procesos y aprendizaje automático (Ministerio de Educación Pública de Costa Rica [MEP], 2008, Dirección de Educación Técnica y Capacidades Emprendedoras[DETCE], 2022; Picado, 2023).

Anna Katharina Müller, ministra de Educación Pública señaló al respecto:

Esta nueva especialidad técnica es respuesta a la demanda de nuevos perfiles profesionales que requiere el país y a las nuevas tendencias que hoy caracterizan el mercado de trabajo. La inteligencia artificial representa para Costa Rica y, en especial para nuestros jóvenes, una oportunidad para incrementar su competitividad, promover la innovación y la empleabilidad (DETCE, 2022, p. 1).

En noviembre del 2022, el Ministerio de Educación Pública y la empresa multinacional Intel de Costa Rica firmaron un convenio para apoyar y habilitar la especialidad de inteligencia artificial en los Colegios Técnico Profesionales, a fin de que la comunidad estudiantil aprenda sobre las implicaciones éticas y legales de esta tecnología, y se fomente el conocimiento y la promoción de una ciudadanía digital responsable (DPRP, 2022).

Timothy Scott Hall, director de asuntos gubernamentales de la empresa Intel de Costa Rica menciona que “el propósito de Intel es crear tecnología que mejore la vida de todas las personas del planeta (DPRP, 2022b, p. 1). Y añade: “apoyar al país en su ruta hacia una industria basada en el conocimiento es un compromiso que asumimos hace 25 años, cuando la empresa se estableció en Costa Rica, y este convenio es una muestra concreta de ello” (DPRP, 2022b, p. 1). En el año 2019 Intel desplegó el programa AI For Youth o Inteligencia artificial para jóvenes de entre 13 y 19 años, incluyendo los insumos para el diseño de los programas educativos, el desarrollo de material didáctico y los procesos de actualización docente en el tema de IA, así como el aprendizaje automático. Adicionalmente, los estudiantes del ciclo lectivo 2023 tendrían una beca para aprender inglés como segunda lengua. Vanessa Gibson de CINDE añadió, “en el horizonte también se nos plantea el reto de aprovechar todo el potencial de esta tecnología para alcanzar una participación equitativa e inclusiva con beneficios para la mayoría” (DPRP, 2022b, p. 1).

En marzo de 2024, coincidiendo con el Día Internacional de la Mujer, Intel presentó la iniciativa Mil Mujeres IA (M1000IA), cuyo propósito es empoderar a mil mujeres de América Latina mediante cursos especializados en inteligencia artificial. Esta iniciativa busca facilitar el acceso a la IA y su aplicación práctica en el ámbito laboral. Se ofrecerán cuatro cursos en línea, dirigidos a mujeres mayores de 18 años de Argentina, Colombia, Costa Rica, México y Uruguay. Los cursos, financiados por Intel, tendrán una duración de doce semanas y otorgarán un certificado de la Universidad Tecnológica Nacional de Argentina (UTN) (MICITT, 2023a, 2024).

En agosto de 2023, el Ministerio de Ciencia, Innovación, Tecnología y Telecomunicaciones (MICITT), en colaboración con el Instituto Nacional de Aprendizaje (INA), lanzó el programa “Crear e implementar inteligencia artificial en su negocio”, como parte de la creación de la estrategia nacional de IA. Este programa está diseñado para fortalecer las capacidades en la adopción de la IA, con el objetivo de mejorar la productividad y competitividad de las pequeñas y medianas empresas (pymes). Orlando Vega, viceministro del MICITT, destacó que se capacitarán a cuarenta empresas que cumplan con tres años de operación, proporcionando asesoría personalizada para desarrollar herramientas basadas en IA y así aumentar sus oportunidades de internacionalización (MICITT, 2023c).

En abril de 2024, Costa Rica se convirtió en el escenario de discusiones estratégicas con la visita de Gina Raimondo, Secretaria de Comercio de Estados Unidos. Durante su reunión con líderes del sector privado y funcionarios gubernamentales, se llevó a cabo un diálogo de alto nivel sobre el centro de excelencia en Costa Rica. Esta iniciativa, respaldada por el Gobierno de Estados Unidos y la Unión Europea, tiene como objetivo desarrollar talento especializado en áreas STEM y capacitar a profesionales en sectores clave como ciberseguridad, 5G/6G, semiconductores, computación en la nube, realidad aumentada/virtual e inteligencia artificial (OECD, 2018; Revista Summa, 2024).

7. RESULTADOS

Se hace evidente la aceleración que están haciendo los países en cuanto a la formación, incorporación y desarrollo de nuevas tecnologías. Sin embargo, los gobiernos y organizaciones deben ocuparse prontamente en elaborar una normativa, así como una serie de regulaciones —en especial sobre la IA—, puesto que sin estas reglas efectivas existe el riesgo de que la adopción de IA cree nuevas desigualdades y amplíe las ya existentes.

Contar con una normativa sobre la IA permite que la tecnología se utilice en beneficio de la sociedad en su conjunto, con la consideración de adaptar efectivamente dichas regulaciones hacia lo interno de las organizaciones y gobiernos y, de esta forma, acompañar la evolución constante, ser parte de un cambio seguro, proactivo y no reactivo, y minimizar los impactos negativos de la IA.

A partir de los análisis y el resumen de las tablas presentadas anteriormente, se extraen las consideraciones clave y se muestran los resultados en una tabla de análisis FODA (nomenclatura de Fortalezas, Oportunidades, Debilidades y Amenazas) como guía base para elaborar marcos de normativas y regulaciones sobre la IA.

Tabla 4

Resumen de análisis FODA para elaborar una normativa sobre IA

Fortalezas	Dominios IA	Temas a considerar para una normativa sobre IA
	Marco legal y regulatorio	<p>Establecer un marco legal sólido de IA que proporcione claridad regulatoria de la IA.</p> <p>Incorporar el Índice Latinoamericano de Inteligencia Artificial como referencia.</p> <p>Prospecto algorítmico como directriz para el desarrollo ético de sistemas IA.</p> <p>Definir regulaciones sobre la IA para aumentar la eficiencia y eficacia de sectores enteros, incluida la prestación de servicios públicos, mejora en la educación y la salud.</p>
	Ética y principios rectores	<p>Enfoque equilibrado entre vida laboral y personal.</p> <p>Marco ético que considere el impacto cultural y social.</p> <p>Inclusión de principios humanos como empatía, juicio y justicia de manera responsable, segura y alineada con los valores humanos.</p>
	Gobernanza y supervisión	<p>La adopción de un enfoque <i>centrado en lo humano</i>. Niveles de madurez de IA determinados para una implementación responsable.</p> <p>Coordinación regional y multilateral para una visión estratégica con el potencial para convertir el país en carbono neutral usando la tecnología IA.</p>
Oportunidades	Dominios IA	Temas a considerar para una normativa sobre IA
	Protección de datos y privacidad	<p>Uso amplio de la tecnología de IA.</p> <p>Consideración de aspectos positivos y controversiales sobre la privacidad y minimización de amenazas potenciales.</p> <p>La innovación en IA puede mejorar la protección de la privacidad y la seguridad de los datos.</p>
	Evaluación de riesgos y seguridad	<p>Identificación de riesgos y seguridad para una implementación segura.</p> <p>Evaluación del impacto sobre los derechos fundamentales.</p> <p>Sistemas IA con riesgo significativo sometidos a evaluaciones detalladas.</p> <p>El potencial de la IA permite aumentar la eficiencia y eficacia, reduciendo los riesgos en la seguridad pública y la salud.</p>
	Auditorías y conformidad	<p>Establecer mecanismos de rendición de cuentas mediante diálogo entre partes interesadas.</p> <p>Fortalecer la transparencia en la implementación y el desarrollo de la IA buscando el equilibrio entre la vida laboral y personal.</p> <p>Enfoque de rendición de cuentas y promoción del <i>no daño</i> al usar la IA.</p>

(continúa)

(continuación)

Oportunidades	Dominios IA	Temas a considerar para una normativa sobre IA
	Educación y formación	Formación en cualidades humanas para un uso equitativo de la IA. Promoción de la investigación y desarrollo en IA preparando a la fuerza laboral, al Gobierno y a las empresas para el futuro. Necesidad de sensibilización y promoción para aprovechar el potencial del talento humano.
	Transparencia y responsabilidad	Consideración de múltiples partes interesadas para abordar temas políticos y regulatorios. Enfoque en igualdad de género en la implementación de IA. Necesidad de que la inteligencia artificial se trabaje de manera explícita y deliberada en el marco de las políticas de desarrollo productivo de los países.
Debilidades	Dominios IA	Temas a considerar para una normativa sobre IA
	Impacto social y económico	Desafíos en la incorporación efectiva de aplicaciones de IA en áreas socioeconómicas. Posible obstáculo de regulación para el desarrollo tecnológico e industrial. Altos costos de generar estadísticas y poca coordinación para compartir datos regionalmente.
Amenazas	Dominios IA	Temas a considerar para una normativa sobre IA
	Cooperación internacional	Incertidumbre en el impacto de la IA en la sociedad y economía. La incertidumbre puede generar miedo, desconfianza y resistencia hacia la adopción de la IA, incluso obstaculizando el desarrollo de esta tecnología. No hay una posición del Gobierno o la sociedad para abordar temas complejos y políticos a nivel internacional. Dificultad para generar marcos interoperables y transfronterizos entre países. No poder compartir estadísticas ni crear espacios para construcción colectiva de políticas de IA.

8. CONCLUSIONES

La inteligencia artificial es una tecnología transformadora y disruptiva con un impacto significativo en la sociedad y la economía. En este artículo se han mostrado elementos relevantes que sirven de base para elaborar un compendio de regulaciones para la promoción y adopción de la IA, tanto para los gobiernos como para las organizaciones privadas. El primer Índice Latinoamericano de Inteligencia Artificial (ILIA), desarrollado por la Cepal, y su segunda actualización, proveen herramientas válidas que miden el estado actual del país con respecto a la planificación, gobernanza y aplicación de la IA. Se pretende que estas herramientas, junto con los elementos clave de los organismos Unesco, OCDE, Cepal y BID, las regulaciones de la Unión Europea, Estados Unidos y República Popular China, así como la iniciativa de una estrategia IA para Costa Rica,

contribuyan a la transformación de los modelos de desarrollo en América Latina y el Caribe, para hacerlos más productivos, inclusivos y sostenibles.

Sin embargo, para aprovechar las oportunidades y minimizar las potenciales amenazas que esta tecnología trae consigo, se requiere de reflexión, visión estratégica, regulación y coordinación regional y multilateral para generar planes estratégicos de IA, preferiblemente medidos con el indicador ILIA. Todo esto para apoyar el desarrollo y la implementación transparente de una normativa coherente y efectiva en marcos regulatorios y legales, los cuales —además— deben ser interoperables y transfronterizos y deben promover la colaboración y consensos con otros países.

Por el lado de la academia en su rol de formación, se deben reforzar los planes y programas curriculares incorporando habilidades y competencias en IA, junto con un enfoque sobre la ética como elemento fundamental para que los alumnos comprendan el uso justo y responsable de esta tecnología.

Las pautas analizadas en este artículo pueden servir de base para normar y gestionar la IA, así como para adoptarla y usarla de manera responsable en beneficio de la sociedad, salvaguardando principalmente los valores éticos y garantizando que la tecnología continúe siendo una fuerza positiva en nuestra sociedad.

Contar con una regulación adecuada no solo protege los derechos y valores, sino que también promueve la confianza en la IA como una herramienta tecnológica que se puede introducir en la sociedad con el objeto de mejorar nuestras vidas de manera significativa.

Se recomienda al lector que utilice todas las tablas con las consideraciones clave, y también el resumen de análisis FODA como referencia para el desarrollo de otras investigaciones, pero en especial para coadyuvar en la elaboración de marcos normativos y regulatorios sobre IA —ya sea a nivel de PYME o empresa individual, a nivel empresarial o a nivel país—, pero también con el propósito de apoyar en el diseño de guías curriculares, talleres y cursos de formación que incorporen aspectos técnicos y éticos de la inteligencia artificial.

REFERENCIAS

- Baiocchi, A. & Leicht, A. (2023, 12 de abril). Inteligencia artificial en Costa Rica: justicia, ética e inclusión para no dejar a nadie atrás. Unesco. <https://www.unesco.org/es/articulos/inteligencia-artificial-en-costa-rica-justicia-etica-e-inclusion-para-no-dejar-nadie-atras>
- Burt, A. (2021, 30 de abril). New AI regulations are coming. Is your organization ready? *Harvard Business Review*. <https://hbr.org/2021/04/new-ai-regulations-are-coming-is-your-organization-ready>

- Cain, L. & Webster, C. (2022, 2-7 noviembre). *The origin, rationale, and impacts of regulations on robots and AI in tourism and hospitality* [Presentación de escrito]. International Conference on Innovation, Documentation and Education, INNODOCT/22, Valencia, 111–118. <https://doi.org/10.4995/inn2022.2022.15978>
- Comisión Económica para América Latina y el Caribe (2023, 11 de agosto). *La inteligencia artificial puede contribuir a la transformación de los modelos de desarrollo en América Latina y el Caribe para hacerlos más productivos, inclusivos y sostenibles*. [https://www.cepal.org/es/comunicados/la-inteligencia-artificial-puede-contribuir-la-transformacion-modelos-desarrollo-america#:~:text=La%20inteligencia%20artificial%20\(IA\)%20puede,se%20requiere%20reflexi%C3%B3n%2C%20visi%C3%B3n%20estrat%C3%A9gica%2C](https://www.cepal.org/es/comunicados/la-inteligencia-artificial-puede-contribuir-la-transformacion-modelos-desarrollo-america#:~:text=La%20inteligencia%20artificial%20(IA)%20puede,se%20requiere%20reflexi%C3%B3n%2C%20visi%C3%B3n%20estrat%C3%A9gica%2C)
- Comisión Económica para América Latina y el Caribe (2024, 24 de setiembre). *Lanzamiento de la segunda versión del “Índice Latinoamericano de Inteligencia Artificial (ILIA)”*. <https://www.cepal.org/es/eventos/lanzamiento-la-segunda-version-indice-latinoamericano-inteligencia-artificial-ilia>
- Chatterjee, S. (2020). Impact of AI regulation on intention to use robots: From citizens and government perspective. *International Journal of Intelligent Unmanned Systems*, 8(2), pp. 97-114.
- Cuéllar, M. F., Larsen, B., Lee, Y. S., & Webb, M. (2024). Does information about AI regulation change manager evaluation of ethical concerns and intent to adopt AI? *Journal of Law, Economics, and Organization*, 40(1), 34-75. <https://doi.org/10.1093/jleo/ewac004>
- Dirección de Educación Técnica y Capacidades Emprendedoras. (2022). Programa de estudio Inteligencia Artificial. Ministerio de Educación Pública de Costa Rica. <https://www.mep.go.cr/sites/default/files/2024-03/inteligenciaartificial12.pdf>
- Dirección de Prensa y Relaciones Públicas. (2022b, 24 de noviembre). Convenio entre MEP e Intel Costa Rica habilitará la especialidad de inteligencia artificial en colegios técnico-profesionales el otro año. Ministerio de Educación Pública de Costa Rica. <https://www.mep.go.cr/noticias/convenio-mep-e-intel-costarica-habilitara-especialidad-inteligencia-artificial-colegios-te>
- Dumouchel, P. (2023). AI and regulations. *AI*, 4(4), 1023-1035. <https://doi.org/10.3390/ai4040052>
- Ferreira Beni, P., Barone, D. A., & De Ortúzar, M. (2023, 13-17 noviembre). *Cuestiones éticas sobre la Inteligencia Artificial en la educación* [Ponencia]. Semana de la Filosofía, La Plata, Argentina. https://www.memoria.fahce.unlp.edu.ar/trab_eventos/ev.17321/ev.17321.pdf
- Franks, E., Lee, B., & Xu, H. (2024). Report: China’s new AI regulations. *Global Privacy Law Review*, 5(1), 43-49. <https://doi.org/10.54648/gplr2024007>

- Galdón Clavell, G. & Lorente Martínez, A. (2022). *Hacia un prospecto en el marco regulatorio laboral en Argentina. Análisis tecnológico, marco regulatorio y buenas prácticas*. CIPPEC; Éticas; BID Lab Buenos Aires. <https://publications.iadb.org/es/hacia-un-prospecto-en-el-marco-regulatorio-laboral-en-argentina-analisis-tecnologico-marco>
- Gstrein, O. J. (2022). European AI regulation: Brussels effect versus human dignity? *Zeitschrift Für Europarechtliche Studien*, 25(4), 755-772. <https://doi.org/10.5771/1435-439X-2022-4-755>
- Katulić, T. (2020). Towards the trustworthy AI: Insights from the regulations on data protection and information security. *Media Research: Croatian Journal for Journalism and the Media*, 26(2), 9-28.
- Khairo, F., & Busroh, F. F. (2023). Harnessing the power of AI in shaping administrative law regulations. *International Journal of Science and Society*, 5(4), 617-625 <https://doi.org/10.54783/ijssoc.v5i4.826>
- Konttila J. & Väyrynen, K. (2022). Challenges of current regulation of AI-based healthcare technology (AIHT) and potential consequences of the European AI Act proposal. En Fischer, L. H., Nørbjerg, J., & Pries-Heje, J. (Eds.) *Proceedings of the 13th Scandinavian Conference on Information Systems*. Association for Information Systems (AIS). Proceedings / Information Systems Research In Scandinavia (IRIS) <https://aisel.aisnet.org/scis2022/7>
- Martínez, M. V. (2024). *De qué hablamos, cuando hablamos de inteligencia artificial*. Oficina Regional de Unesco en Montevideo; Consejo Latinoamericano de Ciencias Sociales. <https://unesdoc.unesco.org/ark:/48223/pf0000391087>
- Ministerio de Educación Pública de Costa Rica (2008). *El centro educativo de calidad como eje de la educación costarricense*. <https://ruie.ucr.ac.cr/catalogo/Record/INIE-UIR-CD-1909?sid=859603>
- Ministerio de Ciencia, Innovación, Tecnología y Telecomunicaciones (2023a, 20 de febrero). MICITT e Intel unen esfuerzos para capacitar a estudiantes fuera de GAM sobre inteligencia artificial. <https://www.micitt.go.cr/el-sector-informa/micitt-e-intel-unen-esfuerzos-para-capacitar-estudiantes-fuera-de-gam-sobre>
- Ministerio de Ciencia, Innovación, Tecnología y Telecomunicaciones (2023b). MICITT inicia formulación de estrategia de inteligencia artificial. <https://www.micitt.go.cr/el-sector-informa/micitt-inicia-formulacion-de-estrategia-de-inteligencia-artificial>
- Ministerio de Ciencia, Innovación, Tecnología y Telecomunicaciones (2023c, 9 de agosto). PYMEs y PYMPAs aplicarán herramientas de Inteligencia Artificial para mejorar competitividad de sus negocios gracias a Plan Piloto. <https://www.micitt.go.cr/el-sector-informa/>

pymes-y-pympas-aplicaran-herramientas-de-inteligencia-artificial-para-mejorar

- Ministerio de Ciencia, Innovación, Tecnología y Telecomunicaciones (2024, 8 de marzo). Intel entrenará a 1000 mujeres en inteligencia artificial en América Latina. <https://www.micitt.go.cr/el-sector-informa/intel-entrenara-1000-mujeres-en-inteligencia-artificial-en-america-latina>
- Nitzberg, M., & Zysman, J. (2022). Algorithms, data, and platforms: the diverse challenges of governing AI. *Journal of European Public Policy*, 29(11), 1753-1778. <https://doi.org/10.1080/13501763.2022.2096668>
- Novelli, C., Casolari, F., Rotolo, A., Taddeo, M. & Floridi, L. (2024). Taking AI risks seriously: a new assessment model for the AI Act. *AI & Society*, 39, 2493-2497. <https://doi.org/10.1007/s00146-023-01723-z>
- OECD. (2018). AI: Intelligent machines, smart policies: Conference summary. *OECD Digital Economy Papers*, 270, 1–33. <https://doi.org/10.1787/f1a650d9-en>
- Picado, N. (2023, 16 de mayo). Directores de colegios técnicos analizan oferta técnica del MEP y el futuro de la especialidad. Ministerio de Educación Pública de Costa Rica. <https://www.mep.go.cr/noticias/directores-colegios-tecnicos-analizan-oferta-tecnica-mep-futuro-especialidad>
- Pichai, S. (2018, 7 de junio). AI at Google: our principles. *The Keyboard*. <https://blog.google/technology/ai/ai-principles/>
- Pownall, C. (2019, 2 de julio). Understanding the reputational risks of AI. *Charlie Pownall. Reputation Management and Communications*. <https://charliepownall.com/?s=Understanding+the+reputational+risks+of+AI>
- Revista Summa. (2024, 1 de abril). *Autoridades sostienen diálogo clave con EE.UU. para crear Centro de Excelencia en Costa Rica*. <https://revistasumma.com/autoridades-sostienen-dialogo-clave-con-ee-uu-para-crear-centro-de-excelencia-en-costa-rica/>
- Schuett, J. (2023). Defining the scope of AI regulations. *Law, Innovation and Technology*, 15(1), 60-82. <https://doi.org/10.1080/17579961.2023.2184135>
- Sheehan, M. (2023). *China's AI Regulations and How They Get Made*. Carnegie Endowment for International Peace. <https://carnegieendowment.org/research/2023/07/chinas-ai-regulations-and-how-they-get-made?lang=en>
- Soto Arriaza, Á., & Durán Rojas, R. (2024). *Índice latinoamericano de inteligencia artificial 2023*. Centro Nacional de Inteligencia Artificial. <https://centrodepensamientodigital.org/wp-content/uploads/2024/03/1.-Indice-Latinoamericano-de-IA-ILIA-2023.pdf>

- Stahl, B. C., Rodrigues, R., Santiago, N., & Macnish, K. (2022). A European agency for artificial intelligence: Protecting fundamental rights and ethical values. *Computer Law and Security Review*, 45, 105661. <https://doi.org/10.1016/j.clsr.2022.105661>
- Tallberg, J., Lundgren, M., & Geith, J. (2024). AI regulation in the European Union: examining non-state actor preferences. *Business and Politics*, 26(2), 218-239, <https://doi.org/10.1017/bap.2023.36>
- Truby, J., Brown, R., & Dahdal, A. (2020). Banking on AI: mandating a proactive approach to AI regulation in the financial sector. *Law and Financial Markets Review*, 14(2), 110-120. <https://doi.org/10.1080/17521440.2020.1760454>
- Unesco (2024). Diálogo político sobre la gobernanza de la IA. <https://www.unesco.org/es/articulos/dialogo-politico-sobre-la-gobernanza-de-la-ia>

LATTICE-BASED CRYPTOGRAPHY: DEVELOPMENT AND ANALYSIS OF A NEW VARIANT OF THE CRYSTALS-KYBER ALGORITHM

MAURICIO SEBASTIAN CISNEROS LAULE
smlaulet@gmail.com
<https://orcid.org/0009-0007-4056-4467>
Universidad de Lima, Peru

JAVIER ENRIQUE OLAZABAL SILVA
javierenriqueos@gmail.com
<https://orcid.org/0009-0003-2728-8614>
Universidad de Lima, Peru

HERNAN NINA HANCO
hninaha@ulima.edu.pe
<https://orcid.org/0000-0003-0230-5812>
Universidad de Lima, Peru

Received: September 8th, 2024 / Accepted: October 12th, 2024
doi: <https://doi.org/10.26439/interfases2024.n020.7383>

ABSTRACT. The imminent arrival of quantum computing has accelerated the need for cryptographic systems resistant to quantum attacks. Such attacks exploit the vulnerability in private and public key encryption systems, where the public key is derived from the private key, which could be refactored from the public key. To address this issue, the National Institute of Standards and Technology (NIST) launched a global competition in 2016 to create quantum-resistant algorithms. CRYSTALS-Kyber, a lattice-based algorithm focused on the learning with errors (LWE) problem, was selected for standardization. This work introduces RKyber, a variant that instead targets the learning with rounding (LWR) problem, simplifying computations by using deterministic errors rather than random noise. Both algorithms were executed 1000 times, showing that RKyber offers improved speed at the cost of some security.

KEYWORDS: post-quantum / lattice-based / quantum computing / Kyber / quantum cryptanalysis

CRİPTOGRAFÍA BASADA EN RETÍCULAS: DESARROLLO Y ANÁLISIS DE UNA NUEVA VARIANTE DEL ALGORITMO CRYSTALS-KYBER

RESUMEN. La inminente llegada de la computación cuántica ha hecho necesario el desarrollo de sistemas criptográficos resistentes a los ataques cuánticos. Los ataques cuánticos explotan la debilidad de la encriptación de llave pública y privada, la cual radica en que la llave pública es derivada desde la llave privada y esta última podría ser factorizada a partir de la llave pública. En respuesta, el NIST inició un concurso mundial en 2016 para crear algoritmos resistentes a la computación cuántica. CRYSTALS-Kyber, un algoritmo basado en celosía que aborda el problema de Aprendizaje con Errores fue seleccionado para su estandarización. Este trabajo introduce una variante, RKyber, que en su lugar aborda el problema de Aprendizaje con Redondeo, simplificando los cálculos mediante el uso de errores deterministas en lugar de ruido aleatorio. Ambos algoritmos se ejecutaron 1000 veces, demostrando que RKyber es más rápido, aunque sacrifica algo de seguridad.

PALABRAS CLAVE: poscuántico / basado en retículas / computación cuántica / Kyber / criptoanálisis cuántico

INTRODUCTION

This paper aims to research and demonstrate a modification to the fundamental problem solved by the Kyber algorithm. Presenting this research is important, as it explores the ramifications derived from modifying the system's core problem from learning with errors (LWE) to learning with rounding (LWR). Quantum computing is widely recognized as a threat to most cryptosystems in use today and LWR is known to be computationally comparable to LWE, meaning that breaking the encryption of one should be as challenging as decrypting the other. However, no research has specifically addressed this modification within the newly standardized CRYSTALS-Kyber algorithm. This knowledge gap has therefore been selected as a focal point for this study.

This paper provides the necessary background to understand the topic, as well as the algorithmic demonstration and brute-force tests conducted on the modified algorithm named RKyber (short for "Rounded Kyber"). The first section covers the theoretical framework, establishing the essential background. This is followed by a description of the methodology and experimental design. The final sections discuss the experimental results, provide a brief analysis, and present the final conclusions of the research.

BACKGROUND

2.1 Quantum Computing

Quantum computing is a paradigm that has seen recent advancements at the hardware level, though research in this field has been ongoing for about 50 years. It began with Stephen Wiesner's concept of conjugate coding (Mor & Renner, 2014), a system in which multiple messages were transmitted, but reading one would destroy the others. In the following years, Benioff (1980) described the Turing machine using Schrödinger's equation and created a model for a quantum computer in 1982 (Mor & Renner, 2014). Based on this model, mathematician Peter Shor and computer scientist Lov Grover each developed a famous algorithm: Shor's algorithm, which uses quantum Fourier transform (QFT) to break many current encryptions (Shor, 1997), and Grover's algorithm, which significantly accelerates database searches (Grover, 1996).

The basis of this paradigm is the qubit, which primarily focuses on superposition and error correction. Superposition allows a single qubit to represent two values at the same time. As shown in Figure 1, qubits are represented on "Bloch spheres," with two opposing poles corresponding to "1" or "0" and a vector pointing to an arbitrary position on the sphere. Depending on the vector's direction, there is a higher or lower probability of receiving a "1" or "0" when measuring the qubit. This probability distribution must follow the linear equation presented in Equation (1):

$$|\psi\rangle = \alpha|0\rangle + \beta|1\rangle \quad (1)$$

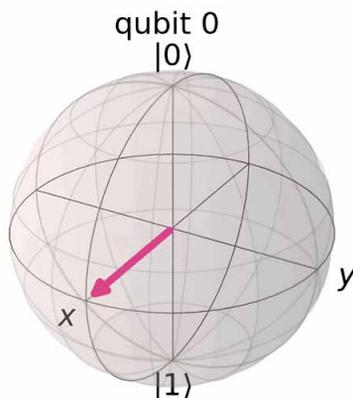
Where ψ is the probability column vector and must meet the limits of Equation (2):

$$|\alpha|^2 + |\beta|^2 = 1 \quad (2)$$

Where α represents the probability of a 0 measurement and β a 1 measurement.

Figure 1

Representation of a Qubit with a Bloch Sphere



The goal of this technology is to enhance processes currently considered efficient, surpassing the limits known in classical computing. Aaronson and Chen’s (2017) complexity theory discuss the concept of quantum supremacy, which is expected to be achieved soon, especially in the field of cryptography. In response to this, algorithms designed to resist the impending threat of quantum computing have been developed. One of these resistant algorithms or “post-quantum” cryptographic algorithms is the CRYSTALS-Kyber algorithm, which has successfully passed numerous tests and is on the path toward standardization by the National Institute of Standards and Technology (NIST) (Avanzi et al., 2021). This algorithm addresses the LWE problem, which is based on the difficulty of solving linear equations in a finite field with noise (Peikert, 2016; Lyubashevsky et al., 2010).

2.2 Lattice-Based Identity

The lattice-based family of algorithms focuses on addressing specific problems that define their particularities, namely the closest vector problem (CVP), shortest vector problem (SVP), and shortest independent vector problem (SIVP). All solutions to these problems are considered during the generation of vector sets used to create points within the finite field containing all lattices (Peikert, 2016). Lattices are defined as a discrete subgroup L of \mathbb{R}^n , where L contains the linear combination of vectors, as seen in Equation (3):

$$av_1 + bv_2 + \dots + kv_n \quad \text{with} \quad a, b, \dots, k \in \mathbb{Z} \wedge v_1, v_2, \dots, v_n \in L \quad (3)$$

The base of the lattice is usually represented in the form shown in Equation (4):

$$\sum_{i=1}^r a_i v_i \quad a_i \in \mathbb{Z} \quad (4)$$

Where r refers to the rank or dimension of the lattice. If r equals the dimension n , it is considered a full-rank lattice (Micciancio & Goldwasser, 2002). This definition is represented with a matrix V that generalizes the dimensional vectors, as shown in Equation (5):

$$V \in R^{n \times r}, L = \{Vx, x \in \mathbb{Z}^r\} \quad (5)$$

In this context, Vx represents the linear combination of vectors generating points collectively known as a lattice. These combinations are the solutions provided by the algorithms for the presented problems. From a cryptographic perspective, these solutions are used to encrypt and send messages. During this process, two sets of vectors of the same rank are generated, and their linear combination creates the same points in a given space. One set is designated as the public key and the other as the private key. The private key will have a combination that is easier to calculate to reach a point i , and it should only be accessible to the user (Micciancio & Goldwasser, 2002).

This public-private key cryptographic method is used in message exchange. When user A sends a message to user B, user A employs user B's public key to encrypt the message, allowing user B to decrypt it with their own private key. In lattice-based cryptography, the message is assigned by user A employing user B's public key to a point in the subgroup L_B (Lyubashevsky et al., 2010).

2.3 CRYSTALS-Kyber – Key Generation

The Kyber algorithm utilizes vector principles. A relatively simple base vector is used as the private key s and a derived public key t . Public key generation requires a matrix of random polynomials A of the same dimension as the private key and an error vector e (Avanzi et al., 2021). This error vector is the proposed solution to the LWE problem. They are defined as shown in Equation (6):

$$s = (a_n x^n + a_{n-1} x^{n-1} + \dots + a_0; b_n x^n + b_{n-1} x^{n-1} + b_0; k_n x^n + k_{n-1} x^{n-1} + \dots + k_0) \quad (6)$$

Where the coefficients a, b, \dots, k belong to the integers in dimension n (\mathbb{Z}^n). Likewise, the matrix A is defined as shown in Equation (7):

$$A = \begin{pmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \dots & a_{nn} \end{pmatrix}, a_n m = bx^n + cx^{n-1} + \dots + zx^0, b, c, \dots, z \in \mathbb{Z}^n \quad (7)$$

The error vector e is defined in the form shown in Equation (8):

$$e = (ax^n + b^{n-1} + \dots + k), a, b, \dots, k \in Z^n \quad (8)$$

This results in the derivation of the public key vector t , defined in Equation (9):

$$t = As + e \quad (9)$$

The key generation algorithm works as shown in Algorithm 1, where coefficients a are restricted to values between -3 and 3, and the parameter q is the commonly used modulo 3329 (Avanzi et al., 2021).

Algorithm 1: Key Generation

1. Start
 2. Generate key s
 3. $S = a_i x^n + a_{i-1} x^{n-1} + \dots + a_1 x^0$ where $a_i \in [-3,3]$
 4. Assign value to q
 5. $q = 3329$
 6. Generate matrix A
 7. $A = [a_{11}(X) \ a_{21}(X) \ \dots \ a_{nn}(X)]$
 8. Generate public key t
 9. $T = As + e$
 10. Return (s, t, A)
 11. End
-

2.4 CRYSTALS-Kyber – Encryption

The encryption method of the Kyber algorithm works as follows. A random vector of polynomials r is generated, matching the dimension of the previous keys, along with two error vectors, e_1 and e_2 . The polynomials in these vectors are relatively small, similar to the vector s (Avanzi et al., 2021). For encryption, the message is transformed into its binary representation, where each bit n of the message is used as a coefficient, as shown in Equation (10):

$$m_b = n_1 x^k + \dots + n_i, n \in \{1; 0\} \quad (10)$$

The polynomial presented in Equation (11) is multiplied by the nearest integer to the quotient, resulting in the polynomial m . This polynomial m is then encrypted using the public key (A, t) , resulting in the values (u, v) .

$$m = m_b \cdot \frac{q}{2} \quad (11)$$

Where the polynomial u is defined as shown in Equation (12):

$$u = A^T r + e_1 \quad (12)$$

And the polynomial v is defined in Equation (13):

$$v = t^T r + e_2 + m \quad (13)$$

The encryption process is demonstrated in Algorithm 2. This algorithm first asks whether the input value is a string or an integer. A constant n , which in this case is the dimension used for encryption, is assigned a value of 256 (Avanzi et al., 2021).

Algorithm 2: Encryption

1. Start
 2. Input value x to encrypt
 3. If x is integer:
 4. Transform it to binary value $(x)_{10} = (x)_2$
 5. With $(x)_2 : m_b = P(x) = b_n x^n + b_{n-1} x^{n-1} + \dots + b_0 x^0$ where $b_n \in \{0,1\}$
 6. $m = m_b * \frac{q}{2}$
 7. Else if x is string:
 8. Transform to binary value $(x) = (x)_2$
 9. If elements in $(x)_2 > n$:
 10. Create blocks where the elements of $(x)_2 \leq n$ where $n = 256$ and add to list L
 11. Generate random vector (r)
 12. Calculate values u, v :
 13. $u = A^T r + e_1$
 14. $v = t^T r + e_2 + m$
 15. Return (u, v)
 16. End
-

2.5 CRYSTALS-Kyber – Decryption

The decryption method uses the private key s and the resulting polynomials (u, v) . The remainder will be called m_n , which will be noisy due to the error vectors generated in the previous steps that modify the result. The resulting coefficients in m_b are compared with the value of $q/2$, and if a coefficient is closer to this value, it will be replaced with it. If it is closer to 0 or q , it will be replaced with 0. The result is then divided by $q/2$, and the coefficients become the original bits of the sent message (Avanzi et al., 2021). See Equation (14):

$$m_n = v - s^T u \quad (14)$$

Expanding the result, m_n is presented in Equation (15):

$$m_n = e^T r + e_2 + m + s^T e_1 \quad (15)$$

Finally, the coefficients n_k make up the sent message, represented by its bits, as shown in Equation (16):

$$m_b = \frac{1}{\frac{q}{2}} (n_1 x^n + n_2 x^{n-1} + \dots + n_k x^0) , n_k \in \left\{ 0; \frac{q}{2} \right\} \quad (16)$$

The decryption process is demonstrated in Algorithm 3 where the conditional executes for each coefficient i on the noisy value m_n . Finally, it returns the *res* which would be the original encrypted message (Avanzi et al., 2021).

Algorithm 3: Decryption

1. Start
 2. Input values to decrypt (u, v)
 3. Calculate noisy value
 4. $m_n = v - s^t u$
 5. For each coefficient (i) of m_n :
 6. If $\left| i - \frac{q}{2} \right| < |i - q|$ o $\left| i - \frac{q}{2} \right| < |0 - i|$:
 7. Then $i = \frac{q}{2}$
 8. Else:
 9. Then $i = 0$
 10. Calculate original value:
 11. $res = m_b * \frac{1}{\frac{q}{2}}$
 12. Return *res*
 13. End
-

The CRYSTALS-Kyber algorithm addresses the LWE problem from the lattice-based algorithm family. Additionally, there is a main extension to this problem known as LWR (Alwen et al., 2013). The main difference between the LWR and LWE cryptosystems is shown in Equation (9). The lack of the error vector and the addition of the parameter p results in a key as shown in Equation (17):

$$t = \begin{bmatrix} p \\ q \end{bmatrix} As \tag{17}$$

The cryptosystem built around the LWR problem assumes that the complexity of reducing the quotient product of the parameters p and q , matrix A , and vector s is sufficient to withstand quantum attacks. Therefore, the error vector can be removed without compromising security (Alwen et al., 2013).

2.6 LWE, LWR, and Reverse Engineering Methodology

The LWE problem enhances encryption security by adding pseudo-random noise to polynomial rings, making it challenging to solve without the private key. In contrast, LWR simplifies the process by removing random noise and using deterministic rounding errors, which makes the algorithm more efficient while maintaining security (Lyubashevsky et al., 2010; Regev, 2005). If the ratio between p and q is large enough, LWR provides computational improvements without significantly compromising the security.

In 2024, researchers from NTT DATA demonstrated a reverse engineering attack on algorithms like Kyber. Their method reduces the number of polynomial calculations by exploiting known public key parameters and minimizing the possible values of the

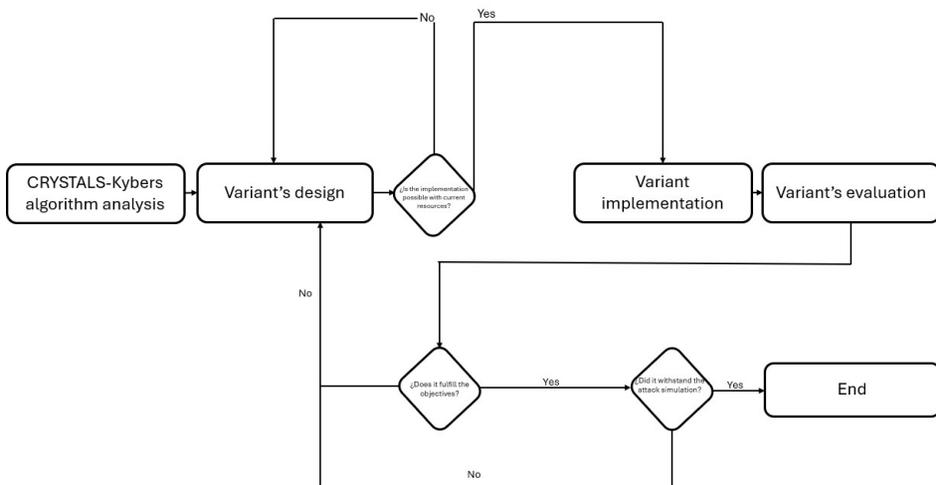
error vector (NTT DATA Perú, 2024). Using regression and projection techniques, this approach estimates private key values based on the time taken to break the encryption. Although not a direct attack on the encryption itself, this method narrows down potential key values by limiting the error vectors to a few discrete options, thereby speeding up brute-force attacks.

3. METHODOLOGY

The methodology follows the structured process shown in Figure 2. First, the CRYSTALS-Kyber algorithm was analyzed to identify areas suitable for modification. After validating the resources, a prototype of the variant was designed and implemented. The final step involved executing brute-force attacks to evaluate the security of both the original algorithm and its variant.

Figure 2

Methodology Followed in the Development of the RKyber Variant



3.1 CRYSTALS-Kyber Algorithm Analysis

To start, an analysis of the original CRYSTALS-Kyber algorithm was conducted to identify specific areas requiring modification in order to achieve the proposed variant design. The algorithm presented in the previous section consists of multiple steps to accomplish its task of protecting messages. For simplification, these steps are divided into three methods. The first method involves generating public and private keys, the second handles encryption, and the third manages decryption (Avanzi et al., 2021).

The authors of the algorithm propose a security solution that addresses the LWE problem (Avanzi et al., 2021). This involves adding noise or errors to a point or lattice

within the discrete group L . In this case, the researchers added random error vectors e , e_1 , and e_2 across the different methods. These error vectors add security by slightly obfuscating the encrypted message (Avanzi et al., 2021; Lyubashevsky et al., 2010), but they also increase the computational cost and, consequently, the execution time. It should be noted that these vectors create small and controlled errors, meaning that if the algorithm's steps are followed, the message will never be lost during execution.

3.2 Variant Design and Implementation

The proposed variant involves taking the base algorithm and addressing another problem from the lattice-based family. While the CRYSTALS-Kyber algorithm solves the LWE problem (Wei et al., 2023), this variant focuses on addressing its extension, LWR (Alwen et al., 2013). The LWR problem centers around the idea that the security provided by polynomial vectors in key creation is sufficient, and that the additional computational cost introduced by polynomial error vectors can be reduced by replacing them with deterministic errors generated by the parameters p and q (Alwen et al., 2013). As a result, the following equations were modified to remove the error vectors. Equation (9) takes the form presented in Equation (18):

$$t = \left[\begin{array}{c} p \\ q \end{array} As \right] \tag{18}$$

The polynomial u is modified as shown in Equation (19):

$$u = \left[\begin{array}{c} p \\ q \end{array} A^T r \right] \tag{19}$$

The polynomial v is modified as shown in Equation (20):

$$v = \left[\begin{array}{c} p \\ q \end{array} t^T r \right] + m \left[\begin{array}{c} q \\ 2 \end{array} \right] \tag{20}$$

The noisy result m_n takes the form shown in Equation (21):

$$m_n = v - us \tag{21}$$

Finally, the result must be rescaled to obtain the original value, as presented in Equation (22):

$$m_b = \left[\frac{2 m_n}{q} \right] \text{mod } 2 \tag{22}$$

Python was selected for implementing the variant due to its suitability for polynomial and matrix calculations, which simplified the mathematical operations required by

these equations (Gonzalez, 2021). Additionally, the tests to verify the effectiveness of the algorithm were also conducted in the same programming language.

The three modified algorithms are presented in Algorithm 4, Algorithm 5, and Algorithm 6. In Algorithm 4, key generation is shown, where the keys s and t must be generated along with matrix A . These functions receive global parameters q and n , which represent the space and maximum dimension, respectively. During this first phase, the value of p is generated, which—together with q —defines the rounded space for the system.

Algorithm 4: Key Generation

1. Start
2. Generate key s
3. $S = a_i x^n + a_{i-1} x^{n-1} + \dots + a_1 x^0$ where $a_i \in [-3.3]$
4. Generate space value p
5. $q = 3329$
6. $P = k$ while $k < q$
7. Generate matrix A
8. $A = [a_{11}(X) a_{21}(X) \dots a_{nn}(X)]$
9. Generate public key t
10. $T = \begin{bmatrix} p \\ q \end{bmatrix} * (s * A)$
11. Return (s, t, A)
12. End

In Algorithm 5, the encryption process is shown. This involves handling both text strings and numbers. The initial transformation step requires converting the input message into its binary form. In the case of numbers, this is relatively straightforward. However, for text, the number generated must be checked to ensure it does not exceed the established dimension n . If it does, it is divided into blocks with elements smaller than or equal to dimension n . Subsequently, the operations are carried out, generating both u and v along with a pseudo-random vector r . The encryption process concludes by returning the encrypted pair (u, v) .

Algorithm 5: Encryption

1. Start
2. Input value x to encrypt
3. If x is integer:
 4. Transform it to binary value $(x)_{10} = (x)_2$
 5. With $(x)_2$: $m_b = P(x) = b_n x^n + b_{n-1} x^{n-1} + \dots + b_0 x^0$ where $b_n \in \{0,1\}$
 6. $M = m_b * \frac{q}{2}$
7. Else if x is string:
 8. Transform to binary value $(x) = (x)_2$
 9. If elements in $(x)_2 > n$:
 10. Create blocks where the elements of $(x)_2 \leq n$ where $n = 256$ and add to list L
 11. Generate random vector (r)
 12. Calculate values u, v :
 13. $u = \begin{bmatrix} p \\ q \end{bmatrix} A^T r$
 14. $v = \begin{bmatrix} p \\ q \end{bmatrix} t^T r + m \begin{bmatrix} q \\ 2 \end{bmatrix}$
 15. Return (u, v)
 16. End

Finally, in Algorithm 6, the decryption process is shown. Here, the established keys are considered as global variables, while the encrypted pair (u,v) is given as an argument. The noisy result m_n is calculated. For each coefficient i , the distance is compared with $q/2$, q , and 0. If i is closer to $q/2$, it will be assigned that value; otherwise, if its distance to q or 0 is smaller, it will be assigned 0. The result is then scaled back to retrieve the original value.

Algorithm 6: Decryption

1. Start
2. Input values to decrypt (u,v)
3. Calculate noisy value
4. $m_n = v - u * s$
5. For each coefficient (i) of m_n :
6. If $\left| i - \frac{q}{2} \right| < |i - q|$ o $\left| i - \frac{q}{2} \right| < |0 - i|$:
7. Then $i = \frac{q}{2}$
8. Else:
9. Then $i = 0$
10. Calculate original value:
11. $res = m_b * \frac{1}{\frac{q}{2}}$
12. Return res
13. End

3.3 Experimental Design

The first step in conducting the experiment was to implement the algorithm based on the formulated equations. Matrix and vector operations were managed using the NumPy library. Once the implementation was completed, each stage of the algorithm was tested to verify that it used the necessary modified and added parameters to consider the change toward LWR (Alwen et al., 2013). The second step involved implementing a brute-force attack method using reverse engineering as presented by NTT DATA (NTT DATA Perú, 2024).

The original Kyber algorithm and its RKyber variant were refactored and implemented respectively in Python. The time in seconds required to generate both public and private keys was recorded for dimensions (n) ranging from 2 to 13. Using this data, the exponential function was applied to project values for larger dimensions, extending up to 256, which is the official value for the original versions (Gonzalez, 2021). The execution times for each method of both algorithms were compared. Finally, it is worth noting that the implementation of the original algorithm followed the official NIST documentation for the competition (Avanzi et al., 2021), while the modification was based on the work by Alwen et al. (2013). The algorithm was executed on a machine with the following specifications: Core i5-11300H processor, 24GB RAM, Windows 11 operating system, and GeForce RTX 3050 GPU.

3.4 Variant Evaluation

Once the implementation of the variant was completed, we focused on comparing the execution times for each part of the algorithm: key generation, encryption, and decryption. This evaluation involved executing each part of the algorithm 1000 times for both the original Kyber algorithm and its variant. The primary objectives of the variant were to improve computational resource efficiency compared to the original algorithm. The decryption process necessarily required equations resulting in u and v . It was essential to perform all calculations related to key generation and encryption. The public key takes the form presented in Equation (9), which can be expressed as shown in Equation (23):

$$\begin{bmatrix} a_{11}(X) & a_{12}(X) \\ a_{21}(X) & a_{22}(X) \end{bmatrix} \begin{bmatrix} s_1(X) \\ s_2(X) \end{bmatrix} + \begin{bmatrix} e_1(X) \\ e_2(X) \end{bmatrix} \tag{23}$$

Where the elements of the matrices are generated based on X , with each element of matrix A being a negacyclic matrix (Gonzalez, 2021). This expression applies to Kyber512, where the coefficients of $s_i(X)$ are only restricted to $\{-3, -2, -1, 0, 1, 2, 3\}$. This range generates 7^{512} possibilities for the private key. In the case of Kyber768, it involves a 3×3 matrix A , and for Kyber1024, a 4×4 matrix A (Gonzalez, 2021). Considering that the error vector is removed in the RKyber variant, and this vector dimension increases with each Kyber version, the estimated security loss is proportional to the number of polynomials removed. For RKyber512, the public key is calculated as presented in Equation (24):

$$\left\lfloor \frac{p}{q} \begin{bmatrix} a_{11}(x) & a_{12}(x) \\ a_{21}(x) & a_{22}(x) \end{bmatrix} \begin{bmatrix} s_1(x) \\ s_2(x) \end{bmatrix} \right\rfloor \tag{24}$$

Given the numerous private key possibilities, the corresponding public key becomes unfathomably large. In a reduced example, where values are divided into two polynomials for the key s , the number of possibilities was calculated to be 7^6 . In this same example, the remaining polynomials would need to be assigned to matrix A , requiring 7^{500} calculations. This results in a total of 7^{512} calculations. Based on this estimate, the projected security loss for RKyber512 is 1.17 %. For RKyber768 and RKyber1024, the estimated loss is 0.7 % and 0.5 %, respectively, assuming that the security loss is directly proportional to the number of removed polynomial operations.

The time required to break the encryption was estimated using reverse engineering and regression analysis. Following NTT researchers (NTT DATA Perú, 2024), this reverse engineering approach minimizes all the possible variables in the key generation method. The number of possible values was reduced from 7^6 to 3^6 by using only the values $\{-1, 0, 1\}$. In this method, matrix A is known, so only the private key s , divided into s_1 and s_2 , needs to be addressed. Moreover, the parameters p and q are known, as they are defined at the start of the execution. The results are derived as presented in Equation (25):

$$\left\lfloor \frac{p}{q} (A_{1,1} s_1 + A_{1,2} s_2) \right\rfloor = t_1$$

$$\left\lfloor \frac{p}{q} (A_{2,1} s_1 + A_{2,2} s_2) \right\rfloor = t_2$$
(25)

In the original algorithm, error vectors were included in the key generation process, resulting in 3^6 possibilities (Avanzi et al., 2021). However, since this variant removes the error vector, the number of possibilities is further reduced to 3^4 .

4 RESULTS

4.1 Analysis Results

Starting with the original CRYSTALS-Kyber algorithm, the first method involves generating the matrix A , the private key s , the error vector e , and calculating the public key t . Since generating matrix A is the most complex operation in terms of time and space, it dictates the complexity of the key generation method, with a time complexity of $O(n^2)$ and a space complexity of $O(n^2 \log q)$. Here, q refers to the space in which the polynomial coefficients are generated. The second method, encryption, generates vector r and the pair of encrypted message values u and v . The space complexity for this method is $O(n \log q)$, while the time complexity is $O(n^2)$, again generated in space q . Finally, the decryption method runs in $O(\log q)$ space and $O(n)$ time, as reversing the message is relatively simpler to store and execute.

In the RKyber variant, no error vector e is generated. Instead, it works with an additional parameter p , which creates a “deterministic error” in place of the pseudo-random error seen in LWE. The first key generation method runs with $O(n^2 \log q)$ space and $O(n^2)$ time. However, in this case, the public key is generated within space p rather than q , as seen in Equation (18). The second encryption method has the same time and space complexity as its LWE counterpart, with $O(n \log q)$ for space and $O(n^2)$ for time. The main difference lies in how the vectors u and v are generated in space p rather than q . Finally, the decryption method runs in $O(\log p)$ space and $O(n)$ time.

4.2 Experimental Results

4.2.1 Execution Time Tests

The results from the experiment consist of the execution times for each part of both algorithms, averaged over 1 000 runs per stage. The Kyber algorithm has three versions in terms of security: Kyber512 (lower security, faster), Kyber768, and Kyber1024 (higher

security, more time-consuming). The following tables show the execution times for both the original algorithm and the RKyber variant across Kyber512, Kyber768, and Kyber1024.

Table 2

Execution Times in Milliseconds for RKyber512 and Kyber512

RKyber 512			Kyber512			
Time per Stage (in ms)	Keygen	Encryption	Decryption	Keygen	Encryption	Decryption
Maximum	12.002	27.526	46.002	17.010	22.002	55.999
Minimum	3.997	7.945	14.225	4.032	7.998	14.612
Median	5.430	9.420	16.181	5.611	9.723	16.658
Standard Deviation	0.804	1.068	1.887	0.881	1.197	2.039
Total	5.43	9.42	16.18	5.6	9.72	16.65

Table 3

Execution Times in Milliseconds for RKyber768 and Kyber768

RKyber768			Kyber768			
Time per Stage (in ms)	Keygen	Encryption	Decryption	Keygen	Encryption	Decryption
Maximum	35.675	51.999	72.510	45.556	41.000	88.998
Minimum	7.600	12.618	21.409	7.996	12.998	21.868
Median	9.251	14.586	24.153	9.619	15.051	24.957
Standard Deviation	1.531	2.558	3.598	2.014	1.874	3.598
Total	9.25	14.58	24.15	9.61	15.05	25.12

Table 4

Execution Times in Milliseconds for RKyber1024 and Kyber1024

RKyber1024			Kyber1024			
Time per Stage (in ms)	Keygen	Encryption	Decryption	Keygen	Encryption	Decryption
Maximum	43.998	83.237	113.001	70.714	94.000	125.999
Minimum	12.533	19.023	31.160	11.997	18.204	29.708
Median	14.759	21.884	35.271	14.665	21.739	34.774
Standard Deviation	1.872	3.695	5.064	4.166	5.574	7.521
Total	14.664	21.73	34.77	14.75	21.88	36.27

These results show that RKyber achieves slightly faster execution times than the original Kyber algorithm. As the algorithm's complexity increases with the security level (from Kyber512 to Kyber1024), the differences in execution times become more apparent.

To model these results, parameters n (degree of polynomials), k (number of polynomials), and N (possible range of coefficient values) were used (NTT DATA Perú, 2024).

4.2.2 BRUTE-FORCE ATTACK TESTS

This section presents brute-force security tests conducted for each algorithm. These tests involved incrementally increasing the polynomial dimensions from the lowest to the highest possible values to project the time required to break these algorithms using brute force. The results are shown in Table 5 and Figures 3 and 4.

Table 5

Brute-Force Attack Times for RKyber512 and Kyber512

n	Kyber	RKyber
2	0.000529162	0.000525681
3	0.001454904	0.001440572
4	0.004000182	0.003947727
5	0.010998292	0.010818309
6	0.030239226	0.029646378
7	0.083141166	0.081242618
8	0.228592276	0.222636403
9	0.628502473	0.610110424
10	1.728034584	1.671940092
11	4.751140451	4.581766782
12	13.06301146	12.55582478
13	35.91606484	34.40784821

Using the results from the attack executions, the exponential function that fits the attack times can be determined. This allows for the estimation of approximate values for $N = 256$, which is the standard value used in these algorithms.

Figure 3

Brute-Force Attack on Kyber512

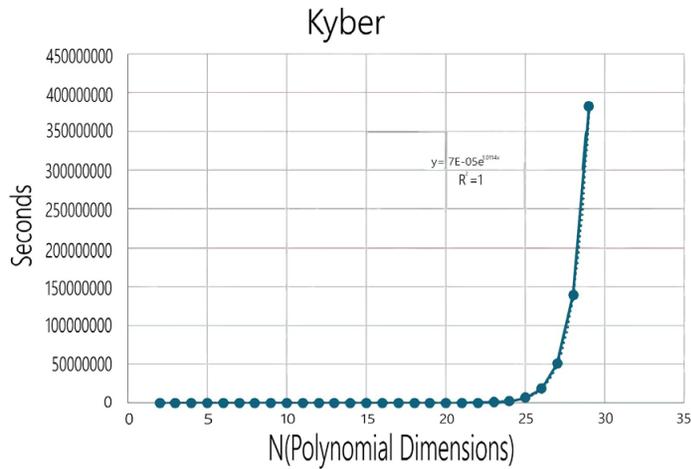
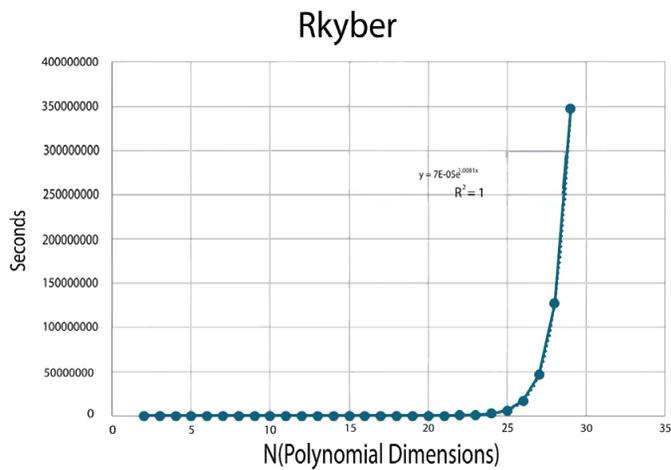


Figure 4

Brute-Force Attack on RKyber512



These results demonstrate that RKyber is slightly easier to break using brute-force attacks, but the difference is negligible. For example, with $N = 30$, the estimated execution time to break RKyber is approximately 12 years. With $N = 256$, the attack would take an incalculable amount of time using current technology, meaning that the variant remains secure. In summary, RKyber offers computational advantages in execution time without significantly compromising security, making it a viable alternative to the original algorithm in environments where speed is critical and extreme security is not required.

5. DISCUSSION

As seen in the results from Tables 2, 3, and 4, the execution times for the RKyber variant are shorter than those for the original Kyber algorithm. This improvement occurs because, in RKyber, errors are no longer generated randomly; instead, they are converted into deterministic values, simplifying the algorithm's execution and computation. At first glance, the time difference may not seem significant. However, it is important to consider that these are cumulative results over 1000 executions, where a difference of just 1 ms per execution can add up substantially. On the other hand, the trade-off for this improvement in execution time is a reduction in security. The original Kyber algorithm introduced random noise, including an additional security layer by making it more difficult for attackers to reverse-engineer the encryption. In RKyber, this noise has been removed, making it theoretically more vulnerable. However, it should be emphasized that RKyber remains resistant to quantum attacks, as the underlying lattice is unchanged, meaning an attacker would still need to find the correct polynomial to decrypt the message. So far, no practical attack has fully compromised Kyber's security. The only known attack, KyberSlash (Bernstein, 2024), assumes direct access to the processor where the system is running, making it incredibly difficult to execute. Dr. Daniel Bernstein has tracked this attack and reported that the original implementation has already been patched to mitigate this threat.

In terms of complexity, the biggest difference between the two algorithms lies in the space used in the generations. The LWE-based version of Kyber primarily uses q space, whereas the RKyber variant uses p space (Alwen et al., 2013). However, the overall complexity remains the same, as p is always smaller than q , making this difference negligible in terms of asymptotic bounds.

Originally, this study aimed to simulate an attack using Shor's quantum algorithm, since it efficiently breaks current public-key schemes. However, it became clear that such attacks are not feasible, at least at the time of writing this report. The reason is the way Shor's algorithm inputs and outputs data. In this case, the input should be a number, and the output should be its prime factors. Given that the fundamental bases of lattices are polynomials stored in vectors, factoring them in this way is not possible. A more appropriate solution would involve using Grover's algorithm to optimize coefficient generation, though this was not tested in this research. Using Grover's algorithm along with the reverse-engineering method could be a potential solution.

To estimate the time needed to break the algorithm, a statistical analysis was conducted based on the time (in seconds) recorded during key generation across multiple experiments. A simple statistical model was built using the input parameters n , k , and N (Gonzalez, 2021). This model allowed for the projection of breaking times for different configurations.

6. CONCLUSIONS

This paper introduces a new perspective on the CRYSTALS-Kyber algorithm by modifying the core problem it addresses and extending it to the LWR problem. The resulting variant, named RKyber, significantly improves execution times at the cost of a slight reduction in security. The primary objective of this work was to transition from LWE to LWR and test the modified algorithm. The change inherently compromises security by removing the pseudo-random obfuscation method used in LWE encryption systems, resulting in a trade-off between efficiency and security. However, the reduction in security does not render the algorithm unusable.

Many systems do not require extremely high levels of security, and as discussed in Section 5, the security loss is minimal. The time needed to break RKyber using brute-force attacks remains prohibitive with current technology, ensuring that the variant is still resistant to quantum attacks. Furthermore, RKyber's improvements in execution time could be advantageous in environments where resource efficiency is a priority. The transition from LWE to LWR supports the hypothesis that both pseudo-random and deterministic errors are computationally congruent. Alwen et al. (2013) suggest that the decryption step, where the error is handled, is the most computationally demanding part of the system. By removing the need to deal with LWE's pseudo-random error, the algorithm becomes more efficient without significantly compromising security. This holds true for all versions of Kyber (512, 768, 1024), where the only significant changes are the parameters involved in the key generation, encryption, and decryption processes.

REFERENCES

- Aaronson, S., & Chen, L. (2017). Complexity-theoretic foundations of quantum supremacy experiments. *Proceedings of the 32nd Computational Complexity Conference (CCC'17)*, Dagstuhl, Germany, Article 22, 1–67. <https://doi.org/10.48550/arXiv.1612.05903>
- Alwen, J., Krenn, S., Pietrzak, K., & Wichs, D. (2013). Learning with rounding, revisited. In R. Canetti, & J. A. Garay (Eds.), *Lecture Notes in Computer Science: Vol. 8042. Advances in Cryptology – CRYPTO 2013* (pp. 57–74). Springer. https://doi.org/10.1007/978-3-642-40041-4_4
- Avanzi, R., Bos, J., Ducas, L., Kiltz, E., Lepoint, T., Lyubashevsky, V., Schanck, J. M., Schwabe, P., Seiler, G., & Stehlé, D. (2021). *CRYSTALS-Kyber: Algorithm specifications and supporting documentation (version 3.01)*. <https://pq-crystals.org/kyber/data/kyber-specification-round3-20210131.pdf>
- Benioff, P. (1980). The computer as a physical system: A microscopic quantum mechanical Hamiltonian model of computers as represented by Turing machines. *Journal of Statistical Physics*, 22, 563–591. <https://doi.org/10.1007/bf01011339>

- Bernstein, D. J. (2024, June 28). *KyberSlash: division timings depending on secrets in Kyber software*. FAQ. <https://kyberslash.cr.yip.to/faq.html>
- Gonzalez, R. (2021, September 14). *Kyber - How does it work?* Approachable Cryptography. <https://cryptopedia.dev/posts/kyber/>
- Grover, L.K. (1996). *A fast quantum mechanical algorithm for database search*. Bell Labs. <https://doi.org/10.1145/237814.237866>
- Lyubashevsky, V., Peikert, C., & Regev, O. (2010). On ideal lattices and learning with errors over rings. In H. Gilbert (Ed.), *Lecture Notes in Computer Science: Vol. 6110. Advances in Cryptology – EUROCRYPT 2010* (pp. 1–23). Springer. https://doi.org/10.1007/978-3-642-13190-5_1
- Micciancio, D., & Goldwasser, S. (2002). *Complexity of lattice problems: A cryptographic perspective*. Springer. <https://ci.nii.ac.jp/ncid/BB14507293>
- Mor, T., & Renner, R. (2014). Preface. *Natural Computing*, 13(4), 447–452. <https://doi.org/10.1007/s11047-014-9464-3>
- NTT DATA Perú. (2024, April 17). Algoritmos post-cuánticos: criptografía y ciberseguridad en la era cuántica. NTT DATA Perú. https://pe.nttdata.com/documents/paper_crystals_kyber_ntt_data.pdf
- Peikert, C. (2016). A decade of lattice cryptography. *Foundations and Trends in Theoretical Computer Science*, 10 (4), 283–424. <https://doi.org/10.1561/04000000074>
- Regev, O. (2005). On lattices, learning with errors, random linear codes, and cryptography. *Proceedings of the thirty-seventh annual ACM symposium on Theory of computing (STOC '05)*, New York, NY, USA, 84–93. <https://doi.org/10.1145/1060590.1060603>
- Shor, P. W. (1997). Polynomial-time algorithms for prime factorization and discrete logarithms on a quantum computer. *SIAM Journal on Computing*, 26(5), 1484–1509. <https://doi.org/10.1137/s0097539795293172>
- Wei, Y., Bi, L., Lu, X., & Wang, K. (2023). Security estimation of LWE via BKW algorithms. *Cybersecurity*, 6, Article 24. <https://doi.org/10.1186/s42400-023-00158-9>

PREDICTION OF PM_{2.5} AND PM₁₀ CONCENTRATIONS USING XGBOOST AND LIGHTGBM ALGORITHMS: A CASE STUDY IN LIMA, PERU

JOHAN ANDRÉS OBLITAS MANTILLA
20191412@aloe.ulima.edu.pe
<https://orcid.org/0009-0007-2183-5583>
Universidad de Lima, Peru

EDWIN JHONATAN ESCOBEDO CÁRDENAS
eescobed@ulima.edu.pe
<https://orcid.org/0000-0003-2034-513X>
Universidad de Lima, Peru

Received: September 3th, 2024 / Accepted: October 12th, 2024
doi: <https://doi.org/10.26439/interfases2024.n020.7417>

ABSTRACT. Air pollution is a major problem that affects both human health and the environment, causing millions of premature deaths annually worldwide and severely degrading the state of the planet. Exposure to fine particulate matter, which is highly hazardous, enables these particles to penetrate deeply into the lungs and lead to serious health issues, including a reduction in life expectancy by more than two years. In response to this problem, it is crucial to identify effective ways to monitor the levels of these pollutants in our daily surroundings. This article presents a case study conducted in the district of San Borja, Lima, Peru, where prediction models for PM_{2.5} and PM₁₀ were implemented using the XGBoost and LightGBM algorithms. Employing data from the SENAMHI portal and a correlation analysis of variables, two different scenarios were developed for training the models. In scenario 1, prediction models for PM_{2.5} and PM₁₀ were trained using all available meteorological and pollution variables. In scenario 2, the models were trained for PM_{2.5} excluding the PM₁₀ variable, and vice versa. The results showed that both models achieved high accuracy, measured by the coefficient of determination, with no statistically significant difference indicating the superiority of either model. Furthermore, the analysis of the proposed scenarios revealed that excluding key variables can result in significantly less accurate predictions, potentially undermining the effectiveness of environmental management strategies.

KEYWORDS: air pollution / air quality / meteorological data / machine learning / XGBoost / LightGBM

PREDICCIÓN DE CONCENTRACIONES DE PM2.5 Y PM10 UTILIZANDO LOS ALGORITMOS XGBOOST Y LIGHTGBM: UN ESTUDIO DE CASO EN LIMA, PERÚ

RESUMEN. La contaminación del aire es un problema importante que afecta tanto a la salud humana como al medio ambiente, causando millones de muertes prematuras anualmente en todo el mundo y degradando severamente el estado del planeta. La exposición a material particulado fino, altamente peligroso, permite que estas partículas penetren profundamente en los pulmones y provoquen problemas de salud graves, incluyendo una reducción en la esperanza de vida de más de dos años. En respuesta a este problema, es crucial identificar formas efectivas de monitorear los niveles de estos contaminantes en nuestro entorno diario. Este artículo presenta un estudio de caso realizado en el distrito de San Borja, Lima, Perú, donde se implementaron modelos de predicción para PM2,5 y PM10 utilizando los algoritmos XGBoost y LightGBM. Empleando datos del portal del SENAMHI y un análisis de correlación de variables, se desarrollaron dos escenarios diferentes para el entrenamiento de los modelos. En el escenario 1, se entrenaron modelos de predicción para PM2,5 y PM10 utilizando todas las variables meteorológicas y de contaminación disponibles. En el escenario 2, los modelos se entrenaron para PM2,5 excluyendo la variable PM10, y viceversa. Los resultados mostraron que ambos modelos lograron una alta precisión, medida por el coeficiente de determinación, sin diferencias estadísticamente significativas que indicaran la superioridad de alguno de los modelos. Además, el análisis de los escenarios propuestos reveló que excluir variables clave puede resultar en predicciones significativamente menos precisas, lo que podría comprometer la efectividad de las estrategias de gestión ambiental.

PALABRAS CLAVE: contaminación del aire / calidad del aire / datos meteorológicos / aprendizaje automático / XGBoost / LightGBM

1. INTRODUCTION

Air pollution is a global problem that affects both human health and the environment. According to the World Health Organization (WHO, 2022), the combined effects of ambient and household air pollution are responsible for approximately 6,7 million premature deaths annually worldwide. Furthermore, WHO data reveals that 99 % of the global population breathes air with pollutant concentrations exceeding the levels established by WHO guidelines, with low- and middle-income countries being the most affected.

Exposure to fine particulate matter —one of the most harmful air pollutants for human health— enables these particles to penetrate deeply into the lungs, triggering reactions on lung surfaces and in defense cells, according to the Pan American Health Organization (PAHO, 2016). As mentioned by Sloss & Smith (2000), PM10 and PM2.5 refer to particulate matter with diameters of 10 microns or less and 2.5 microns or less, respectively. These particles originate from various chemical species emitted by both natural and human sources, including coal-fired power plants, industrial activities, and road transport. They can be emitted directly or formed through atmospheric chemical reactions. Increased concentrations of this particulate matter pose a serious threat to human health.

The Ministerio del Ambiente (MINAM – Ministry of the Environment of Peru) has acknowledged the severity of air pollution in the country, noting that mobile sources, mainly vehicles, account for 58 % of particulate matter emissions, followed by stationary sources (26 %), and area sources (16 %) (MINAM, 2021).

Studies by MINAM (2021) and WHO (2021) highlight that prolonged exposure to fine particles can reduce life expectancy by more than two years. Addressing this issue requires the development of accurate air quality prediction methods that can help mitigate its effects. In this context, there is a growing need to explore advanced approaches that leverage detailed meteorological data and machine learning (ML) techniques. These models offer significant benefits over traditional approaches, as they are both cost-effective and computationally efficient. Research on estimating pollutant concentrations remains highly active, with efforts focused on reducing reliance on sensors and networks by using approximate predictions. Thus, various machine learning models have been applied for this purpose.

Researchers like Wang et al. (2023), and Gryech et al. (2020) have reported improvements in pollution estimation accuracy by through the incorporation of ng more detailed meteorological data, such as wind speed and wind direction. They also further suggest that, in the presence of large datasets, deep learning models should be prioritized over traditional ML models when working with large datasets. According to Cordova et al. (2021), while several studies have been focusing on applying machine

learning methods to forecast air quality in large cities, there is a limited number of studies of such research in the context of Lima, Peru, a city that ranks among the most populated in South America.

XGBoost and LightGBM are advanced machine learning algorithms used for predicting air quality, especially PM2.5 and PM10 concentrations, offering superior performance through efficient optimization and memory usage. XGBoost excels in computational efficiency, while LightGBM's leaf-wise growth strategy helps it handle large datasets effectively, making both suitable for robust, computationally efficient air quality prediction models.

Based on the previous context, a case study is proposed to predict fine particles PM2.5 and PM10 using the XGBoost and LightGBM algorithms. Data will be collected through the Servicio Nacional de Meteorología e Hidrología (SENAMHI – National Meteorology and Hydrology Service of Peru) web portal, specifically from the San Borja station. Using this data and two scenarios developed from a correlation analysis, prediction models will be implemented and evaluated using different performance metrics to conduct a comparative analysis.

This research article adopts a classical structure, beginning with the state of the art, where key variables in pollution estimation are reviewed, various prediction algorithms are explored, and relevant data processing techniques are discussed. The methodology focuses on the study area in San Borja, using SENAMHI datasets that include meteorological and pollutant data, refined and integrated to identify significant correlations. During the experimentation phase, the integrated dataset is normalized and divided to apply methods such as XGBoost and LightGBM, evaluating the models according to specific criteria. The results are discussed in detail in relation to the hypotheses posed, and conclusions summarize the study's key findings. Finally, future research is proposed, addressing potential methodological improvements or new areas of application.

2. STATE OF THE ART

The state of the art provides an updated and comprehensive overview of the study topic. In this regard, this section presents a structured analysis of the existing literature. First, the databases commonly used in this field are described, detailing their names, variables, number of records, frequency, location, and data collection periods. Subsequently, ML algorithms applied in various research articles are discussed, including the metrics used and their respective results.

2.1 Identified Variables in Pollution Estimation

The relevance of meteorological data in developing prediction models has been well established. For example, temperature and solar radiation influence the formation of ground-level ozone, while wind direction and wind speed affect the dispersion of pollutants and their impact across different geographical areas. Moreover, precipitation significantly contributes to the dispersion and removal of atmospheric pollutants, as it washes away particles and clears the air. Additionally, relative humidity plays a role in the reactivity and chemical transformation of pollutants (Zhang et al., 2020; Gryech et al., 2020; Ameer et al., 2019).

Furthermore, besides finding a strong correlation between PM10, PM2.5, nitrogen dioxide (NO₂), and carbon monoxide (CO) concentrations and meteorological conditions, a significant seasonal correlation was observed between atmospheric pollutants and temperature. Specifically, during winter, the concentrations of these pollutants were found to be double those recorded in summer (Gryech et al., 2020). However, some studies have analyzed the importance of incorporating data related to vehicular flow when predicting air quality. According to Gryech et al. (2020), greater accuracy can be achieved by combining meteorological data with traffic-related data to estimate unmeasured pollutant concentrations.

Additionally, Sulaimon et al. (2022) conducted a research experiment where several air pollution prediction models were trained based on different ML algorithms. In scenario 1, only air quality and meteorological data was used to process the dataset, whereas in scenario 2, an experimental dataset that included traffic data was employed. The results consistently showed that models trained with the experimental dataset outperformed those trained with the control dataset. A performance improvement of at least 20 % and an error reduction of at least 18.97 % were observed in 98 % of the ML algorithms when trained with a dataset containing traffic-related information. These findings underscore the significant impact of traffic data on improving the performance of ML-based air pollution prediction models (Sulaimon et al., 2022).

For this study, datasets provided by SENAMHI, which include pollutant and meteorological data, were selected. These datasets are particularly relevant because they provide specific information about the study area of interest—in this case, Lima, Peru.

2.2 Prediction Algorithms

Zhang et al. (2020) achieved positive results with their proposed distributed hybrid system of fixed and IoT sensors for predicting air quality. When comparing the applied algorithms—support vector regression (SVR), random forest regression (RFR), and gradient boosting regression (GBR)—the latter yielded the best results, with an RMSE of 13.8375 for PM10 predictions and 11.225 for PM2.5 predictions.

In contrast, Gryech et al. (2020) used accuracy as the evaluation metric to compare the techniques employed, with the random forest (RF) algorithm achieving high accuracy:

94 %, 97 %, and 98 % for pollutants NO₂, PM₁₀, and PM_{2.5}, respectively. Additionally, they demonstrated that certain pollutants can be accurately predicted based on the concentrations of other pollutants. A key finding was that NO₂ concentration could be predicted based on PM₁₀ concentration and vice versa. They concluded that the RF algorithm is highly flexible and shows less variation compared to individual decision trees.

For Gokul et al. (2023), the gradient-boosting regression model (XGBoost) emerged as the ML algorithm that delivered the best results, obtaining a mean absolute error (MAE) of 7.01, a mean squared error (MSE) of 93.55, and an RMSE of 9.67. Sulaimon et al. (2022), on the other hand, achieved a performance improvement of at least 20 % and an error reduction of 18.97 % by including traffic flow-related data into the training of different ML models. They also observed varying behaviors and performances across the algorithms, with no single algorithm consistently yielding the best results overall. Their findings were primarily influenced by variations in the study areas and the combinations of datasets used.

Finally, according to Liu et al. (2023), the LightGBM model was employed to predict the atmospheric concentration of PM_{2.5} by optimizing its parameters. After analyzing monitoring data from various times and regions, the prediction curve of haze concentration indicated that the model exhibited strong learning capability, a high degree of fit, and significant improvement in both accuracy and stability. It has been demonstrated that optimization with this algorithm significantly enhances precision. The improved model is highly applicable in practice and is suitable for forecasting PM_{2.5} concentrations, offering valuable insights for predicting trends in air quality changes.

2.3 Data Processing Techniques

Several data processing techniques frequently used in the analyzed research can be identified. First, data cleaning involves detecting and correcting errors, outliers, or missing data to improve the quality and reliability of the dataset. It remains one of the most widely used techniques across various datasets (Gryech et al., 2020; Cordova et al., 2021; Gokul et al., 2023; Ayus et al., 2023). This technique includes several sub-techniques, such as outlier detection and data interpolation, among others.

On the other hand, data integration is a technique that involves combining multiple data sources into a single, coherent dataset. This approach provides a more holistic view of the data by combining different variables and features, and its application is considered essential for effective data processing (Gokul et al., 2023; Gryech et al., 2020; Sulaimon et al., 2022).

In the studies by Zhang et al. (2020), Liang et al. (2020), and Ayus et al. (2023), data normalization is commonly highlighted as a method used to scale variable values within a specific range, facilitating the comparison and analysis of variables within the same context.

Several key findings from the research on atmospheric pollution estimation stand out. The critical role of meteorological data —especially variables such as temperature, wind direction, wind speed, and precipitation in the formation and dispersion of pollutants— has been demonstrated. Additionally, a strong seasonal correlation between atmospheric pollutants and temperature has been observed, underscoring the significant impact of weather conditions on air quality. The studies have also highlighted the need to integrate multiple data sources to achieve more accurate and robust results. These findings underline the complexity and multidimensionality of the atmospheric pollution problem, providing a solid foundation for the implementation of advanced ML models in future research.

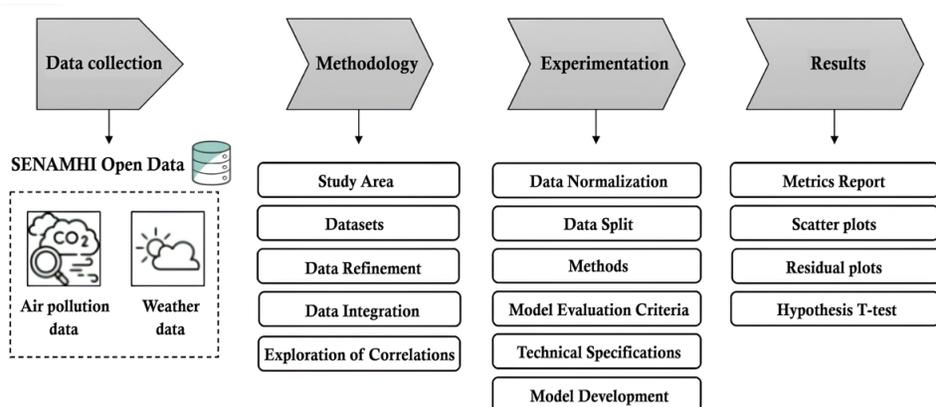
3. METHODOLOGY

This section outlines the key procedures derived from a review of the aforementioned literature. Based on the research by Sulaimon et al. (2022), Gryech et al. (2020), Ayus et al. (2023), Yang et al. (2018), and Ameer et al. (2019), the methodology began with a systematic review of the state of the art in air quality prediction, followed by the data collection, which encompassed a wide range of pollutant concentrations and meteorological data. A comprehensive exploratory analysis was performed on these datasets, including a descriptive analysis, evaluation of missing data, and exploration of correlations between variables.

The data preprocessing phase included integrating, transforming, cleaning, and normalizing the extracted datasets, followed by the variable selection process. Finally, prediction models were developed, and the performance of the trained models was evaluated through a comparative analysis.

Figure 1

Methodological Design



3.1 Study Area

The study area for training and testing the proposed approach is located in the province of Lima, Peru, specifically in the district of San Borja, as shown in Figure 2. Given its high traffic density and diverse lane distribution, San Borja is considered an ideal location for this study, as it also houses a variety of regulatory and commercial facilities. The air quality monitoring station is managed by SENAMHI, under the Dirección de Redes de Observación y Datos (Directorate of Observation Networks and Data). This station has been operational since May 26, 2010, and is located at coordinates 12.10859 latitude and 77.00769 longitude.

The data collected from the San Borja station spans from the start of its operation to the present date. It is important to note that this data is presented in its raw form, meaning it has not undergone any quality control process. Therefore, applying necessary corrections is deemed essential to minimize any negative impact on the results.

The dataset comprises 11 input variables, including temperature, relative humidity, wind direction, wind speed, precipitation, CO, nitrogen oxides (NO_x), ozone (O₃), sulfur dioxide (SO₂), and particulate matter (PM_{2,5} and PM₁₀).

Figure 2

Map Showing the Study Area and the Location of the Air Quality Monitoring Station in San Borja



3.2 Datasets

Two datasets were examined, both describing pollutant concentrations and meteorological conditions for the same period and area. The data was recorded through the San Borja monitoring station and provided by SENAMHI (2024), with public access via their web portal.

The first dataset includes hourly observations from January 1 to April 30, 2024, measuring atmospheric pollutant concentrations, expressed in micrograms per cubic meter ($\mu\text{g}/\text{m}^3$) for PM_{2.5}, PM₁₀, NO₂, O₃, and CO. It consists of a total of 2810 records.

The second dataset contains meteorological variables such as temperature (in degrees Celsius), precipitation (millimeters per hour), relative humidity (percentage), wind direction (degrees), and wind speed (meters per second). It includes 2841 records.

3.3 Data Refinement

Based on the work of Sulaimon et al. (2022), data refinement was applied, which involves handling missing data and cleaning outliers. In the pollutant dataset, four missing records were identified, specifically in the NO₂ variable. Similarly, the meteorological dataset showed missing values for the temperature and humidity variables, with one missing record for each. Given the small number of missing records relative to the total dataset size, these records were removed to maintain data consistency.

Additionally, it was observed that 98.9 % of the records for the *precipitation* variable had a value of zero. This unusually high proportion suggests a possible anomaly in data capture, potentially indicating a malfunction of the measurement device during the observation period. Therefore, the *precipitation* column was removed to prevent misinterpretation or bias in further analyses.

For outlier detection, the multidimensional outlier detection method was employed, specifically the local outlier factor (LOF) method, which is widely recognized for its ability to identify anomalous points in multidimensional datasets. In this case, a contamination parameter of 0.1 was used.

3.4 Data Integration

According to Sulaimon et al. (2022), the use of multiple datasets requires a data integration process to ensure the information can be accessed through a unified repository. For this purpose, the datasets were processed and integrated. The common reference points were the date and time features. Below, Table 1 shows an initial fragment of the integrated dataset, while Table 2 provides a description of each feature.

Table 1

Header of the Integrated Dataset

N.º	PM10	PM2,5	NO2	O3	CO	Temperature	Humidity	Wind Direction	Wind Speed
0	31.0	14.4	15.3	11.6	332.4	21.9	85.0	168	2.1
1	32.0	14.9	11.8	12.6	226.8	21.5	87.0	184	1.3
2	25.8	10.8	9.6	15.3	242.7	22.0	83.0	183	0.8
3	23.7	11.8	9.2	35.9	181.7	26.2	67.0	276	1.0
4	25.5	12.7	11.2	39.1	188.6	26.6	68.0	210	0.7

Table 2
Data Dictionary

Variable	Unit	Data Type	Description
PM2.5	µg/m ³	Float	Contains numerical data represented as floating-point values with units of micrograms per cubic meter (µg/m ³). This feature measures the concentration of fine particles in the air with a diameter of 2.5 micrometers or less.
PM10	µg/m ³	Float	Contains numerical data represented as floating-point values with units of micrograms per cubic meter (µg/m ³). This feature measures the concentration of fine particles in the air with a diameter of 10 micrometers or less.
NO2	µg/m ³	Float	Contains numerical data represented as floating-point values with units of micrograms per cubic meter (µg/m ³). This feature measures the concentration of nitrogen dioxide in the air.
O3	µg/m ³	Float	Contains numerical data represented as floating-point values with units of micrograms per cubic meter (µg/m ³) or parts per million (ppm). It measures the concentration of ozone in the air.
CO	µg/m ³	Float	Contains numerical data represented as floating-point values with units of micrograms per cubic meter (µg/m ³) or parts per million (ppm). It measures the concentration of carbon monoxide in the air.
Temperature	Degrees Celsius	Float	Stores numerical data in floating-point format with units of degrees Celsius (°C). These values represent the ambient temperature at the time of measurement.
Humidity	Percentage	Float	Recorded as floating-point numerical values with units of percentage (%). It indicates the level of relative humidity in the air at the time of measurement.
Wind Direction	Degrees	Float	Stored as floating-point numerical data with units of degrees (°). This feature indicates from where the wind is coming at the time of measurement.
Wind Speed	m/s	Float	Contains numerical data in floating-point format with units of meters per second (m/s). It represents the wind speed at the time of measurement.

3.5 Exploration of Correlations

Based on the work of Bai et al. (2016), an analysis of correlations between pollutant variables and meteorological variables was conducted, revealing several significant relationships that provide valuable insights into the factors influencing air quality. First, PM10 and PM2.5 were highly correlated with each other (0.8), indicating a strong association in their concentration levels. This was expected, as both are particles of similar size and share common emission sources, such as fossil fuel combustion and industrial activities.

On the other hand, NO2 showed a relatively high correlation with CO at 0.69. This is because both substances are emitted during combustion processes and are influenced by similar factors, such as traffic density and meteorological conditions.

Wind direction and wind speed showed moderate correlations with other variables. This indicates that wind conditions can influence the dispersion of pollutants in the air. Stronger winds or favorable wind directions are likely to promote greater dispersion of pollutants, while weak winds may result in the accumulation of pollutants in a specific area.

Finally, a high negative correlation was found between temperature and humidity (-0.89). This inverse relationship is consistent with basic principles of physics, where the air's capacity to hold moisture decreases as temperature increases. This result underscores the important role of temperature and humidity in the formation and dispersion of atmospheric pollutants.

Table 3

Correlation Map Between Pollution and Meteorological Variables

Variables	PM10	PM2.5	NO2	O3	CO	T	H	WD	WS
PM10	1	0.79	0.60	-0.43	0.72	-0.03	-0.15	0.11	-0.15
PM2,5		1	0.49	-0.30	0.61	-0.07	-0.01	0.14	-0.27
NO2			1	-0.14	0.69	0.30	-0.39	0.18	0.03
O3				1	-0.28	0.58	-0.42	0.15	0.21
CO					1	0.17	-0.28	0.20	-0.17
T						1	-0.89	0.24	0.19
H							1	-0.24	-0.22
WD								1	-0.37
WS									1

Note. T represents temperature (°C), H represents humidity (%), WD represents wind direction (°), and WS represents wind speed (m/s).

Based on the analysis, two scenarios were created for the experimental phase of this study. In scenario 1 (S1), prediction models for PM2.5 and PM10 were trained using all available meteorological and pollution variables. In scenario 2 (S2), prediction models were developed separately for PM2.5, excluding the PM10 variable, and for PM10, excluding the PM2.5 variable. This approach aims to assess the impact that each variable has on the training of the other.

4. EXPERIMENTATION

Below is a detailed explanation of the workflow involved in the development of the prediction models.

- **Dataset:** The data was collected hourly at the San Borja meteorological monitoring station (SENAMHI) from January 1 to April 30, 2024. The integrated dataset included two categories —meteorological and pollution data— used as input variables. PM2.5 and PM10 were considered as the output variables.
- **Normalization:** As shown in Table 4, the dataset contains values with varying ranges. Therefore, the data is normalized. Normalization involves adjusting the scale of the data from its original range to a range between 0 and 1. Table 4 presents detailed statistics of the input and output variables used in this study. For this case, the standard scaling strategy was employed, with each value in the dataset normalized as follows:

$$z = \frac{x - \mu}{\sigma} \quad (1)$$

where z represents the scaled value, x is the original value, μ is the mean, and σ represents the standard deviation of the dataset.

- **Data Split:** According to research by Shakya et al. (2023), Liu et al. (2023), Ayus et al. (2023), Zhang et al. (2023), and Liang et al. (2020), the dataset was divided into training and testing sets, with 80 % of data used for training and the remaining 20 % for testing, following the Pareto principle, as noted by one of the authors. Table 4 presents the dataset statistics used to predict PM2.5 concentrations.
- **Methods:** This study used conventional ML methods, such as XGBoost and LightGBM, to predict PM2.5 concentrations in San Borja. The results from these models were compared to assess their accuracy and effectiveness.
- **Model Evaluation Criteria:** Shakya et al. (2023), Martín-Baos et al. (2022), and Pan (2018) used different metrics to evaluate their models. In this study, performance metrics such as coefficient of determination (R^2), RMSE, relative root mean square error (RRMSE), and MAPE were applied. The descriptions, formulas, and ranges of performance metrics are shown in Table 5.
- **Technical Specifications:** Python was chosen for the experimental phase due to its extensive access to key libraries such as Pandas, NumPy, and Scikit-learn, as well as other libraries specific to the ML algorithms applied in this work.

Table 4

Data Statistics

Dataset	Variables	Minimum	Maximum	Mean	Standard Deviation	25 %	50 %	75 %
Target Data	PM2.5	6.70	26.10	15.11	3.6842	12.40	14.70	17.40
	PM10	17.50	109.20	51.45	19.2692	37.10	47.40	63.80
Pollutants	NO2	4.50	41.80	21.02	7.0858	15.80	20.85	25.90
	O3	4.00	45.40	16.37	9.6222	6.60	15.30	23.80
	CO	101.20	1360.50	631.95	240.6815	458.90	632.50	810.80
Meteorological	Temperature	18.50	31.50	24.36	2.5980	22.40	23.90	26.30
	Humidity	48.00	98.00	77.03	10.7499	68.00	79.00	86.00
	Wind Direction	104.00	310.00	203.44	36.2904	179.00	191.00	227.25
	Wind Speed	0.00	2.70	1.02	0.6063	0.60	0.90	1.40

Based on Table 4, relevant information can be observed. First, the variability of PM2.5, with a standard deviation of 3.6842, suggests significant daily fluctuations in air quality. It can also be noted that the median (14.70) is close to the mean (15.11), indicating a relatively symmetrical distribution of the data.

The presence of other pollutants —such as PM10, NO2, O3, and CO— along with their respective variations and standard deviations provides a framework for understanding potential correlations between these pollutants and PM2.5. For example, the high standard deviation of CO (240.6815) indicates significant fluctuations that could have a substantial impact on PM2.5 levels. On the other hand, meteorological conditions are crucial factors affecting the dispersion and concentration of pollutants. For instance, the temperature with a mean of 24.36 and a standard deviation of 2.5980 suggests some stability, but fluctuations can still influence PM2.5 levels. Wind speed, although low on average (1.02 m/s), shows variations that can disperse pollutants.

Table 5

Formulas, Descriptions, and Ranges of Performance Metrics

Metric	Formula	Description	Range
R^2	$\left(\frac{\sum_{i=1}^n (a_i - \bar{a})(p_i - \bar{p})}{\sqrt{\sum_{i=1}^n (a_i - \bar{a})^2} \sqrt{\sum_{i=1}^n (p_i - \bar{p})^2}} \right)^2$	It is a widely used metric that indicates how well the trends of the model simulation match the trends of the actual data.	$0 \leq R^2 \leq 1$ (Higher values indicate better performance)
MAE	$\frac{1}{n} \sum_{i=1}^n (p_i - a_i)$	Quantifies the dispersion between the actual values and the predicted values.	$0 \leq MAE \leq \infty$ (Lower values indicate better performance)

(continúa)

(continuación)

Metric	Formula	Description	Range
RRMSE	$\frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (a_i - p_i)^2}}{\bar{a}}$	Calculated by dividing the RMSE value by the mean of the actual values.	$0 \leq RRMSE \leq \infty$ (Lower values indicate better performance)
MAPE	$\frac{1}{n} \sum_{i=1}^n \left \frac{a_i - p_i}{a_i} \right $	It is a statistical measure that provides a benchmark for the accuracy of a prediction model.	Lower values indicate better performance

Note. a_i represents the actual values, p_i represents the predicted values, \bar{a} represents the mean of the actual values, \bar{p} represents the mean of the predicted values and n represents the number of observations (Shakya et al., 2023).

4.1 Model Development

For the training process of each model, 100 iterations were performed to adjust the hyperparameters and obtain optimal results. This adjustment was carried out using RandomizedSearchCV, an efficient random search technique that systematically explores the hyperparameter space. Each hyperparameter is defined within a specific range, determining the values it can take during the random search process. The ranges used are shown in Table 6.

Table 6

Hyperparameter Values

Algorithm	Hyperparameter	Range of Values
XGBoost and LightGBM	n_estimators	Random integer between 20 and 150. This hyperparameter controls the number of estimators (trees) used in the model.
XGBoost	max_depth	Random integer between 3 and 12. This parameter determines the maximum depth of each tree in the model, influencing its complexity and ability to fit the data.
XGBoost and LightGBM	learning_rate	Random continuous value between 0.05 and 0.35. This learning rate controls the magnitude of updates to the model weights in each iteration, affecting the speed and accuracy of training.
XGBoost and LightGBM	colsample_bytree	Random continuous value between 0.5 and 1.0. This parameter determines the percentage of features to consider for each tree during training, helping to control overfitting.
XGBoost and LightGBM	subsample	Random continuous value between 0.5 and 1.0. This hyperparameter specifies the percentage of samples (instances) to consider for each tree during training, helping to control overfitting and improve model generalization.

(continúa)

(continuación)

Algorithm	Hyperparameter	Range of Values
XGBoost and LightGBM	reg_alpha	Random continuous value between 0.05 and 9.95. This parameter controls the strength of L1 regularization (Lasso regression) in the model, helping to prevent overfitting by penalizing large coefficients.
LightGBM	reg_lambda	Random continuous value between 0.05 and 9.95. Similar to reg_alpha, this parameter controls the strength of L2 regularization (Ridge regression) in the LightGBM model.
XGBoost	min_child_weight	Random continuous value between 1 and 19. This hyperparameter sets the minimum weight required to create a new partition in a tree node during the growth process, influencing the complexity and structure of the final tree.
LightGBM	min_child_samples	Random integer between 20 and 50. This hyperparameter sets the minimum number of samples required to create a new partition in a tree node during the growth process, affecting the structure and complexity of the final tree.
LightGBM	num_leaves	Random integer between 31 and 100. This parameter determines the maximum number of leaves allowed in each tree of the model, affecting its complexity and adaptability.

5. RESULTS

This section presents an analysis of the results from the models developed to predict PM2.5 and PM10 concentrations. First, the performance of the models is evaluated using the mentioned metrics and considering the proposed scenarios informed by the correlation analysis. Next, residual and scatter plots related to these results are included. Finally, a paired t-test is conducted to statistically assess potential differences between the algorithms under study.

Table 7

Performance of XGBoost and LightGBM Models for PM2.5 and PM10 Predictions: A Scenario Comparison

		XGBoost				LightGBM			
		R ²	MAE	RRMSE	MAPE	R ²	MAE	RRMSE	MAPE
S1	PM2.5	0.75	1.6376	0.1454	10.0227	0.75	1.654	0.1474	10.1317
	PM10	0.84	6.6538	0.1595	12.2376	0.83	6.7814	0.1632	12.4313
S2	PM2.5	0.54	2.1142	0.1810	13.6036	0.55	2.1367	0.1810	13.7412
	PM10	0.69	8.9187	0.2156	17.1318	0.68	8.9814	0.2190	17.0944

Table 7 compares the performance of the XGBoost and LightGBM models in predicting PM2.5 and PM10 concentrations across the proposed scenarios. In S1, the

results for PM2.5 prediction are quite similar, with both models achieving an R^2 of 0.75. However, XGBoost shows a slight advantage in some metrics, such as MAE, where it records a slightly lower value (1.6376) compared to LightGBM (1.654). Similarly, XGBoost exhibits slightly lower RRMSE and MAPE values, at 0.1454 and 10.0227, respectively, compared to 0.1474 and 10.1317 for LightGBM. On the other hand, for PM10 prediction, XGBoost demonstrates a slightly superior performance, with an R^2 value of 0.84 compared to 0.83 for LightGBM. Additionally, XGBoost records lower MAE (6.6538) and RRMSE (0.1595) than LightGBM, as well as a slightly better MAPE (12.2376) compared to LightGBM (12.4313).

In S2, a similar trend is noted. For PM2.5 prediction, LightGBM shows a slight improvement in the R^2 value (0.55) compared to XGBoost (0.54). The MAE and RRMSE values are almost identical for both models, with values around 2.1142 and 0.1810 for XGBoost, and 2.1367 and 0.1810 for LightGBM, respectively. The MAPE values follow a similar trend, at 13.6036 for XGBoost and 13.7412 for LightGBM. For PM10 prediction in this scenario, XGBoost has a slightly higher R^2 (0.69). The MAE, RRMSE, and MAPE values are very similar, with slight differences favoring XGBoost in MAE (8.9187) and RRMSE (0.2156).

At a macro level, both models demonstrate a marked decrease in predictive performance when excluding the PM10 variable for PM25 predictions, and vice versa. This suggests that including both variables is crucial for achieving more accurate predictions. The residual and scatter plots for each target variable and scenario are presented below.

Figure 3

S1 (PM2.5): Scatter and Residual Plots of the XGBoost and LightGBM Models

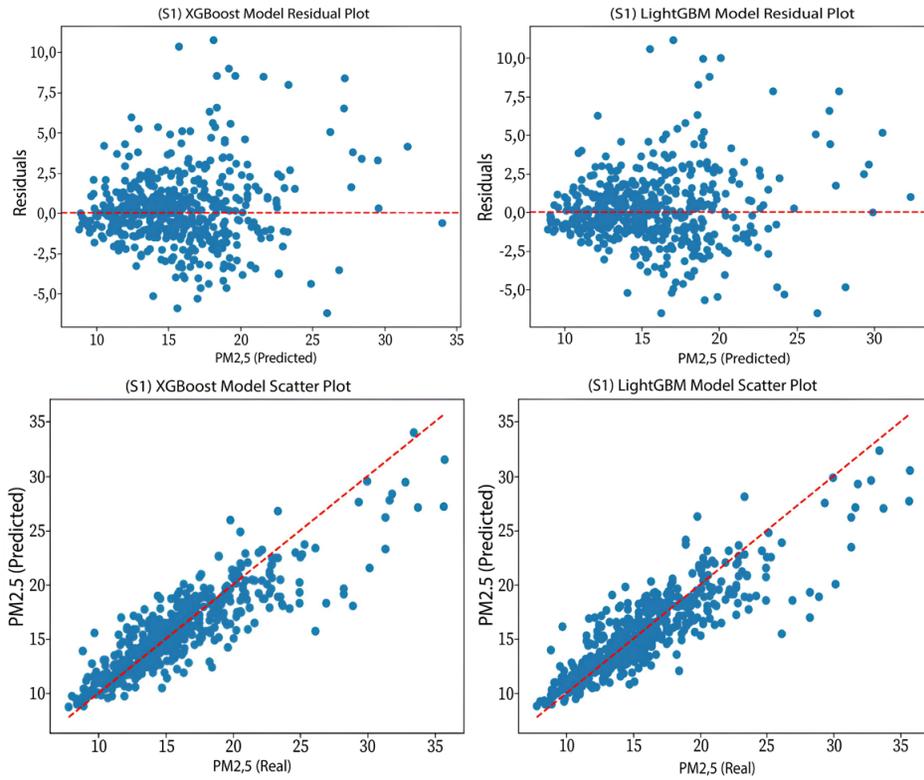


Figure 4

S1 (PM10): Scatter and Residual Plots of the XGBoost and LightGBM Models

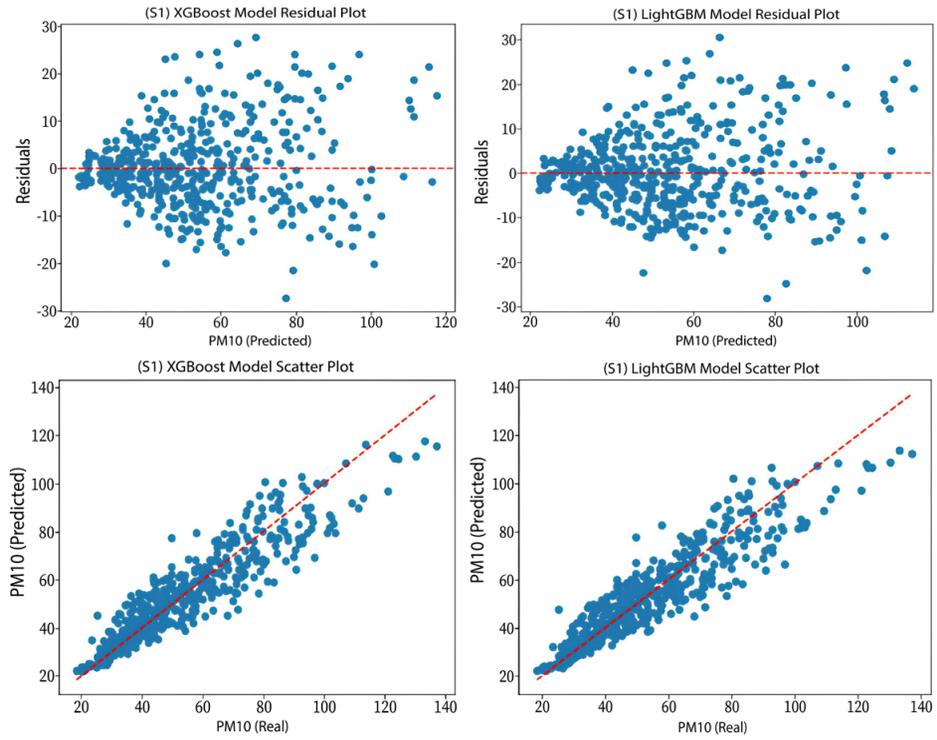


Figure 5

S2 (PM2.5): Scatter and Residual Plots of the XGBoost and LightGBM Models

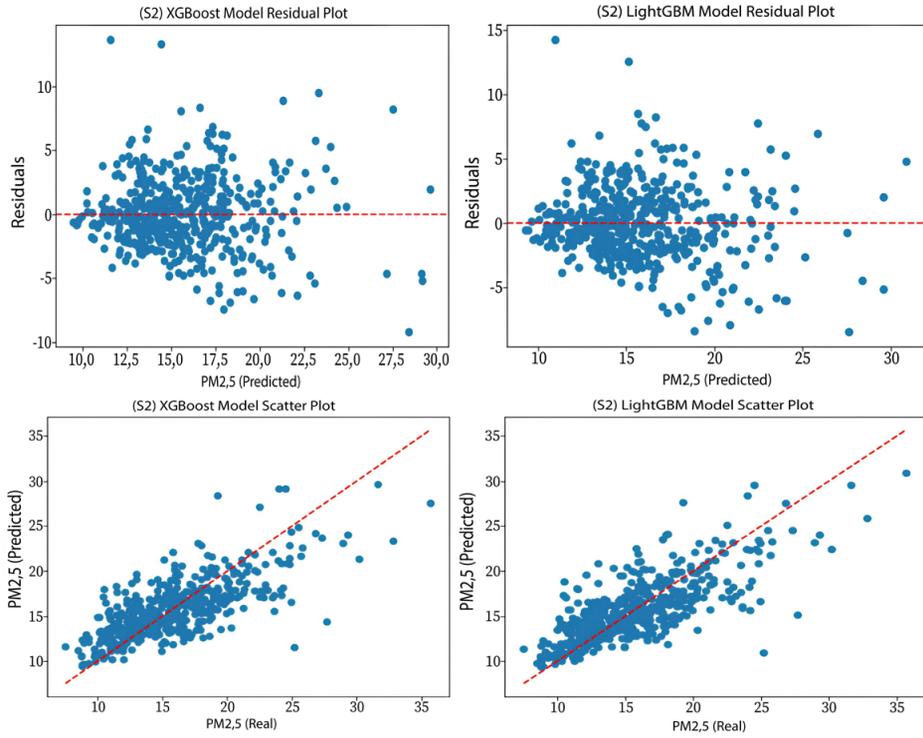


Figure 6

S2 (PM10): Scatter and Residual Plots of the XGBoost and LightGBM Models

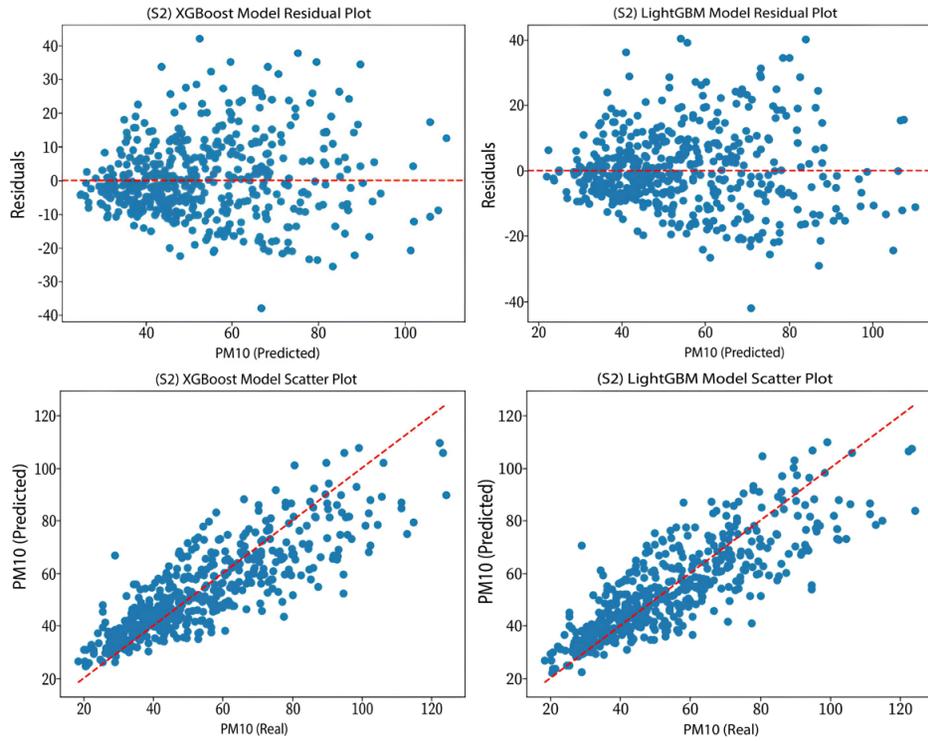


Table 8

Hypothesis T-Test

		T-Statistic	P-Value
S1	PM2,5	-0.1357	0.8921
	PM10	1.4859	0.1380
	PM2,5	-0.4743	0.6355
S2	PM10	-3.042	0.0025

Table 8 shows the paired t-test results comparing the performance of the XGBoost and LightGBM models across both scenarios for PM2.5 and PM10 predictions. In S1, for PM2.5 prediction, the t-statistic was -0.1357, with a p-value of 0.8921. Since this p-value is significantly higher than the 0.05 significance level, there is no statistically significant evidence to reject the null hypothesis, indicating no difference in performance between the XGBoost and LightGBM models for PM2.5.

For PM10 prediction in S1, the t-statistic was 1.4859, with a p-value of 0.1380. Similarly, this p-value exceeds the 0.05 threshold, suggesting insufficient evidence to

conclude that the performance differences between the XGBoost and LightGBM models for PM10 are statistically significant. Therefore, the observed differences in performance metrics for PM10 in this scenario are also not statistically significant.

In S2, for PM2.5 prediction, the t-statistic was -0.4743, with a p-value of 0.6355. This result indicates that, as in S1, the observed differences in performance metrics between the two models are not statistically significant for PM2.5 in this scenario.

Finally, for PM10 prediction in S2, the t-statistic was -3.042, with a p-value of 0.0025. This result suggests that the observed differences in performance metrics for PM10 in this scenario are statistically significant, highlighting a superior performance of one model over the other.

6. DISCUSSION

The results provide a comprehensive assessment of the effectiveness of the XGBoost and LightGBM algorithms in predicting PM2.5 and PM10 concentrations in Lima, Peru. In S1, both algorithms exhibited similar performance in terms of R^2 . Although XGBoost showed a slight improvement in some metrics, such as MAE and RRMSE, especially for PM10 prediction, the paired t-test revealed no statistically significant differences.

In contrast, a significant decrease in predictive performance was observed S2. This highlights the importance of including both variables to achieve more accurate predictions. The strong correlation between PM2.5 and PM10 appears to be critical, and excluding one undermines the predictive capability of the models.

These findings underscore the value of using advanced ML models like XGBoost and LightGBM in addressing complex air pollution problems. The slight performance advantage of XGBoost in certain scenarios could be leveraged to optimize early warning systems and mitigation policies.

7. CONCLUSIONS

One of the main benefits of this research lies in the ability of predictive models to accurately estimate PM2.5 and PM10 concentrations without the need for specialized equipment and machinery for measuring pollutants and climatic conditions. This approach offers significant cost savings, as it avoids the need for expensive equipment with limited spatial coverage. Prediction techniques enable the integration of multiple datasets, offering a broader and more accurate perspective than traditional measurement methods. These capabilities support more effective air quality management and better public health policy planning.

Despite the promising results, the study has some limitations. The analysis was based on data collected from a single monitoring station, which may not fully capture the spatial variability of air pollution across Lima. Additionally, important factors such as

extreme weather conditions, changes in emission sources, precipitation, solar radiation, traffic congestion, and natural events were not considered due to limitation in the available datasets.

8. FUTURE RESEARCH

Future research should consider expanding the geographic scope by incorporating data from multiple monitoring stations distributed across Lima. This would enable a more accurate representation of the spatial variability of air pollution, providing a broader understanding of environmental conditions in different urban and suburban areas. Moreover, extending the data collection period to capture seasonal variations and long-term trends is recommended. Analyzing data over several years could offer deeper insights into how factors such as seasonal climate changes and fluctuations in emissions affect PM_{2.5} and PM₁₀ concentrations.

Another promising area for future research is the development of new variants of ML algorithms specifically adapted for air pollution prediction. This could involve modifying existing algorithms or creating new hybrid approaches that combine the strengths of multiple algorithms. Moreover, it is important to include additional factors that may influence air quality, such as extreme weather conditions, changes in emission sources, precipitation, solar radiation, traffic congestion, and natural events. Incorporating these factors into predictive models could further enhance their accuracy and relevance for air quality management decision-making.

REFERENCES

- Ameer, S., Shah, M. A., Khan, A., Song, H., Maple, C., Islam, S. U., & Asghar, M. N. (2019). Comparative analysis of machine learning techniques for predicting air quality in smart cities, *IEEE Access*, 7, 128325–128338. <https://doi.org/10.1109/ACCESS.2019.2925082>
- Ayus, I., Natarajan, N. & Gupta, D. (2023). Comparison of machine learning and deep learning techniques for the prediction of air pollution: a case study from China, *Asian Journal of Atmospheric Environment*, 17, Article 4. <https://doi.org/10.1007/s44273-023-00005-w>
- Bai, Y., Li, Y., Wang, X., Xie, J., & Li, C. (2016). Air pollutants concentrations forecasting using back propagation neural network based on wavelet decomposition with meteorological conditions, *Atmospheric Pollution Research*, 7(3), 557–566. <https://doi.org/10.1016/j.apr.2016.01.004>
- Cordova, C. H., Portocarrero, M. N. L., Salas, R., Torres, R., Canas, P., & López-Gonzales J. L. (2021). Air quality assessment and pollution forecasting using artificial neural

- networks in Metropolitan Lima-Peru, *Scientific Reports*, 11, Article 24232. <https://doi.org/10.1038/s41598-021-03650-9>
- Gokul, P. R., Mathew, A., Bhosale, A., & Nair, A. T. (2023). Spatio-temporal air quality analysis and PM2,5 prediction over Hyderabad City, India using artificial intelligence techniques, *Ecological Informatics*, 76, Article 102067. <https://doi.org/10.1016/j.ecoinf.2023.102067>
- Gryech, I., Ghogho, M., Elhammouti, H., Sbihi, N., & Kobbane, A. (2020). Machine learning for air quality prediction using meteorological and traffic related features, *Journal of Ambient Intelligence and Smart Environments*, 12(5), 379–391. <https://doi.org/10.3233/AIS-200572>
- Liang, Y-C., Maimury, Y., Chen, A. H-L., & Juarez, J. R. C. (2020). Machine learning-based prediction of air quality, *Applied Sciences*, 10(24), Article 9151. <https://doi.org/10.3390/app10249151>
- Liu, X., Zhao, K., Liu, Z., & Wang, L. (2023). PM2,5 Concentration Prediction Based on LightGBM Optimized by Adaptive Multi-Strategy Enhanced Sparrow Search Algorithm, *Atmosphere*, 14(11), Article 1612. <https://doi.org/10.3390/atmos14111612>
- Martín-Baos, J. Á., Rodríguez-Benitez, L., García-Ródenas, R., & Liu, J. (2022). IoT based monitoring of air quality and traffic using regression analysis, *Applied Soft Computing*, 115, Article 108282. <https://doi.org/10.1016/j.asoc.2021.108282>
- Ministerio del Ambiente. (2021). Plan de acción para la calidad del aire en Lima y Callao. https://cdn.www.gob.pe/uploads/document/file/2090922/PAMCA_Lima-Callao.pdf?v=1629305191
- Pan, B. (2018). Application of XGBoost algorithm in hourly PM2,5 concentration prediction, *IOP Conference Series: Earth and Environmental Science*, 113, Article 012127. <https://doi.org/10.1088/1755-1315/113/1/012127>
- Pan American Health Organization. (2016). Annual report 2016. <https://www.paho.org/annual-report-2016/index.html>
- Servicio Nacional de Meteorología e Hidrología del Perú. (2024). Monitoreo de la Calidad de Aire, para Lima Metropolitana. <https://www.senamhi.gob.pe/?p=calidad-del-aire-estacion&e=112194>
- Shakya, D., Deshpande, V., Goyal, M. K., & Agarwal, M. (2023). PM2,5 air pollution prediction through deep learning using meteorological, vehicular, and emission data: A case study of New Delhi, India, *Journal of Cleaner Production*, 427, Article 139278. <https://doi.org/10.1016/j.jclepro.2023.139278>
- Sloss, L. L., & Smith, I. M. (2000). PM10 and PM2.5: An international perspective. *Fuel Processing Technology*, 65-66, 127–141. [https://doi.org/10.1016/S0378-3820\(99\)00081-8](https://doi.org/10.1016/S0378-3820(99)00081-8)

- Sulaimon, I. A., Alaka, H., Olu-Ajayi, R., Ahmad, M., Ajayi, S. & Hye, A. (2022). Effect of traffic data set on various machine-learning algorithms when forecasting air quality, *Journal of Engineering, Design and Technology*, 22(3), 1030–1056. <https://doi.org/10.1108/JEDT-10-2021-0554>
- Wang, Z., Chen, P., Wang, R., An, Z., & Qiu, L. (2023). Estimation of PM_{2,5} concentrations with high spatiotemporal resolution in Beijing using the ERA5 dataset and machine learning models, *Advances in Space Research*, 71(8), 3150–3165. <https://doi.org/10.1016/j.asr.2022.12.016>
- World Health Organization. (2021). WHO global air quality guidelines: particulate matter (PM_{2,5} and PM₁₀), ozone, nitrogen dioxide, sulfur dioxide and carbon monoxide. <https://apps.who.int/iris/handle/10665/345329>
- World Health Organization. (2022). Air pollution. https://www.who.int/health-topics/air-pollution#tab=tab_1
- Yang, W., Deng, M., Xu, F., & Wang, H. (2018). Prediction of hourly PM_{2,5} using a space-time support vector regression model, *Atmospheric Environment*, 181, 12–19. <https://doi.org/10.1016/j.atmosenv.2018.03.015>
- Zhang, D., & Woo, S. S. (2020). Real time localized air quality monitoring and prediction through mobile and fixed IoT sensing network, *IEEE Access*, 8, 89584–89594. <https://doi.org/10.1109/ACCESS.2020.2993547>
- Zhang, K., Yang, X., Cao, H., Thé, J., Tan, Z., & Yu, H. (2023). Multi-step forecast of PM_{2,5} and PM₁₀ concentrations using convolutional neural network integrated with spatial–temporal attention and residual learning, *Environment International*, 171, Article 107691. <https://doi.org/10.1016/j.envint.2022.107691>

ARTÍCULOS DE REVISIÓN

ANÁLISIS DE CARACTERÍSTICAS EN PROYECTOS DE *BIG DATA*: REVISIÓN SISTEMÁTICA DE LITERATURA

MARIEL LILIANA OJEDA

marielojeda@frba.utn.edu.ar

<https://orcid.org/0009-0003-3529-8994>

Universidad Tecnológica Nacional, Argentina

CINTHIA VEGEA

cinthia.vegea@gmail.com

<https://orcid.org/0000-0002-5382-7875>

Universidad Tecnológica Nacional, Argentina

MARÍA F. POLLO CATTANEO

flo.pollo@gmail.com

<https://orcid.org/0000-0003-4197-3880>

Universidad Tecnológica Nacional, Argentina

Recibido: 4 de octubre del 2024 / Aceptado: 2 de noviembre del 2024

doi: <https://doi.org/10.26439/interfases2024.n020.7457>

RESUMEN. En el desarrollo de proyectos de *big data* se identifican diversas problemáticas que pueden deberse a distintos factores, como la baja calidad de los datos utilizados con anomalías que pueden afectar la precisión de los resultados o la falta de claridad en los objetivos comerciales. Esta situación puede provocar errores en el proceso de toma de decisiones, retrasos en las entregas y hasta la cancelación del proyecto. En este contexto, el presente trabajo surge de la necesidad de recopilar investigaciones previas con el fin de conocer la importancia de la aplicación de una metodología de trabajo en proyectos de *big data*. Se realiza con el objetivo de identificar los enfoques de las metodologías más utilizadas y analizar las características propias de cada una, así como las características comunes o transversales, que permiten la combinación, o adaptación, de distintas metodologías en un mismo proyecto. La generación de grandes volúmenes de datos provenientes de diferentes fuentes y formatos aumenta el desafío de verificar la calidad, ya que pueden presentar anomalías que afecten así la precisión de los resultados obtenidos.

PALABRAS CLAVE: metodología / tecnología *big data* / gestión de datos empresariales

ANALYSIS OF FEATURES IN BIG DATA PROJECTS: A SYSTEMATIC LITERATURE REVIEW

ABSTRACT. In the implementation of big data projects, several problems are identified that may be due to different factors, such as the low quality of the data used with anomalies that may affect the accuracy of the results or the lack of clarity in the business objectives. This situation can lead to errors in the decision making process, delays in deliveries and even the cancellation of the project. In this context, the present work arises from the need to compile previous research in order to know the importance of the application of a working methodology in big data projects. The objective is to identify the approaches of the most used methodologies and to analyze the characteristics of each one, as well as the common or transversal characteristics that allow the combination, or adaptation, of different methodologies in the same project. The generation of large volumes of data from different sources and formats increases the challenge of verifying quality, as they may present anomalies that affect the accuracy of the results obtained.

KEYWORDS: methodology / big data technology / enterprise data management

INTRODUCCIÓN

Uno de los impactos de la globalización es la integración de los mercados. Un mercado globalizado exige a las organizaciones poseer una amplia visión del entorno en el cual actúa, con el afán de poder anticipar las oportunidades y amenazas que pueden emerger (Zúñiga et al., 2023). Como indica Dai et al. (2019), el análisis de la demanda del mercado, junto con los requisitos del cliente, puede ser utilizado para mejorar el diseño y la calidad de los productos.

Constantemente, los usuarios consumidores de bienes y servicios dejan registro de datos personales, financieros, entre otros, en distintas fuentes de almacenamiento. A lo largo de los últimos años, se hizo foco en los datos, los cuales eran considerados como un recurso estratégico de las organizaciones, ya que su proceso de tratamiento ha ayudado a organizaciones públicas y privadas a obtener conocimiento de gran valor (Krasteva & Ilieva, 2021).

Asimismo, el crecimiento continuo de los datos intensifica el desarrollo de proyectos de *big data* (Abdul Hamid et al., 2021), a partir de lo que comienzan a obtenerse beneficios, pero también se identifican nuevos desafíos (Shu et al., 2020). La generación de grandes volúmenes de datos provenientes de diferentes fuentes y formatos aumenta el desafío de verificar la calidad, ya que pueden presentar anomalías que afecten así la precisión de los resultados obtenidos (Caffetti et al., 2023).

En este contexto, Thomas H. Davenport (2006) describe cómo las empresas pueden obtener una ventaja competitiva con el análisis de datos de manera eficaz, dado que (son un insumo básico y clave en la economía del conocimiento; aunque sin el correspondiente refinamiento, procesamiento y análisis, el dato por sí solo no es generador de valor (Ontiveros et al., 2018). Luego del análisis de los datos, se puede extraer información que permite predecir próximos eventos, ahí es cuando comienzan a jugar un rol importante (Dai et al., 2019).

Dado que el crecimiento del volumen, la variedad y la velocidad de la generación de datos requiere de avances tecnológicos que acompañen una mayor capacidad de captura, almacenamiento, procesamiento y análisis, surge *big data* como concepto para el tratamiento de grandes volúmenes. Esto incluye el conjunto de herramientas y técnicas destinadas a extraer todo el valor de los datos para enriquecer y complementar sistemas con capacidades predictivas (Manzano & Avalos, 2023).

Por ello, un ejemplo de implementación de *big data* son las empresas que se dedican al comercio electrónico, ya que utilizan la gran variedad de datos recogidos de sus clientes (Tardío et al., 2020). Eso se transforma en un nuevo activo que alimenta la economía de la información (Manzano & Avalos, 2023).

Considerando que un proyecto se define como un esfuerzo temporal que se lleva a cabo para crear un producto, servicio o resultado único, que tiene un comienzo y un

final definidos, así como un propósito claro, que generalmente busca cumplir con ciertos objetivos o resolver un problema específico (Project Management Institute [PMI], 2017), es necesario contar con un marco de trabajo que dé soporte a la estandarización de procesos, con el fin de minimizar riesgos, mejorar la coordinación y garantizar que se cumplan los objetivos del proyecto a partir del uso de una metodología. Por definición de PMI (2017), una metodología es un sistema de prácticas, técnicas, procedimientos y reglas utilizado por quienes trabajan en una disciplina.

No obstante, la gestión de este tipo de proyectos puede presentar dificultades en su implementación, las cuales generan complicaciones que terminan impidiendo que un proyecto pueda alcanzar a completarse, o bien que el mismo se termine cancelando. Reggio y Astesiano (2020) presentan un estudio de investigación que estima que entre el 60 y 85 % de los proyectos no finalizan exitosamente, sus principales causas son las siguientes: inicio de proyecto con falta de claridad en los objetivos comerciales (o bien puede ocurrir que distintos actores tengan en cuenta requisitos diferentes), falta de experiencia o de conocimiento técnico del equipo e incorrecta identificación del problema.

En los últimos años, se ha trabajado en aproximaciones metodológicas con el objetivo de proporcionar soluciones efectivas. Aunque la mayoría de estas propuestas se basan en el análisis de los requisitos derivados de las diez características de *big data* (las diez *v*) indicadas por Khan et al. (2018), se considera imprescindible describir un escenario como factor clave para la elección de las técnicas y herramientas más adecuadas. Sin embargo, a modo de ejemplo para los casos donde un proyecto se oriente al desarrollo de la arquitectura, de acuerdo con lo mencionado por Tardío et al. (2020), las metodologías existentes no guían el desarrollo con suficiente detalle o no son aplicables.

Por lo tanto, la implementación de una metodología de gestión permite organizar mejor un proyecto, obtener mejores resultados del *software* entregado al cliente y evitar los fracasos (Bahit, 2012). La misma se define de acuerdo con el enfoque del mismo y la problemática a tratar, y se considera que cada metodología cuenta con características propias y características que las asemejan entre sí. En este contexto, el objetivo de este trabajo es realizar una revisión sistemática de la literatura (RSL) sobre las metodologías aplicadas en proyectos de *big data*.

Por esta razón, resulta necesario mencionar la metodología Cross Industry Standard Process for Data Mining (CRISP-DM), por ejemplo, la cual consta de seis fases iterativas, donde según sea necesario, el equipo puede "regresar" a una fase anterior (Saltz & Hotz, 2020). Estas fases configuran el problema empresarial (comprensión del negocio), revisan los datos disponibles (comprensión de datos), desarrollan modelos analíticos (preparación y modelado de datos), evalúan los resultados frente a las necesidades empresariales (evaluación) e implementan el modelo (implementación). Todo el

ciclo está diseñado para ser iterativo y repetirse según sea necesario para mantener los modelos actualizados y eficaces (Ahmad et al., 2022).

Otro marco metodológico a mencionar es Sample, Explore, Modify, Model, and Assess (SEMMA), el cual consta de cinco fases (Saltz & Hotz, 2020). Las características principales de este marco son la extracción de datos para muestreo aleatorio y la exploración de tendencias de datos. Se inicia con una muestra de datos estadísticamente representativa que utiliza estrategias de muestreo. El muestreo es un método utilizado para seleccionar un subconjunto de un grupo que permita obtener conclusiones estadísticas y aproximar las características de toda la población (Ahmad et al., 2022).

El presente trabajo se organiza de la siguiente manera: la primera sección describe la metodología utilizada y el proceso de revisión de literatura, mientras que la segunda sección muestra la interpretación de los resultados. Finalmente, en la tercera sección, se presentan las conclusiones y futuras líneas de trabajo.

1. METODOLOGÍA

De acuerdo con la definición de Kitchenham y Charters (2007), una revisión sistemática de la literatura (RSL) es un medio para identificar, evaluar e interpretar toda la investigación disponible que sea relevante para una pregunta de investigación, un área temática o un fenómeno de interés en particular.

En esta RSL, se siguen las instrucciones y recomendaciones de Kitchenham y Charters, las cuales aplican un método basado en sus aportes, con el fin de evaluar e interpretar el trabajo de investigadores, académicos y profesionales en el campo elegido. El objetivo es la búsqueda y hallazgo de artículos científicos que desarrollen la implementación de metodologías en proyectos de *big data* que permitan la generación de propuestas de futuras líneas de investigación.

A continuación, se describe el protocolo de revisión a utilizar:

- 1.1. Definición de preguntas de investigación
- 1.2. Definición de fuentes de datos
- 1.3. Establecimiento de cadenas de búsqueda
- 1.4. Ejecución de consultas
- 1.5. Proceso de selección

1.1. DEFINICIÓN DE PREGUNTAS DE INVESTIGACIÓN

Dado que el eje principal de esta investigación es conocer la importancia de la aplicación de una metodología de trabajo en proyectos de *big data*, se plantea una serie de interrogantes para dar curso al desarrollo de la presente RSL.

En primer lugar, se definen en la Tabla 1 las preguntas de investigación, junto a la motivación de cada una de ellas, las cuales van a dar lugar al desarrollo del trabajo actual. La definición y establecimiento de las preguntas de investigación orienta la búsqueda y posterior análisis de información, ayudando a cumplir con el objetivo del estudio. Se considera necesaria la RSL buscando dar respuesta a las siguientes preguntas:

Tabla 1

Preguntas de investigación

Ref	Preguntas	Motivación
P11	¿Cuál es el foco de la metodología utilizada aplicada a proyectos de <i>big data</i> ?	Analizar cómo las metodologías abordan las necesidades de los proyectos.
P12	¿Cuáles son las características propias de cada una de las metodologías aplicadas a proyectos de <i>big data</i> ?	Identificar las características únicas de cada metodología para evaluar las fortalezas de las mismas.
P13	¿Cuáles son las características comunes entre las distintas metodologías aplicadas a proyectos de <i>big data</i> ?	Determinar si una metodología puede combinarse en un nuevo aspecto metodológico.

1.2. Definición de fuentes de datos

El segundo paso es definir las fuentes de datos que van a ser consultadas. Se decide realizar una búsqueda automática en los repositorios descritos en la Tabla 2 con el fin de recuperar estudios alineados al propósito del presente estudio.

Tabla 2

Fuentes de datos

Bibliotecas/repositorios	Opciones
Biblioteca digital de ACM	Artículos de congresos, artículos de revistas
IEEE Xplore	Artículos de congresos, artículos de revistas
arXiv	Artículos de congresos, artículos de revistas
Sistema Nacional de Repositorios Digitales	Artículos de congresos, artículos de revistas

1.3. Establecimiento de cadenas de búsqueda

Con el fin de recuperar estudios relevantes que respondan las preguntas de investigación planteadas inicialmente, se definen los términos para realizar las búsquedas, en idioma inglés y español: “metodología”, “metodológica”, “método”, “methodology”, “methodologies”, “methodological”, “method”, “big data”, “data science” y “análisis de datos”. Para las búsquedas se utilizan los términos aplicados en los filtros: título, resumen y palabras clave.

Se construye una cadena de búsqueda que incluye el conjunto de términos indicados anteriormente y se utilizan los operadores booleanos AND y OR para relacionarlos. Por

consiguiente, para la recopilación de los diferentes artículos científicos, se emplea la siguiente cadena de búsqueda:

("Título": metodología OR metodológica OR método OR methodology OR methodologies OR methodological OR method) AND ("Título": "big data" OR "data science" OR "análisis de datos") OR ("Resumen": metodología OR metodológica OR método OR methodology OR methodologies OR methodological OR method) AND ("Resumen": "big data" OR "data science" OR "análisis de datos") AND ("Palabras clave": metodología OR metodológica OR método OR methodology OR methodologies OR methodological OR method) AND ("Palabras clave": "big data" OR "data science" OR "análisis de datos")

1.4. Ejecución de consultas

Con el objetivo de realizar la selección de estudios más representativos en forma adecuada, se definen los criterios de inclusión y exclusión.

Las variables utilizadas son el periodo de tiempo de publicación de artículos, el idioma, la duplicidad de hallazgos y que apliquen con la cadena establecida. Los criterios definidos se encuentran listados a continuación en la Tabla 3.

Tabla 3

Preguntas de investigación

Criterios de inclusión	Criterios de exclusión
Artículos publicados en el periodo: 1/1/2020-30/4/2024	Artículos que no cumplan con el periodo de publicación establecido como criterio de inclusión
Idioma: español o inglés	Idioma: distintos del español o inglés
Artículos que contengan las cadenas definidas en el título, palabras clave o en el resumen	Duplicidad de hallazgo entre repositorios

La primera ejecución se realiza en los cuatro repositorios con los términos de la cadena en ambos idiomas, español e inglés. En la Tabla 4, se visualiza el resultado de la ejecución:

Tabla 4

Resultados de la primera ejecución

Repositorio	Cantidad de resultados
IEEE	802
ACM	219
Sistema Nacional de Repositorios Digitales	12
arXiv	25
Total	1058

Para la segunda etapa, se considera una serie de revisiones desde lo general a lo particular, con el fin de depurar los resultados, que definen este proceso de selección de estudios en cinco fases descritas en el siguiente punto.

1.5. Proceso de selección de estudios

Como parte del proceso de selección de estudios, se define una serie de fases que van a actuar como filtros para obtener el conjunto de estudios primarios.

Las fases se describen a continuación:

- Fase 1: Revisión de artículos con la aplicación de la cadena de búsqueda en los gestores bibliográficos
- Fase 2: Eliminación de estudios duplicados para evitar repetición de información
- Fase 3: Lectura del título, las palabras clave y el resumen del artículo para evaluar su relevancia
- Fase 4: Lectura de la introducción, los resultados y las conclusiones del artículo para obtener una comprensión más profunda del estudio
- Fase 5: Lectura completa del artículo para asegurar su relevancia para la investigación

Al momento de ejecutar la quinta fase, la cantidad de resultados para iniciar la lectura completa de los artículos se visualiza en la Tabla 5.

En esta instancia, la lectura determina el grado de relación del artículo con el tema objeto de la investigación. En esta etapa son descartados 15 artículos por no ser relevantes para las preguntas de investigación planteadas, por lo que finalmente 14 artículos forman parte del resultado de esta investigación.

Tabla 5

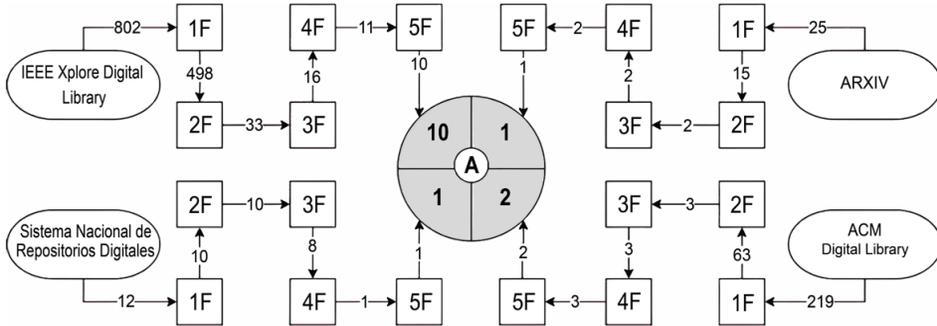
Cadena definitiva por repositorio

Repositorio	Periodo	Cantidad de resultados
IEEE	2020-2024	16
ACM	2020-2024	3
Sistema Nacional de Repositorios Digitales	2020-2024	8
arXiv	2020-2024	2
Total		29

El proceso de selección de estudios primarios se visualiza en la Figura 1, donde se reflejan las fases de filtros aplicados y se especifica en cada instancia la cantidad de estudios resultantes. Al finalizar la lectura se identificará el conjunto de artículos primarios que darán respuesta a las preguntas de investigación planteadas inicialmente.

Figura 1

Selección de estudios primarios



En la Tabla 6, se muestran los estudios primarios junto con el repositorio desde el cual se obtuvieron.

Tabla 6

Detalle de estudios primarios

Artículo	Repositorio
Jin, W., Yang, J., & Fang, Y. (2020). Application methodology of big data for emergency management. En <i>2020 IEEE 11th International Conference on Software Engineering and Service Science (ICSESS)</i> (pp. 326-330). Institute of Electrical and Electronics Engineers. https://doi.org/10.1109/ICSESS49938.2020.9237653	IEEE Xplore
Abdul Hamid, K., Abu Bakar, M., Jalar, A., & Hakim Badarisman, A. (2021). Incorporation of big data in methodology of identifying corrosion factors in the semiconductor package. En <i>2021 International Conference on Electrical, Communication, and Computer Engineering (ICECCE)</i> (pp. 1-4). https://doi.org/10.1109/ICECCE52056.2021.9514240	IEEE Xplore
Kavakli, E., Sakellariou, R., Eleftheriou, I., & Mascolo, J. (2020). Towards a multi-perspective methodology for big data requirements. En <i>2020 IEEE International Conference on Big Data</i> (pp. 5719-5720). Institute of Electrical and Electronics Engineers. https://doi.org/10.1109/BigData50022.2020.9378406	IEEE Xplore
Song, X., Zhang, H., Akerkar, R., Huang, H., Guo, S., Zhong, L., Ji, Y., Opdahl, A. L., Purohit, H., Skupin, A., Pottathil, A., & Culotta, A. (2020). Big data and emergency management: concepts, methodologies, and applications. <i>IEEE Transactions on Big Data</i> , 8(2), 397-419. https://doi.org/10.1109/TBDA-TA.2020.2972871	IEEE Xplore
Tardío, R., Maté, A., & Trujillo, J. (2020). An iterative methodology for defining big data analytics architectures. <i>IEEE Access</i> , 8, 210597-210616. https://doi.org/10.1109/ACCESS.2020.3039455	IEEE Xplore

(continúa)

(continuación)

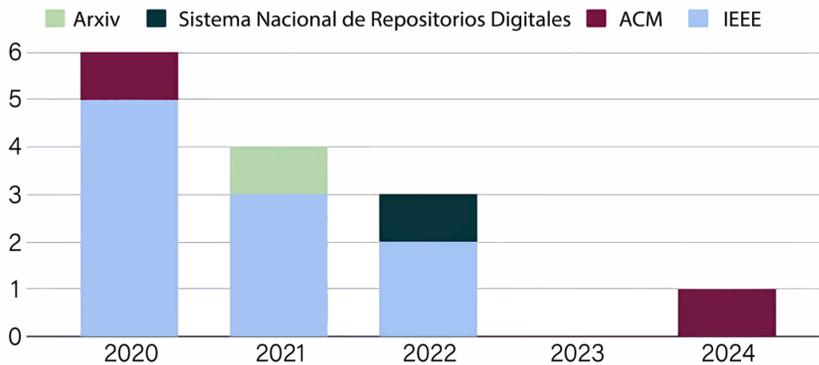
Artículo	Repositorio
Saltz, J., & Hotz, N. (2020). Identifying the most common frameworks data science teams use to structure and coordinate their projects. En <i>2020 IEEE International Conference on Big Data</i> (pp. 2038-2042). Institute of Electrical and Electronics Engineers. https://doi.org/10.1109/BigData50022.2020.9377813	IEEE Xplore
Dastgerdi, A., & Gandomani, T. (2021). On the appropriate methodologies for data science projects. En <i>2021 International Conference on Information Technology</i> (pp. 667-673). Institute of Electrical and Electronic Engineers. https://doi.org/10.1109/ICIT52682.2021.9491712	IEEE Xplore
Krasteva, I., & Ilieva, S. (2021). Adopting agile software development methodologies in big data projects – a systematic literature review of experience reports. En <i>2020 IEEE International Conference on Big Data</i> (pp. 2028-2033). Institute of Electrical and Electronics Engineers. https://doi.org/10.1109/BigData50022.2020.9378118	IEEE Xplore
Funde, S., & Swain, G. (2022). Big data privacy and security using abundant data recovery techniques and data obliviousness methodologies. <i>IEEE Access</i> , <i>10</i> , 105458-205484. https://doi.org/10.1109/ACCESS.2022.3211304	IEEE Xplore
Ahmad, Z., Yaacob, S., Ibrahim, R., & Farahwani, W. (2022). The review for visual analytics methodology. En <i>2022 International Congress on Human-Computer Interaction, Optimization and Robotic Applications</i> (pp. 1-10). Institute of Electrical and Electronics Engineers. https://doi.org/10.1109/HORA55278.2022.9800100	IEEE Xplore
Caffetti, Y. A., Eckert, K., Ruidías, H. J., & Vera Laceiras, M. S. (2023). Data cleansing en entornos big data: mapeo sistemático de la literatura. En S. Rodríguez, M. Giménez y M. A. Molina (Comps.), <i>XXVIII Congreso Argentino de Ciencias de la Computación – CACIC 2022</i> (pp. 75-79). Editorial de la Universidad Nacional de La Rioja. https://repositoriosdigitales.mincyt.gob.ar/vufind/Record/SEDICI_1d437c59c0d397280848f3cfd422df97	Sistema Nacional de Repositorios Digitales
García-Gil, D., García, S., Xiong, N., & Herrera, F. (2021). Smart data driven decision trees ensemble methodology for imbalanced big data. <i>Cognitive Computation</i> , <i>16</i> , 1572-1588. https://doi.org/10.48550/arXiv.2001.05759	arXiv
Shu, W., Sun, W., & Li, Y. (2020). The development trend of design methodology under the influence of artificial intelligence and big data. En <i>ICDLT '20: Proceedings of the 2020 4th International Conference on Deep Learning Technologies</i> (pp. 104-108). Association for Computing Machinery. https://doi.org/10.1145/3417188.3417214	ACM Digital Library
Markopoulos, D., Tsolakidis, A., Karanikolas, N., Marinagi, A., & Skourlas, C. (2024). Applying soft system methodology for a clearer understanding of the future intensive care units. En <i>PCI '23: Proceedings of the 27th Pan-Hellenic Conference on Progress in Computing and Informatics</i> (pp. 163-170). Association for Computing Machinery. https://doi.org/10.1145/3635059.3635084	ACM Digital Library

2. DISCUSIÓN DE RESULTADOS

En base a los datos extraídos, se realiza un análisis que permite dar cuenta de las publicaciones por año, a partir del cual es posible determinar que si bien las publicaciones alcanzan un pico en el año 2021 decrecen en los años posteriores. Ello ha generado una menor cantidad de investigaciones que evidencien la importancia de la aplicación de una metodología de trabajo en proyectos de *big data*. En la Figura 2, se muestra la cantidad de publicaciones realizadas por año, la cual considera el rango 2020-2024 incluido en los criterios de inclusión.

Figura 2

Artículos publicados por año



Como se describe en el protocolo aplicado, la ejecución de la RSL retorna un listado de artículos filtrados hasta la selección final, que conforma un conjunto de artículos relevantes para responder las preguntas de investigación planteadas como parte del presente trabajo.

Los estudios primarios se analizan teniendo en cuenta lo siguiente:

- El tipo de enfoque que busca resolver el problema que dio origen al proyecto.
- Las características comunes entre las distintas metodologías halladas.
- Las características propias de cada una de las metodologías aplicadas.

Para cada uno de los puntos mencionados anteriormente se define una categorización para la posterior clasificación de los artículos, que se presenta en la Tabla 7.

Tabla 7

Definición de categorización de artículos

Dimensión	Categoría
PI1/Tipo de enfoque	Los tipos de enfoque son los siguientes: análisis de problema, aplicación de metodologías, arquitectura, calidad de datos, gestión de emergencias, proceso de obtención de requisitos, reducción de riesgos, seguridad de los datos, toma de decisiones, uso pedagógico.
PI2/Características propias	Las características propias son las siguientes: análisis predictivo de eventos, combinación de métodos, esquema lógico, modelo conceptual, modelos de innovación, métodos de recuperación de datos, obtención de requisitos, proceso de entrega de valor, proceso de limpieza de datos, retroalimentación, toma de decisiones.
PI3/Características comunes	Las características comunes son las siguientes: análisis de datos, análisis del contexto, guía del proceso, metodología iterativa, perspectiva multidisciplinaria, resolución de problema complejo.

Se analizan los trabajos desarrollados en 14 artículos de investigación, los cuales fueron considerados como “estudios primarios”. El resultado de la RSL muestra particularidades en cada metodología aplicada, que permiten su implementación cuando el proyecto cuenta con determinadas características.

La aplicación de metodologías se enfoca principalmente en mitigar los riesgos en los que se puede incurrir por no llevar adecuadamente el análisis de la problemática a resolver (García-Gil et al., 2021; Shu et al., 2020), por niveles bajos en la calidad de los datos (Caffetti et al., 2023; García-Gil et al., 2021). Por ende, ello puede generar errores en el proceso de toma de decisiones (Markopoulos et al., 2024; Tardío et al., 2020; Jin et al., 2020).

Los artículos resultantes muestran que una metodología no aplica a todos los casos, ya que el contexto en el cual se desarrolla el proyecto es determinante y cada metodología tiene características propias que hacen que se pueda aplicar con mayor éxito en un universo de casos y en otros no. Entre las principales características que se identifican en los artículos, se destacan la flexibilidad para permitir la combinación de diferentes métodos de trabajo (García-Gil et al., 2021; Kavakli et al., 2020) y el enfoque en dar soporte al proceso de toma de decisiones (Markopoulos et al., 2024; Song et al., 2020).

Se observan características propias entre las metodologías utilizadas, así como se identifican características comunes que permiten hallar la metodología que aplique mejor con los requerimientos del proyecto. Entre las características comunes destacadas, pueden mencionarse el análisis de datos (García-Gil et al., 2021; Krasteva & Ilieva, 2021), el trabajo desde una perspectiva multidisciplinaria (Shu et al., 2020; Song et al., 2020; Ahmad et al., 2022), y la implementación de un proceso de fases iterativas (Caffetti et al., 2023; Tardío et al., 2020; Jin et al., 2020).

A continuación, se contesta cada una de las preguntas de investigación:

PI1: ¿Cuál es el foco de la metodología utilizada aplicada a proyectos de big data?

Shu et al. (2020) realizan un análisis de la situación actual en el ámbito del diseño de innovación de productos. En ese sentido, plantean que la innovación y el desarrollo tradicional de nuevos productos requieren que las empresas realicen enormes inversiones de recursos humanos y materiales para hacer frente a cambios rápidos del mercado; sus dificultades de diseño son cada vez más difíciles. Ante ello, cualquier empresa debe enfrentar los riesgos en el proceso de desarrollo de productos, incluso para grandes empresas. Se establece la idea de diseño innovador impulsado por algoritmos para establecer un modelo diferente del diseño de innovación de productos tradicionales y promover el desarrollo de teorías y métodos de desarrollo de innovación basados en datos.

Por otra parte, Jin et al. (2020) basan su modelado en un análisis previo de la demanda real. Se sostiene que el desglose y claridad con que se deben presentar los elementos centrales que componen el objetivo del desarrollo permitirán determinar el modelado y, a partir de ahí, seleccionar el algoritmo a aplicar.

De la misma forma en que Jin et al. (2020) plantean el enfoque en el análisis del problema, Abdul Hamid et al. (2021) indican que la identificación de las probables causas raíz es la piedra angular de la resolución de problemas. Así, esta representa la base de la mejora continua donde la lección aprendida es una parte integral de la misma.

Continuando con el enfoque que se plantea de abordar adecuadamente las características de los requisitos tempranos, Kavakli et al. (2020) desarrollan la interacción entre las intenciones del negocio y la funcionalidad del sistema, con el objetivo de alinear las necesidades empresariales y los requisitos, tanto del usuario como del sistema, ya que luego se conceptualizan en objetivos fundamentales para conseguir valor.

Es necesario determinar el contexto en el cual se desarrolla el proyecto de Krasteva e Ilieva (2021), que proporciona información relevante para mitigar los casos que no permiten que un proyecto alcance a completarse.

Tardío et al. (2020) identifican la falta de conocimiento profesional en el uso de la tecnología *big data* como el principal problema actual que impide a las empresas su adopción con éxito. De este modo, presentan una guía para la selección de las herramientas y técnicas que posteriormente darán paso a la construcción de una correcta arquitectura del sistema.

La calidad de datos se ve referenciada también por Caffetti et al. (2023), donde se plantea la necesidad de una adecuada limpieza de los datos, ya que, a grandes volúmenes provenientes de diferentes fuentes y formatos, aumenta el desafío de verificar la calidad de los mismos, que pueden ser imprecisos, presentar anomalías o no ser adecuados

para el análisis o procesamiento, que afecten así la precisión de los resultados obtenidos. La ausencia de datos, valores ficticios o predeterminados, ruido, datos erróneos, datos inconsistentes, datos crípticos, claves primarias duplicadas, identificadores no únicos, campos multipropósito y violación de reglas comerciales son problemas que pueden ser contrarrestados por una correcta limpieza de datos, lo que permita garantizar las fases siguientes de análisis.

Otro enfoque identificado en los artículos encontrados es el de la seguridad con el fin de preservar la privacidad de la información que se está gestionando, ya que los piratas informáticos explotan las plataformas de *big data* para lanzar ataques contra las organizaciones. Frente a ello, Funde y Swain (2022) presentan diferentes técnicas para preservar la privacidad de los datos con enfoques criptográficos y no criptográficos.

Si bien se considera cada vez más a los datos como un recurso estratégico para la organización, con el fin de obtener una ventaja competitiva es necesario aprovecharlos mediante análisis (Saltz & Hotz, 2020), y se ha observado que existen desafíos importantes al tratar de aprovechar los datos estratégicamente.

El último enfoque identificado está relacionado con la dinámica de equipo, ya que, a medida que aumenta el volumen de datos, aumenta la cantidad de recursos que tienen que intervenir en un proyecto, de modo que se deja de trabajar individuos en forma aislada para volverse un equipo de trabajo (Dastgerdi & Gandomani, 2021). Es en este punto donde surge el riesgo de que el rendimiento del equipo no sea óptimo. Por lo tanto, la cuestión principal es cómo se puede garantizar que el equipo trabaje de forma eficiente y eficaz.

PI2: ¿Cuáles son las características propias de cada una de las metodologías aplicadas a proyectos de big data?

Dentro de las principales propiedades de cada una de las metodologías identificadas, se encuentra el trabajo realizado por Shu et al. (2020), donde la implementación de algoritmos en el modelado permite sistemas innovadores que logran alcanzar mayor inteligencia, paralelismo y escalabilidad que las técnicas tradicionales. La propuesta de Shu et al. (2020) se centra en el desarrollo de un algoritmo inteligente basado en un modelo básico de demanda de usuario, que combina métodos cualitativos y cuantitativos, con el uso de técnicas como redes neuronales; parte de la recuperación y el análisis correspondiente de información para optimizar el proceso de innovación de productos. La puesta en práctica del modelado de algoritmos eficaces para el análisis inteligente es mencionada por Jin et al. (2020) como muestra de gran aporte a la obtención de un resultado exitoso. En este último artículo también se destaca la retroalimentación entre etapas (Jin et al., 2020), lo que genera la mejora continua del proceso.

La identificación de problemas es la base de la mejora continua y, ante el incremento de su complejidad, resulta oportuno adoptar un enfoque alternativo para su

resolución. Una posibilidad de hacer frente a la resolución de problemas complejos es la combinación de diferentes marcos de trabajo, lo que es tratado por Abdul Hamid et al. (2021) como una estrategia eficaz y efectiva para resolver un problema complejo. En la misma línea, García-Gil et al. (2021) mencionan la combinación de diferentes métodos de preprocesamiento de datos para mejorar la calidad de los mismos.

Otra característica que se destaca por Kavakli et al. (2020) es la priorización de los requisitos de *big data* desde diferentes perspectivas y en etapas tempranas. Esto permite una mejor alineación entre los objetivos del negocio y el comportamiento que debe poseer el sistema a desarrollar, lo cual resulta con alta relevancia al garantizar una trazabilidad entre el negocio y el rendimiento del sistema.

El modelado de los requisitos también es una característica a destacar como un punto de alta importancia, donde Tardío et al. (2020) indican que incurrir en errores en la toma de requisitos puede conducir al fracaso del proyecto. El trabajo desarrollado por Tardío et al. (2020) propone una metodología iterativa compuesta de cinco fases, donde a su vez cada una de ellas contiene múltiples subprocesos y se basa en el análisis de requisitos no funcionales derivados de las características de *big data*. Estos requisitos se utilizan como entrada para que el algoritmo propuesto genere una estructura inicial que se va a ir refinando sucesivamente durante las fases.

PI3: ¿Cuáles son las características comunes entre las distintas metodologías aplicadas a proyectos de big data?

Shu et al. (2020) destacan el análisis interdisciplinario hecho por profesionales de campos relacionados con la tecnología de la información, la inteligencia artificial y el *big data*, así como por profesionales vinculados con el conocimiento sociológico en los campos de la psicología, el comportamiento, la estética y la filosofía, los cuales también influyen en el desarrollo de una investigación. Contar con un equipo multidisciplinario permite el cruzamiento de diferentes contextos con el fin de incrementar y mejorar la comunicación entre el personal del equipo de trabajo (Markopoulos et al., 2024). Incorporar un enfoque multiperspectivo logra que se integren la comprensión del negocio, la integración de datos, la estadística, las hipótesis, el modelado, la visualización y el razonamiento analítico a lo largo del ciclo de vida del desarrollo de proyectos de *big data* (Ahmad et al., 2022).

Plantear la metodología como una guía en la identificación de diferentes requisitos es mencionado por Kavakli et al. (2020) y para el presente análisis es identificado como una característica común en el resto de los otros marcos de trabajo.

Otra de las características comunes a las metodologías es que las mismas sean iterativas para fomentar la retroalimentación que ayude a los profesionales de la tecnología de la información (TI) en la definición y validación de arquitecturas *big data* (Tardío et al., 2020). La iteración sobre las fases definidas permite la detección y corrección de errores, para así obtener resultados que colaboren en el proceso de toma de decisiones (Caffetti et al., 2023).

La búsqueda constante para trabajar con datos de calidad se menciona por García-Gil et al. (2021) donde se indica que la calidad de los datos se consigue mediante la aplicación de varias técnicas de preprocesamiento de datos para permitir diferentes enfoques del conjunto de datos.

3. CONCLUSIONES

En el presente trabajo se han revisado las diferentes metodologías aplicadas en proyectos de *big data* con el fin de dar respuesta a las preguntas de investigación planteadas inicialmente.

En la actualidad, las industrias deben dar una pronta e innovadora respuesta a las demandas del mercado, las cuales consideran que la masividad de los datos complejiza la resolución de problemas y el proceso de resolución genera altos costos.

Se analizan trabajos que reconocen a la gestión de los datos como parte importante dentro de un proyecto de *big data*, cuya imprecisa definición de los requerimientos puede llevar al fracaso. Incluso, la baja calidad de los datos puede resultar en problemas futuros, como inconsistencias, mientras que la imprecisión de resultados obtenidos podría conducir a una errónea toma de decisiones. Asimismo, la base de este tipo de proyectos es el análisis de la demanda comercial, los elementos y las necesidades del negocio, como así los procesos de etapas iterativas que permiten el modelo inicial.

En cuanto a limitaciones técnicas, se pueden mencionar la falta de experiencia para guiar el desarrollo de arquitecturas de *big data* y la necesidad de contar con medidas de seguridad que impidan ataques cibernéticos. Se reconoce la necesidad de contar con perspectivas multidisciplinarias que promuevan el trabajo colaborativo y creativo.

Por lo tanto, se requieren investigaciones futuras que permitan indagar y continuar desarrollando enfoques colaborativos entre distintos roles, dada la variedad de las temáticas identificadas como probables causas raíz que llevan al fracaso de los proyectos.

La presente revisión permite identificar puntos de interés para dar continuidad a futuras líneas de investigación de estudios que puedan aportar nuevos conocimientos que sean de relevancia en el campo de la gestión de proyectos de *big data*. Por ello, se enfatiza en la necesidad de abordar la definición, el análisis y la especificación de los requisitos funcionales y no funcionales, los cuales se consideran desde diferentes perspectivas con el objetivo de lograr una mejor armonización entre las metas del negocio y las funcionalidades del sistema a desarrollar como propuesta de solución.

REFERENCIAS

Abdul Hamid, K., Abu Bakar, M., Jalar, A., & Hakim Badarisman, A. (2021). Incorporation of big data in methodology of identifying corrosion factors in the semiconductor

- package. En *2021 International Conference on Electrical, Communication, and Computer Engineering (ICECCE)* (pp. 1-4). <https://doi.org/10.1109/ICECCE52056.2021.9514240>
- Ahmad, Z., Yaacob, S., Ibrahim, R., & Farahwani, W. (2022). The review for visual analytics methodology. En *2022 International Congress on Human-Computer Interaction, Optimization and Robotic Applications* (pp. 1-10). Institute of Electrical and Electronics Engineers. <https://doi.org/10.1109/HORA55278.2022.9800100>
- Bahit, E. (2012). *Scrum & Extreme Programming (para programadores)*. Creative Commons.
- Caffetti, Y. A., Eckert, K., Ruidías, H. J., & Vera Laceiras, M. S. (2023). Data cleansing en entornos big data: mapeo sistemático de la literatura. En S. Rodríguez, M. Giménez y M. A. Molina (Comps.), *XXVIII Congreso Argentino de Ciencias de la Computación – CACIC 2022* (pp. 75-79). Editorial de la Universidad Nacional de La Rioja. https://repositoriosdigitales.mincyt.gob.ar/vufind/Record/SEDICI_1d437c59c0d397280848f3cfd422df97
- Dai, H.-N., Wang, H., Xu, G., Wan, J., & Imran, M. (2019). Big data analytics for manufacturing internet of things: opportunities, challenges and enabling technologies. *Enterprise Information Systems*, 14(9-10), 1279-1303. <https://doi.org/10.48550/arXiv.1909.00413>
- Dastgerdi, A., & Gandomani, T. (2021). On the appropriate methodologies for data science projects. En *2021 International Conference on Information Technology* (pp. 667-673). Institute of Electrical and Electronic Engineers. <https://doi.org/10.1109/ICIT52682.2021.9491712>
- Davenport, T. (2006). *Competing on Analytics*. Harvard Business Review <https://hbr.org/2006/01/competing-on-analytics>
- Funde, S., & Swain, G. (2022). Big data privacy and security using abundant data recovery techniques and data obliviousness methodologies. *IEEE Access*, 10, 105458-205484. <https://doi.org/10.1109/ACCESS.2022.3211304>
- García-Gil, D., García, S., Xiong, N., & Herrera, F. (2021). Smart data driven decision trees ensemble methodology for imbalanced big data. *Cognitive Computation*, 16, 1572-1588. <https://doi.org/10.48550/arXiv.2001.05759>
- Jin, W., Yang, J., & Fang, Y. (2020). Application methodology of big data for emergency management. En *2020 IEEE 11th International Conference on Software Engineering and Service Science (ICSESS)* (pp. 326-330). Institute of Electrical and Electronics Engineers (IEEE). <https://doi.org/10.1109/ICSESS49938.2020.9237653>
- Kavakli, E., Sakellariou, R., Eleftheriou, I., & Mascolo, J. (2020). Towards a multi-perspective methodology for big data requirements. En *2020 IEEE International*

- Conference on Big Data* (pp. 5719-5720). Institute of Electrical and Electronics Engineers. <https://doi.org/10.1109/BigData50022.2020.9378406>
- Khan, N., Alsaqer, M., Shah, H., Badsha, G., Abbasi, A., & Salehian, S. (2018). The 10 Vs, Issues and Challenges of Big Data. En *ICBDE '18* (pp. 52-56). Association for Computing Machinery. <https://doi.org/10.1145/3206157.3206166>
- Kitchenham, B., & Charters, S. (2007). *Guidelines for performing Systematic Literature Reviews in Software Engineering*. Keele University; Durham University Joint Report.
- Krasteva, I., & Ilieva, S. (2021). Adopting agile software development methodologies in big data projects – a systematic literature review of experience reports. En *2020 IEEE International Conference on Big Data* (pp. 2028-2033). Institute of Electrical and Electronics Engineers. <https://doi.org/10.1109/BigData50022.2020.9378118>
- Manzano, F., & Avalos, D. (2023). Análisis de calidad de los datos en las estadísticas públicas y privadas, ante la implementación del Big Data. *Ciencias Administrativas*, 11(22), 1-11. <https://doi.org/10.24215/23143738e119>
- Markopoulos, D., Tsolakidis, A., Karanikolas, N., Marinagi, A., & Skourlas, C. (2024). Applying soft system methodology for a clearer understanding of the future intensive care units. En *PCI '23: Proceedings of the 27th Pan-Hellenic Conference on Progress in Computing and Informatics* (pp. 163-170). Association for Computing Machinery. <https://doi.org/10.1145/3635059.3635084>
- Ontiveros, E. (Dir.), Sabater, V. (Coord.), Vizcaíno, D., Romero, M., & Llorente, A. (2018). *Economía de los datos. Riqueza 4.0*. Fundación Telefónica, Ariel España.
- Project Management Institute. (2017). *A guide to the project management knowledge. PMBOK Guide* (6.ª ed).
- Reggio, G., & Astesiano, E. (2020). Big-Data/Analytics projects failure: A literature review. En *2020 46th Euromicro Conference on Software Engineering and Advanced Applications* (pp. 246-255). <https://doi.org/10.1109/SEAA51224.2020.00050>
- Saltz, J., & Hotz, N. (2020). Identifying the most common frameworks data science teams use to structure and coordinate their projects. En *2020 IEEE International Conference on Big Data* (pp. 2038-2042). Institute of Electrical and Electronics Engineers. <https://doi.org/10.1109/BigData50022.2020.9377813>
- Shu, W., Sun, W., & Li, Y. (2020). The development trend of design methodology under the influence of artificial intelligence and big data. En *ICDLT '20: Proceedings of the 2020 4th International Conference on Deep Learning Technologies* (pp. 104-108). Association for Computing Machinery. <https://doi.org/10.1145/3417188.3417214>

- Song, X., Zhang, H., Akerkar, R., Huang, H., Guo, S., Zhong, L., Ji, Y., Opdahl, A. L., Purohit, H., Skupin, A., Pottathil, A., & Culotta, A. (2020). Big data and emergency management: concepts, methodologies, and applications. *IEEE Transactions on Big Data*, 8(2), 397-419. <https://doi.org/10.1109/TBDDATA.2020.2972871>
- Tardío, R., Maté, A., & Trujillo, J. (2020). An iterative methodology for defining big data analytics architectures. *IEEE Access*, 8, 210597-210616. <https://doi.org/10.1109/ACCESS.2020.3039455>
- Zúñiga, F., Mora Poveda, D., & Llerena Llerena, W. (2023). El Big Data y su implicación en el marketing. *Revista de Comunicación de la SEECI*, 56, 302-321. <https://doi.org/10.15198/seeci.2023.56.e832>

DATOS DE LOS AUTORES

JORGE CRISTHOFER ALCÁNTARA VÁSQUEZ

Estudiante de Ingeniería Mecatrónica en la Universidad Nacional de Trujillo, con interés en control, robótica, diseño y automatización. Actualmente forma parte del grupo de investigación en Energía y Sistemas de Control Energético (ENERGYCON) de la Universidad Nacional de Trujillo.

ANA BEATRIZ ALVAREZ

Doctora y magíster en Ingeniería Eléctrica por la Universidade Estadual de Campinas (2011 y 2004 respectivamente), también realizó un doctorado sánguiche en la Universidad de Alcalá (2008-2009), un posdoctorado en la misma universidad (2011-2013) y una estancia postdoctoral en la Universidad Nacional San Antonio Abad del Cusco (2018-2019). Ingeniera electrónica por la Universidad Nacional del Altiplano (2000) e ingeniera eléctrica por la Universidade Federal de Minas Gerais (2013), actualmente es profesora titular en la Universidade Federal do Acre (Brasil) y coordinadora general del proyecto PAVIC-Lab. Tiene experiencia en inteligencia computacional, visión computacional, y sistemas de control y automatización.

JOEL ARAGÓN VALLADARES

Magíster e ingeniero de las telecomunicaciones por la Pontificia Universidad Católica del Perú. Amplia experiencia en la planificación, diseño e ingeniería RAN. Lideró la planificación e ingeniería para despliegue móvil en zonas rurales para RAN como NAAS para Telefónica, Entel y Claro, pilotos de nuevas soluciones de RAN tradicional, virtualizada, OpenRAN y RAN en HAPS. Especialista en redes LAN y WLAN, modelamiento y generación de tráfico, calidad de servicio, seguridad de la información, programación y sistemas de código abierto.

OLDA BUSTILLOS ORTEGA

Graduada de la maestría en Informática, con especialidad en Auditoría Informática, por la Universidad Latina de Costa Rica. Actualmente, se desempeña como directora de la Escuela de Ingeniería Informática y como docente investigadora en la Universidad Internacional de las Américas. Ha participado en la XI Conferencia “Servicios creativos y modernos para el comercio y desarrollo sostenible” de la Red Latinoamericana y Caribeña para la Investigación en Servicios (REDLAS), en la The 2022 International Conference on Information Technology & Systems (ICITS’22), y fue reconocida como Académica Honoraria de la International Academy of Social Sciences (IASS) en Palm Beach, Florida, USA. Sus principales intereses de investigación incluyen la inteligencia artificial, la ciberseguridad y el desarrollo de sistemas inteligentes.

MARÍA IRENE CARRILLO MAYANQUER

Médico, especialista en pediatría por la Pontificia Universidad Católica del Ecuador. Actualmente, es profesora en el departamento de Ciencias de la Salud de la Universidad Técnica Particular de Loja (UTPL), Ecuador. Sus intereses de investigación incluyen patologías del niño y del adolescente, crecimiento, lactancia materna, malnutrición infantil.

MAURICIO CISNEROS

Graduado en Ingeniería de Sistemas por la Universidad de Lima, se especializó en Ciencias de la Computación. Es desarrollador *fullstack* y sus áreas de interés incluyen computación cuántica, ciencias de la computación y desarrollo de *software*.

UENDEL DIEGO DA SILVA ALVES

Ingeniero eléctrico graduado por la Universidade Federal do Acre, Brasil. Actualmente, es investigador en el PAVIC-Lab, donde trabaja proyectos vinculados a las ciencias exactas y tecnológicas.

EDWIN JHONATAN ESCOBEDO CÁRDENAS

Doctor y magíster en Ciencias de la Computación por la Universidade Federal de Ouro Preto, Brasil y bachiller en Ciencias de la Computación e Ingeniería Informática por la Universidad Nacional de Trujillo. Actualmente se desempeña como docente en la carrera de Ingeniería de Sistemas de la Universidad de Lima y es investigador registrado en RENACYT. Sus áreas de interés incluyen la visión computacional, el aprendizaje automático (*machine learning*) y la ciencia de datos.

RENÉ RONALDO GUTIÉRREZ CÓRDOVA

Estudiante de Ingeniería Mecatrónica en la Universidad Nacional de Trujillo (tercio superior), con interés en robótica y control avanzado. Actualmente pertenece al grupo de investigación en Energía y Sistemas de Control Energético (ENERGYCON) de la Universidad Nacional de Trujillo.

EDGAR ANDRE MANZANO RAMOS

Doctorando en Ciencias con mención en Energética de la Universidad Nacional de Ingeniería, magíster en Ingeniería Mecatrónica por la Pontificia Universidad Católica del Perú y bachiller en Ingeniería Electrónica por la Universidad Nacional del Altiplano. Es docente auxiliar en la Universidad Nacional de Trujillo y forma parte del grupo de investigación Energía y Sistemas de Control Energético (ENERGYCON) de la Universidad Nacional de Trujillo, donde realiza investigaciones en identificación y control de sistemas dinámicos, electrónica de potencia y energías renovables.

JORGE MURILLO GAMBOA

Graduado de la maestría en Computación, con especialidad en Telemática, por el Instituto Tecnológico de Costa Rica. Actualmente se desempeña como docente investigador. Ha recibido varios premios, como el reconocimiento de "Valued member and supporter" (junio de 2016) y el "Certificate of appreciation" (diciembre de 2014) por la IEEE Computer Society. Sus principales intereses de investigación incluyen la inteligencia artificial, la ciberseguridad y las habilidades y competencias digitales según el modelo SFIA.

HERNÁN NINA HANCO

Doctor en Ingeniería de Sistemas por la Universidad Nacional Federico Villarreal, magíster en Administración por la Universidad Nacional de San Antonio Abad del Cusco, magíster en Informática con mención en Ingeniería de *Software* por la Pontificia Universidad Católica del Perú. Nina es también ingeniero informático y de sistemas. Está registrado como investigador en RENACYT y actualmente es profesor de la Universidad de Lima, Perú. Sus áreas de interés incluyen ingeniería y desarrollo seguro de *software*, innovación en la educación superior e interacción humano-computadora. Es miembro activo de ACM e IEEE.

OLMAN NÚÑEZ PERALTA

Licenciado en la maestría en Base de Datos por la Universidad CENFOTEC, Costa Rica. En la actualidad se desempeña como docente e investigador, con principales intereses en bases de datos, *machine learning* e inteligencia artificial.

JOHAN A. OBLITAS MANTILLA

Bachiller en Ingeniería de Sistemas por la Universidad de Lima (décimo superior), donde se especializó principalmente en ingeniería de *software*. Actualmente cursa una maestría en Ingeniería Eléctrica e Informática (ECE) en la Universidad de Oklahoma, donde previamente realizó dos pasantías en el Centro de Investigación de Radar Avanzado, aplicando conocimientos en electromagnetismo y teledetección, en colaboración con el Grupo de Investigación y Desarrollo de Antenas en Fase (PAARD). Su experiencia abarca procesos como la caracterización de materiales, corte por láser y simulación electromagnética, además de brindar soporte en el mantenimiento y desarrollo del sitio web oficial de PAARD. Entre sus competencias en informática se destacan el desarrollo web, programación en Java, Python, JavaScript y C++, gestión de bases de datos, análisis de datos y gestión de procesos.

MARIEL LILIANA OJEDA

Licenciada en Informática por la Universidad Nacional de Lomas de Zamora, Argentina, actualmente cursa una maestría en Ingeniería en Sistemas de Información en la Universidad Tecnológica Nacional, Argentina. Sus intereses de investigación incluyen marcos de trabajo ágiles y metodologías.

JAVIER OLAZABAL

Ingeniero de sistemas de la Universidad de Lima, trabaja con un enfoque en el desarrollo y análisis de algoritmos. Es analista de integraciones y sus áreas de investigación incluyen computación cuántica, criptografía y análisis computacional.

QUEFREN OLIVEIRA LEHER

Investigador en la Universidade Federal do Acre (PAVIC-Lab) en Brasil. Participa en proyectos relacionados con el análisis de imágenes mediante aprendizaje profundo y tiene publicaciones destacadas como el artículo *Exploratory Analysis Using Deep Learning for Water-Body Segmentation of Peru's High-Mountain Remote Sensing Images*, publicado en la revista *Sensors* en 2024.

JUAN ANTONIO PACO FERNÁNDEZ

Ingeniero electrónico graduado de la Pontificia Universidad Católica del Perú y candidato a magíster en Gerencia de Tecnologías de Información por CENTRUM PUCP. Actualmente se desempeña como coordinador. Fue nominado finalista en el Concurso Nacional de

Inventores 2022 y, junto con varios colegas, obtuvo el primer puesto en el concurso internacional IEEE Connecting the Unconnected Challenge 2021, en la modalidad Modelo de Negocio. En la edición 2024 del mismo concurso, lograron el primer puesto en la modalidad Aplicación de la Tecnología. Sus principales áreas de interés incluyen redes inalámbricas, redes de sensores, aplicaciones tecnológicas para entornos rurales y *machine learning*.

THUANNE PAIXÃO

Magíster en Ciencias de la Computación por la Universidade Federal do Acre, Brasil (2023), con una especialización en Seguridad de la Información por el Centro Universitario Estácio de Ribeirão Preto, Brasil (2021) y el título en Sistemas de Información por la Universidade Federal do Acre, Brasil (2019). Tiene experiencia en inteligencia artificial, robótica y seguridad de la información. Actualmente participa como investigadora en el proyecto de I+D de investigación aplicada en visión e inteligencia computacional (PAVIC-Lab), una colaboración entre UFAC, Motorola, Flextronics y FUNDAPE, en Brasil.

MARÍA F. POLLO CATTANEO

Doctora en Ciencias de la Computación por la Universidad Nacional de La Plata, Argentina; magíster en Ingeniería de *Software* por la Universidad Politécnica de Madrid, España; especialista en Construcción de Sistemas Expertos por el Instituto Tecnológico de Buenos Aires, e ingeniera en Sistemas de Información por la Universidad Tecnológica Nacional, Argentina. Actualmente es directora del grupo GEMIS y profesora titular concursada en la UTN FRBA, Argentina. Ha recibido el premio Dr. Raúl Gallard en 2019. Sus intereses de investigación incluyen inteligencia artificial, sistemas de información, informática y gestión del conocimiento.

RIVER QUISPE TACAS

Ingeniero electrónico orientado al desarrollo tecnológico de proyectos de telecomunicaciones para zonas rurales. Ha trabajado en el GTR-PUCP en varios proyectos, encargándose del diseño de la red de datos y de los servicios, su implementación y la realización de las respectivas pruebas. Estas redes fueron implementadas utilizando como tecnología de interconexión a enlaces inalámbricos de larga distancia. Ha participado en el despliegue de la red del río Napo (Loreto), río Putumayo (frontera Perú-Colombia), Acomayo (Cusco) y San Pablo (Cajamarca), donde los beneficiados utilizan servicios como la telefonía y el internet. Estos proyectos han beneficiado a la comunicación de las entidades de salud públicas y otras entidades municipales. Actualmente dirige proyectos de investigación aplicada relacionados a redes inalámbricas de sensores para la

medición de parámetros atmosféricos y de calidad del aire. Fue ponente en diversos congresos nacionales para colaborar con el desarrollo de las telecomunicaciones rurales y fue invitado para desarrollar talleres sobre tecnología VoIP y WiLD en la ETSIT de la Universidad Rey Juan Carlos (España) y en la Universidad Técnica Particular de Loja (Ecuador), respectivamente. Ha sido coautor del proyecto ganador en el Concurso de Prototipos de Innovaciones Tecnológicas (CONCYTEC) y ha sido ponente en varios eventos como en el Real-Time Linux Workshop. También es coautor de distintos libros relacionados a telecomunicaciones rurales.

RUTH MARÍA REÁTEGUI ROJAS

Doctora por la Escuela de Tecnología Superior (École de technologie supérieure - ÉTS), Canadá. Actualmente, es profesora en el departamento de Ciencias de la Computación y Electrónica de la Universidad Técnica Particular de Loja (UTPL), Ecuador. Sus intereses de investigación incluyen minería de texto, minería de datos, aprendizaje automático y aprendizaje profundo con aplicaciones en salud y educación

ANGIE TATIANA RECUENCO TAPIA

Estudiante de Ingeniería Mecatrónica en la Universidad Nacional de Trujillo (tercio superior), con interés en la automatización industrial. Miembro activo de la Asociación Nacional de Estudiantes de Ingeniería Mecánica, Mecatrónica, Eléctrica, Electrónica y Ramas Afines (ANEIMERA – UNT). Actualmente forma parte del grupo de investigación en Energía y Sistemas de Control Energético (ENERGYCON) de la Universidad Nacional de Trujillo.

FABIÁN RODRÍGUEZ SIBAJA

Graduado de la maestría en Administración de Proyectos por la Universidad para la Cooperación Internacional. Actualmente se desempeña como docente e investigador. Sus principales intereses de investigación incluyen metodologías de desarrollo de *software*, inteligencia artificial y sistemas de información de apoyo a los negocios.

EMILI SILVA BEZERRA

Ingeniera eléctrica graduada de la Universidade Federal do Acre, Brasil, e investigadora en el proyecto P&D PAVIC-Lab. Su labor se enfoca en inteligencia artificial, así como en el análisis de imágenes satelitales y médicas, con destacadas publicaciones en revistas y conferencias internacionales.

JUAN CARLOS TORRES-DIAZ

Doctor por la Universitat Oberta de Catalunya (UOC), España. Actualmente es profesor en el departamento de Ciencias de la Computación y Electrónica de la Universidad Técnica Particular de Loja (UTPL), Ecuador. Investiga el efecto de la tecnología en la transformación social, de manera particular la inteligencia artificial.

CINTHIA VEGEGA

Magíster, especialista e ingeniera en Sistemas de Información por la Universidad Tecnológica Nacional, Argentina, donde actualmente se desempeña como profesora e investigadora en el grupo GEMIS. Sus intereses de investigación abarcan inteligencia artificial, sistemas de información, informática y gestión del conocimiento.

LUIS ALBERTO YOVERA SUÁREZ

Estudiante de Ingeniería Mecatrónica en la Universidad Nacional de Trujillo (tercio superior), con interés en robótica e inteligencia artificial. Actualmente forma parte del grupo de investigación Energía y Sistemas de Control Energético (ENERGYCON) de la Universidad Nacional de Trujillo.



UNIVERSIDAD
DE LIMA